

13. cvičení z PSI

9.- 13. května 2022

Poznámky k testu dobré shody: Chceme otestovat (na hladině α), jestli daná veličina X s konečně mnoha (navzájem různými!) hodnotami a_1, \dots, a_k (ne nutně číselnými) má předepsané pravděpodobnosti (p_1, \dots, p_k) , tedy nulovou hypotézu

$$\mathbf{H}_0 : P(X = a_i) = p_i \text{ pro všechna } i \in \{1, \dots, k\}$$

proti alternativní hypotéze:

$$\mathbf{H}_A : P(X = a_{i_0}) \neq p_{i_0}, \text{ pro alespoň jedno } i_0 \in \{1, \dots, k\}$$

Při n pokusech s veličinou X si pro $i = 1, \dots, k$ označme veličiny

$$N_i = \text{“počet výskytů případu } X = a_i \text{ při } n \text{ pokusech”} .$$

Máme tedy náhodný vektor

$$\mathbf{N} = (N_1, \dots, N_k)$$

a vztah $N_1 + \dots + N_k = n$. Už z toho vidíme, že veličiny N_i nejsou nezávislé, ale zase k té nezávislosti tak daleko nemají. Náhodný vektor \mathbf{N} má tzv. multinomické rozdělení a jednotlivá marginální rozdělení veličin jsou binomická, konkrétně $N_i \sim \text{Bi}(n, p_i)$. Speciálně tedy $E(N_i) = n \cdot p_i$.

Jako testovací veličinu zde používáme:

$$T = \sum_{i=1}^k \frac{(N_i - n \cdot p_i)^2}{n \cdot p_i}$$

která má asymptoticky (tj. pro $n \rightarrow \infty$) tzv. χ^2 -rozdělení s $k - 1$ stupni volnosti. Pro praktické použití této asymptotiky se obvykle požaduje, aby platilo, že

$$n \cdot p_i \geq 5 \text{ pro všechna } i \in \{1, \dots, k\} .$$


Hodnoty $n \cdot p_i$ se označují jako tzv. *teoretické četnosti*.

Pokud tedy platí nulová hypotéza \mathbf{H}_0 , měly by být hodnoty veličiny T malé. Jestliže hodnoty T budou příliš velké, bude to důvod k zamítnutí nulové hypotézy.

Jak určit hranici, kde už nastane zamítnutí: veličina T má (přibližně) $\chi^2_{(k-1)}$ rozdělení, tedy platí

$$P_{(\mathbf{H}_0 \text{ platí})} (T > \chi^2_{1-\alpha; k-1}) \doteq \alpha$$

kde $\chi^2_{1-\alpha; k-1}$ je hodnota kvantilu pro $\chi^2_{(k-1)}$ rozdělení (viz obrázek, kde α je velikost žluté plochy pod hustotou $f_{\chi^2_{(k-1)}}(x)$ pro $\chi^2_{(k-1)}$ rozdělení).



Kritérium pro **ZAMÍTNUTÍ H_0** (na hladině α) proto volíme jako

$$t > \chi_{1-\alpha; k-1}^2 \Leftrightarrow \text{zamítáme } H_0 \text{ (na hladině } \alpha \text{)} .$$

Z definice chyby 1. druhu, tj.

$$\text{nastává chyba 1. druhu} \Leftrightarrow (\text{hypotéza } H_0 \text{ platí} \ \& \ \text{my ji zamítáme})$$

pak totiž máme, že

$$\begin{aligned} P_{(H_0 \text{ platí})}(\text{nastává chyba 1. druhu}) &= P_{(H_0 \text{ platí})}(\text{zamítáme } H_0 \text{ (na hladině } \alpha \text{)}) = \\ &= P_{(H_0 \text{ platí})}(T > \chi_{1-\alpha; k-1}^2) \doteq \alpha \end{aligned}$$

neboli pravděpodobnost chyby 1. druhu (ovšem za předpokladu platnosti H_0 !) je pak omezena hodnotou α .

13.1 Firma má 3 pobočky. Dva roky bylo sledováno, která z nich zaznamenala nejvyšší měsíční výnos. Bylo zjištěno, že nejvýnosnější byla první pobočka 10×, druhá 6× a třetí 8×.

Je možné říct, že první pobočka je nejvýnosnější 2× častěji než každá ze zbylých dvou? Testujte na hladině 5%.

Řešení:

Máme tedy veličinu

$$X = \text{“číslo pobočky, která je zrovna (tj. v daném měsíci) nejvýnosnější”}$$

s $k = 3$ hodnotami {první, druhá, třetí}.

Nejdříve si potřebujeme zjistit, jaké rozdělení

$$P(X = \text{první}) = p_1, \quad P(X = \text{druhá}) = p_2, \quad P(X = \text{třetí}) = p_3$$

vlastně předpokládáme. Z požadavku máme

$$p_1 = 2 \cdot p_2, \quad p_1 = 2 \cdot p_3, \quad p_1 + p_2 + p_3 = 1$$

z čehož dostáváme

$$(p_1, p_2, p_3) = \left(\frac{1}{2}, \frac{1}{4}, \frac{1}{4}\right)$$

Naše hypotéza tedy je

$$H_0 : \text{veličina } X \text{ má rozdělení s pravděpodobnostmi } (p_1, p_2, p_3) = \left(\frac{1}{2}, \frac{1}{4}, \frac{1}{4}\right),$$

a alternativní hypotéza bude:

$$H_A : \text{veličina } X \text{ má rozdělení jiné než } \left(\frac{1}{2}, \frac{1}{4}, \frac{1}{4}\right).$$

Využijeme test dobré shody. Celkový počet měření (tj. počet měsíců) je $n = 10 + 6 + 8 = 24$. Pro přehlednost si vypíšeme tabulku s jednotlivými četnostmi (pozorovanými i teoretickými):

i (pobočky)	první	druhá	třetí
n_i (pozorované četnosti)	10	8	6
p_i (teoretické pravděpodobnosti)	$\frac{1}{2}$	$\frac{1}{4}$	$\frac{1}{4}$
$n \cdot p_i$ (teoretické četnosti)	$24 \cdot \frac{1}{2} = 12$	$24 \cdot \frac{1}{4} = 6$	$24 \cdot \frac{1}{4} = 6$

Vidíme, že všechny teoretické četnosti jsou ≥ 5 , takže skutečně můžeme použít asymptotické přiblížení pro testovací statistiku T (ta tedy bude mít χ^2 -rozdělení). Teď už si jen spočítáme hodnotu této statistiky

$$t = \sum_{i=1}^3 \frac{(n_i - np_i)^2}{np_i} = \frac{(10 - 12)^2}{12} + \frac{(8 - 6)^2}{6} + \frac{(6 - 6)^2}{6} = \frac{1}{3} + \frac{2}{3} + 0 = 1$$

a porovnáme s kvantilem χ^2 -rozdělení s $k - 1 = 3 - 1 = 2$ stupni volnosti:

$$t = 1 \not\geq 5.99 \doteq \chi_{0.95; 2}^2 = \chi_{1-\alpha; k-1}^2$$

Protože zamítací kritérium NENÍ splněno, tak H_0 **NEZAMÍTÁME** (na hladině α).

Poznámky k testu nezávislosti: Máme veličiny

- X s (různými) hodnotami $\{a_1, \dots, a_k\}$ a
- Y s (různými) hodnotami $\{b_1, \dots, b_\ell\}$

a chceme otestovat (na hladině α), hypotézu

H_0 : rozdělení veličin X a Y jsou *nezávislá*

proti alternativní hypotéze:

H_A : rozdělení veličin X a Y jsou *závislá*

Při n pokusech s náhodným vektorem (X, Y) si pro $i = 1, \dots, k$ označme veličiny

$N_{i,j}$ = "počet výskytů případu $(X, Y) = (a_i, b_j)$ při n pokusech" .

a opět máme náhodný vektor

$$\mathbf{N} = (N_{1,1}, \dots, N_{k,\ell})$$

s multinomickým rozdělením. Marginální rozdělení jednotlivých veličin $N_{i,j}$ jsou opět binomická a za předpokladu *nezávislosti* X a Y mají střední hodnotu

$$E(N_{i,j}) = n \cdot P(X = a_i, Y = b_j) \stackrel{(\text{nezáv.})}{=} n \cdot P(X = a_i) \cdot P(Y = b_j) .$$

Podobně jako v testu dobré shody by tyto střední hodnoty představovaly teoretické četnosti až na to, že pravděpodobnosti $P(X = a_i)$ a $P(Y = b_j)$ nemáme v hypotéze uvedeny. Proto je odhadneme jako

$$P(X = a_i) \doteq \frac{n_{i,\bullet}}{n} \quad \text{a} \quad P(Y = b_j) \doteq \frac{n_{\bullet,j}}{n}$$

kde $n_{i,\bullet}$ a $n_{\bullet,j}$ jsou naměřené hodnoty veličin

$$N_{i,\bullet} = \sum_{j=1}^{\ell} N_{i,j} = \text{"počet výskytů případu } X = a_i \text{ při } n \text{ pokusech"}$$

$$N_{\bullet,j} = \sum_{i=1}^k N_{i,j} = \text{"počet výskytů případu } Y = b_j \text{ při } n \text{ pokusech"}$$

což jsou tzv. *marginální četnosti*.

Z tohoto důvodu jako testovací veličinu volíme:

$$T = \sum_{i=1}^k \sum_{j=1}^{\ell} \frac{\left(N_{i,j} - \frac{N_{i,\bullet} \cdot N_{\bullet,j}}{n} \right)^2}{\frac{N_{i,\bullet} \cdot N_{\bullet,j}}{n}}$$

která má asymptoticky (tj. pro $n \rightarrow \infty$) opět χ^2 -rozdělení, tentokrát ale s $(k-1) \cdot (\ell-1)$ stupni volnosti. Pro praktické použití této asymptotiky se obvykle opět požaduje, aby platilo, že

$$\frac{n_{i \cdot} \cdot n_{\cdot j}}{n} \geq 5 \text{ pro všechna } i = 1, \dots, k \text{ a } j = 1, \dots, \ell.$$

Kritérium pro **ZAMÍTNUTÍ** H_0 (na hladině α) volíme podobně jako u testu dobré shody a sice

$$t > \chi^2_{1-\alpha; (k-1) \cdot (\ell-1)} \Leftrightarrow \text{zamítáme } H_0 \text{ (na hladině } \alpha \text{)}.$$

13.2 Na $n = 100$ osobách byla pozorována barva očí a vlasů. Naměřeny byly následující sdružené četnosti:

Oči \ Vlasý	Vlasý	
	tmavé	světlé
modré	10	20
šedé	10	10
hnědé	40	10

(a) Jsou barvy očí a vlasů nezávislé? Testujte na hladině 5%.

(b) Otestujte na hladině 5%, jestli je v populaci stejně tmavovlasých jako světlovlasých.

Řešení:

Označme si veličiny

$X = \text{"barva očí daného člověka"}$

$Y = \text{"barva vlasů daného člověka"}$

a dál budeme pracovat s náhodným vektorem (X, Y) , tj. u daného člověka budeme zjišťovat barvu očí a barvu vlasů.

(a) Budeme testovat hypotézu:

H_0 : rozdělení veličin X a Y jsou *nezávislá*

proti alternativní hypotéze:

H_1 : rozdělení veličin X a Y jsou *závislá*.

na hladině významnosti $\alpha = 5\%$.

Četnost případu $(X, Y) = (i, j)$ v tabulce označme jako $n_{i,j}$ a marginální četnosti pak budou

$$n_{i \cdot} = \sum_j n_{i,j} \text{ pro případ } X = i$$

$$n_{\cdot j} = \sum_i n_{i,j} \text{ pro případ } Y = j.$$

což jsou součty v řádcích a sloupcích tabulky:

$n_{i,j}$ ($X =$) i \ ($Y =$) j	tmavé	světlé	$n_{i \cdot}$
modré	10	20	30
šedé	10	10	20
hnědé	40	10	50
$n_{\cdot j}$	60	40	

Za předpokladu \mathbf{H}_0 pak jako teoretické četnosti budeme chápat hodnoty $\frac{n_{i\bullet} \cdot n_{\bullet j}}{n}$ v této tabulce:

$\frac{n_{i\bullet} \cdot n_{\bullet j}}{n}$ ($X =$) i (Y =) j	tmavé	světlé	$n_{i\bullet}$
modré	$\frac{30 \cdot 60}{100} = 18$	$\frac{30 \cdot 40}{100} = 12$	30
šedé	$\frac{20 \cdot 60}{100} = 12$	$\frac{20 \cdot 40}{100} = 8$	20
hnědé	$\frac{50 \cdot 60}{100} = 30$	$\frac{50 \cdot 40}{100} = 20$	50
$n_{\bullet j}$	60	40	

Podmínka na tyto teoretické (tj. očekávané) četnosti ≥ 5 je splněna, takže test nezávislosti můžeme použít. Pro hodnotu testovací statistiky dostaneme

$$t = \sum_{i,j} \frac{\left(n_{i,j} - \frac{n_{i\bullet} \cdot n_{\bullet j}}{n}\right)^2}{\frac{n_{i\bullet} \cdot n_{\bullet j}}{n}} =$$

$$= \frac{(10 - 18)^2}{18} + \frac{(10 - 12)^2}{12} + \frac{(40 - 30)^2}{30} + \frac{(20 - 12)^2}{12} + \frac{(10 - 8)^2}{8} + \frac{(10 - 20)^2}{20} = 18 + \frac{1}{18} \doteq 18.056 .$$

Tuto hodnotu dále porovnáme s hodnotou kvantilu χ^2 pro $(k-1)(\ell-1)$ stupňů volnosti, kde k je počet položek veličiny X a ℓ je počet položek veličiny Y . Tento počet je nyní jiný, než by byl u “obvyklého” testu dobré shody s $k \cdot \ell$ položkami, protože data jsme použili k odhadu marginálních pravděpodobností.

Kritérium pro **ZAMÍTNUTÍ** \mathbf{H}_0 (na hladině α) bude tedy tvaru

$$t > \chi_{1-\alpha; (k-1)(\ell-1)}^2 \Leftrightarrow \text{zamítáme } \mathbf{H}_0 \text{ (na hladině } \alpha \text{)} .$$

Hledaný kvantil je

$$\chi_{1-\alpha; (3-1)(2-1)}^2 = \chi_{0.95; 2}^2 \doteq 5.992 .$$

Protože

$$t \doteq 18.056 > 5.992 \doteq \chi_{0.95; 2}^2 ,$$

hypotézu o nezávislosti **ZAMÍTÁME**.

(b) V tomto případě budeme uvažovat pouze veličinu Y a testovat (na hladině $\alpha = 5\%$) hypotézu

$$\tilde{\mathbf{H}}_0 : \text{veličina } Y \text{ má rozdělení s pravděpodobnostmi } (p_1, p_2) = \left(\frac{1}{2}, \frac{1}{2}\right),$$

proti alternativní hypotéze

$$\tilde{\mathbf{H}}_A : \text{veličina } Y \text{ má rozdělení } \textit{jiné} \text{ než } \left(\frac{1}{2}, \frac{1}{2}\right).$$

Využijeme teď opět test dobré shody. Celkový počet měření je zase $n = 100$. Naměřené četnosti odpovídají už spočítaným marginálním četnostem pro hodnoty veličiny Y , tedy $n_i = n_{\bullet i}$. Pro přehlednost si zase vypíšeme tabulku s jednotlivými četnostmi (pozorovanými i teoretickými):

i (barvy vlasů)	tmavé	světlé
n_i (pozorované četnosti)	60	40
p_i (teoretické pravděpodobnosti)	$\frac{1}{2}$	$\frac{1}{2}$
$n \cdot p_i$ (teoretické četnosti)	$100 \cdot \frac{1}{2} = 50$	$100 \cdot \frac{1}{2} = 50$

Vidíme, že všechny teoretické četnosti jsou ≥ 5 , takže můžeme použít asymptotické přiblížení pro testovací statistiku T . Teď už si jen spočítáme hodnotu této statistiky

$$t = \sum_{i=1}^2 \frac{(n_i - np_i)^2}{np_i} = \frac{(60 - 50)^2}{50} + \frac{(40 - 50)^2}{50} = 2 + 2 = 4$$

a porovnáme s kvantilem χ^2 -rozdělení s $k - 1 = 2 - 1 = 1$ stupněm volnosti:

$$t = 4 > 3.84 \doteq \chi_{0.95; 1}^2 = \chi_{1-\alpha; k-1}^2$$

Protože zamítací kritérium JE splněno, tak $\tilde{\mathbf{H}}_0$ **ZAMÍTÁME** (na hladině α).

13.3 V přímořském středisku probíhá kurz surfování a vodních lyží pro děti. Vybíráme 100 účastníků a sledujeme následující rozdělení sportů mezi chlapce a dívky:

	surf	vodní lyže
chlapci	40	20
dívky	20	20

(a) Testujte na hladině $\alpha = 1\%$, zda je druh sportu nezávislý na tom, zda je zvolen chlapcem nebo dívkou.

(b) Testujte na hladině $\alpha = 5\%$, zda jsou počty chlapců a dívek účastnících se kurzu přibližně stejné.

Řešení:

Nechť veličina X označuje pohlaví daného dítěte a Y druh sportu, který si vybralo.

(a) Budeme testovat hypotézu:

\mathbf{H}_0 : rozdělení veličin X a Y jsou *nezávislá*

proti alternativní hypotéze:

\mathbf{H}_1 : rozdělení veličin X a Y jsou *závislá*.

na hladině významnosti $\alpha = 5\%$.

Naměřené četnosti $n_{i,j}$ a marginální četnosti $n_{i,\bullet}$ a $n_{\bullet,j}$ pak budou:

$n_{i,j}$ ($X =$) i	($Y =$) j	surf	vodní lyže	$n_{i,\bullet}$
chlapci		40	20	60
dívky		20	20	40
$n_{\bullet,j}$		60	40	

Celkový počet dětí je $n = \sum_{i,j} n_{ij} = 40 + 20 + 20 + 20 = 100$. Za předpokladu \mathbf{H}_0 pak teoretické četnosti $\frac{n_{i,\bullet} \cdot n_{\bullet,j}}{n}$ v této tabulce budou:

$\frac{n_{i\bullet} \cdot n_{\bullet j}}{n}$ ($Y =$) j ($X =$) i	surf	vodní lyže	$n_{i\bullet}$
chlapci	$\frac{60 \cdot 60}{100} = 36$	$\frac{40 \cdot 60}{100} = 24$	60
dívky	$\frac{60 \cdot 40}{100} = 24$	$\frac{40 \cdot 40}{100} = 16$	40
$n_{\bullet j}$	60	40	

Podmínka na tyto teoretické (tj. očekávané) četnosti ≥ 5 je splněna, takže test nezávislosti můžeme použít. Pro hodnotu testovací statistiky dostaneme

$$t = \sum_{i,j} \frac{\left(n_{i,j} - \frac{n_{i\bullet} \cdot n_{\bullet j}}{n}\right)^2}{\frac{n_{i\bullet} \cdot n_{\bullet j}}{n}} =$$

$$= \frac{(40 - 36)^2}{36} + \frac{(20 - 24)^2}{24} + \frac{(20 - 24)^2}{24} + \frac{(20 - 16)^2}{16} \doteq 2.78 .$$

Tuto hodnotu dále porovnáme s hodnotou kvantilu χ^2 pro $(k-1)(\ell-1) = 1$ stupňů volnosti, kde $k = 2$ je počet položek veličiny X a $\ell = 2$ je počet položek veličiny Y .

Kritérium pro **ZAMÍTNUTÍ H_0** (na hladině α) bude tedy tvaru

$$t > q_{\chi^2_1(1-\alpha)} \Leftrightarrow \text{zamítáme } H_0 \text{ (na hladině } \alpha \text{)} .$$

Hledaný kvantil je

$$q_{\chi^2_1(1-\alpha)} = q_{\chi^2_1(0.99)} = 6.63 .$$

Protože

$$t \doteq 2.78 \not> 6.63 \doteq q_{\chi^2_1(0.99)} ,$$

hypotézu o nezávislosti **NEZAMÍTÁME**.

(b) V tomto případě budeme uvažovat pouze veličinu X a testovat (na hladině $\alpha = 5\%$) hypotézu

$$\tilde{H}_0 : \text{veličina } X \text{ má rozdělení s pravděpodobnostmi } (p_1, p_2) = \left(\frac{1}{2}, \frac{1}{2}\right),$$

proti alternativní hypotéze

$$\tilde{H}_A : \text{veličina } X \text{ má rozdělení } \textit{jiné} \text{ než } \left(\frac{1}{2}, \frac{1}{2}\right).$$

Využijeme teď opět test dobré shody. Celkový počet měření je zase $n = 100$. Naměřené četnosti odpovídají už spočítaným marginálním četnostem pro hodnoty veličiny X , tedy $n_i = n_{i\bullet}$. Pro přehlednost si zase vypíšeme tabulku s jednotlivými četnostmi (pozorovanými i teoretickými):

i	chlapci	dívky
n_i (pozorované četnosti)	60	40
p_i (teoretické pravděpodobnosti)	$\frac{1}{2}$	$\frac{1}{2}$
$n \cdot p_i$ (teoretické četnosti)	$100 \cdot \frac{1}{2} = 50$	$100 \cdot \frac{1}{2} = 50$

Vidíme, že všechny teoretické četnosti jsou ≥ 5 , takže můžeme použít asymptotické přiblížení pro testovací statistiku T . Teď už si jen spočítáme hodnotu této statistiky

$$t = \sum_i \frac{(n_i - np_i)^2}{np_i} = \frac{(60 - 50)^2}{50} + \frac{(40 - 50)^2}{50} = 2 + 2 = 4$$

a porovnáme s kvantilem χ^2 -rozdělení s $k - 1 = 2 - 1 = 1$ stupněm volnosti:

$$t = 4 > 3.84 \doteq q_{\chi^2_1}(0.95) = q_{\chi^2_1}(1 - \alpha)$$

Protože zamítací kritérium JE splněno, tak \tilde{H}_0 **ZAMÍTÁME** (na hladině α).

13.4 Pro pojištění motorových vozidel používá pojišťovna tři kategorie pojistného:

1 - základní pojistné,

2 - bonus 30%,

3 - bonus 50%.

V prvním roce platí pojištěný základní pojistné. Jestliže má rok bezeškodní průběh, je pojištěný v dalším roce zařazen o třídu výše (pokud je to možné), pokud ale uplatní jeden pojistný nárok, je v příštím roce zařazen o kategorii níže (pokud je to možné) a při uplatnění více než jednoho nároku o dvě kategorie níže (pokud je to možné). Počty výskytů pojistné události v jednotlivých letech jsou nezávislé, stejně rozdělené náhodné veličiny s Poissonovým rozdělením s parametrem λ .

(a) Určete počáteční rozdělení a matici pravděpodobností přechodu.


(b) Najděte stacionární rozdělení pro případ, kdy každý řidič hlásí škodu průměrně jednou za 10 let (hodnoty v matici pravděpodobností přechodu zaokrouhlete na jedno desetinné místo).

Řešení:

Veličina

$X =$ počet pojistných události pojištěnce za jeden rok

má Poissonovo rozdělení $Poiss(\lambda)$, s konkrétní volbou $\lambda = \frac{1}{10} = 0.1$. Graf Markovova řetězce s pravděpodobnostmi přechodu bude následující



Konkrétní pravděpodobnosti jsou

$$P(X = 0) = e^{-\lambda} = e^{-0.1} \doteq 0.9$$

$$P(X = 1) = \lambda e^{-\lambda} = 0.1 e^{-0.1} \doteq 0.1$$

$$P(X \geq 1) = 1 - e^{-\lambda} = 1 - e^{-0.1} \doteq 0.9$$

$$P(X \geq 2) = 1 - (1 + \lambda)e^{-\lambda} = 1 - 1.1e^{-0.1} \doteq 0.$$

Počáteční rozdělení vycházející ze stavu 1 bude $\mathbf{p}_0 = (1, 0, 0)$. Matice přechodu pak je

$$\mathbf{P} = \begin{pmatrix} 1 - e^{-\lambda} & e^{-\lambda} & 0 \\ 1 - e^{-\lambda} & 0 & e^{-\lambda} \\ 1 - (1 + \lambda)e^{-\lambda} & \lambda e^{-\lambda} & e^{-\lambda} \end{pmatrix} \doteq \begin{pmatrix} 0.1 & 0.9 & 0 \\ 0.1 & 0 & 0.9 \\ 0 & 0.1 & 0.9 \end{pmatrix}$$

Stacionární rozdělení pravděpodobnosti $\mathbf{p} = (p_1, p_2, p_3) \in \mathbb{R}^3$ je takové, které se nemění při jednom kroku. Tedy platí

$$\mathbf{p} = \mathbf{p} \cdot \mathbf{P} \text{ neboli } \mathbf{p} \cdot (\mathbf{P} - \mathbf{I}_3) = 0 .$$

Ekvivalentní zápis je

$$(\mathbf{P}^T - \mathbf{I}_3^T) \cdot \mathbf{p}^T = 0^T .$$

(A pochopitelně musí být $p_1, p_2, p_3 \geq 0$ a $\sum_{j=1}^3 p_j = 1$, protože se jedná o rozdělení pravděpodobnosti.)

Pozor! Přejít k transponované matici je nezbytný, pokud budeme při Gaussově eliminaci používat ekvivalentní ŘÁDKOVÉ úpravy soustavy (A|0). Ta totiž odpovídá rovnici $\mathbf{A}x = 0$, kdy x je SLOUPCOVÝ vektor.

Pomocí Gaussovy eliminace najdeme tudíž řešení soustavy reprezentované maticí

$$\mathbf{P}^T - \mathbf{I}_3^T = \begin{pmatrix} 0.1 & 0.1 & 0 \\ 0.9 & 0 & 0.1 \\ 0 & 0.9 & 0.9 \end{pmatrix} - \begin{pmatrix} 1 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 1 \end{pmatrix} = \begin{pmatrix} -0.9 & 0.1 & 0 \\ 0.9 & -1 & 0.1 \\ 0 & 0.9 & -0.1 \end{pmatrix} \sim \begin{pmatrix} -0.9 & 0.1 & 0 \\ 0 & 0.9 & -0.1 \end{pmatrix} .$$

Tato soustava má hodnost 2, tedy má pouze $3 - 2 = 1$ lineárně nezávislých řešení, např. $(\frac{1}{9}, 1, 9)$. Po jeho “znormování” (tj. vydělení číslem $\frac{1}{9} + 1 + 9 = \frac{91}{9}$) pak dostaneme

$$\mathbf{p} = \left(\frac{1}{91}, \frac{9}{91}, \frac{81}{91} \right) .$$

Pozor! NEJEDNÁ se o eukleidovskou normu $\|\mathbf{p}\|_2 := (\sum_i |p_i|^2)^{\frac{1}{2}}$, ALE o normu tvaru $\|\mathbf{p}\|_1 := \sum_i |p_i|$.

13.5 Markovův řetězec má matici přechodu

$$\begin{pmatrix} 0 & 0 & 0 & 1/5 & 4/5 \\ 0 & 1/2 & 0 & 1/2 & 0 \\ 0 & 0 & 1 & 0 & 0 \\ 0 & 1/3 & 0 & 2/3 & 0 \\ 1/3 & 0 & 1/3 & 0 & 1/3 \end{pmatrix}$$


(a) Klasifikujte všechny stavy.

(b) Najděte všechny uzavřené množiny stavů.

(c) Najděte všechna stacionární rozdělení pravděpodobností a posuďte, zda řetězec k některému z nich konverguje.



Řešení:

(a) Nakreslíme si příslušný orientovaný graf přiřazený této matici:



Z něj už je snadno vidět, že

- stav 3 je trvalý, dokonce absorpční (tedy tvoří komponentu $K_1 = \{3\}$),
- stavy 2 a 4 jsou trvalé a vzájemně propojené (takže tvoří komponentu $K_2 = \{2, 4\}$) a
- stavy 1 a 5 jsou přechodné.



Obě komponenty mají periodu 1, např. proto, že obsahují smyčku (tj. uzavřenou cestu délky 1) a tedy je $\pi(K_i) = \gcd(\text{délky uzavřených cest v } K_i) = \gcd(1, \dots) = 1$.

(b) Všechny uzavřené množiny trvalých stavů (tj. množiny trvalých stavů, ze kterých nevedou ven žádné šipky) jsou

$$\emptyset, \{3\}, \{2, 4\}, \{2, 3, 4\}$$

neboli (kromě prázdné množiny) to jsou vždy sjednocení nějakých komponent.

(c) Podle Věty o stacionárních rozděleních (viz Poznámky k Markovovým řetězcům), jsou všechna stacionární rozdělení na celém řetězci konvexní kombinace (jediných) stacionárních rozdělení příslušných jednotlivým komponentám (tj. takovéto rozdělení je vždy nulové mimo danou komponentu).

Pro $K_1 = \{3\}$ je příslušné stacionární řešení zřejmě $\mathbf{p}_1 = (0, 0, 1, 0, 0)$. Pro komponentu $K_2 = \{2, 4\}$ si napíšeme matici přechodů (pro pořadí stavů 2, 4):

$$\mathbf{P} = \begin{pmatrix} 1/2 & 1/2 \\ 1/3 & 2/3 \end{pmatrix}$$

a najdeme řešení $\mathbf{p} = (p_2, p_4)$ soustavy $(\mathbf{P}^T - \mathbf{I}_2^T) \cdot \mathbf{p}^T = 0$ reprezentované maticí

$$\mathbf{P}^T - \mathbf{I}_2^T = \begin{pmatrix} -1/2 & 1/3 \\ 1/2 & -1/3 \end{pmatrix} \sim \dots \sim \begin{pmatrix} -3 & 2 \\ 0 & 0 \end{pmatrix}.$$

Tato soustava má hodnotu 1, tedy má pouze $2 - 1 = 1$ lineárně nezávislých řešení, např. $(2, 3)$. Po jeho “znormování” (tj. vydělení číslem $2 + 3 = 5$) pak dostaneme

$$\mathbf{p} = (p_2, p_4) = \left(\frac{2}{5}, \frac{3}{5} \right).$$

Když toto řešení zapíšeme pro původní řetězec s pěti stavy, tak pro komponentu K_2 máme stacionární řešení $\mathbf{p}_2 = (0, \frac{2}{5}, 0, \frac{3}{5}, 0)$.

Každé stacionární řešení pro původní řetězec je tedy tvaru

$$\mathbf{p}_{stac} = (1 - t) \cdot \mathbf{p}_1 + t \cdot \mathbf{p}_2 = (0, \frac{2}{5}t, 1 - t, \frac{3}{5}t, 0)$$

kde $0 \leq t \leq 1$.

Protože všechny komponenty mají periodu 1, tak libovolné počáteční rozdělení konverguje k nějakému stacionárnímu rozdělení.