

Markovské metody pro modelování pravděpodobnosti rizikových stavů

1 Markovský řetězec

Budeme uvažovat náhodný proces s diskrétním časem (náhodnou posloupností) $X(t)$, $t \in T = \{0, 1, 2, \dots\}$ s konečnou množinou stavů $E = \{1, 2, \dots, N\}$. V případě, že $X(t) = i$, budeme říkat, že proces je v čase t ve stavu i , $t \in T$, $i \in E$. Stavy procesu $X(t)$ mohou popisovat různé rizikové situace a zajímá nás, s jakou pravděpodobností se v čase t sledovaný proces v jednotlivých rizikových situacích vyskytne.

Předpokládejme, že sledujeme v souvislosti s pojišťovacími operacemi zdravotní stav pojištěnců. Pro jednoduchost předpokládejme, že uvažujeme tři možné kategorie zdravotního stavu pojištěnce: 1. aktivní; 2. nemocný; 3. hospitalizovaný. Sledování zdravotního stavu sledujeme v diskrétních časových okamžicích, např. ve dnech. Pak tento zdravotní stav lze popsat náhodnou posloupností $X(t)$, $t \in T$. Je-li v čase $t = 2$ sledovaný pojištěnec zdravotně aktivní, lze pomocí $X(t)$ tuto situaci zapsat ve tvaru $X(2) = 1$ a říkáme, že v čase $t = 2$ je proces ve stavu 1 (tj. pojištěnec je aktivní). Cílem je popsat dynamiku procesu $X(t)$, tedy popsat pravděpodobnosti stavů $p_i(t) = P(X(t) = i)$ pro $i \in E$ a $t \in T$. V obecné situaci může být dynamika procesu $X(t)$ velmi komplikovaná, mezi veličinami $X(0)$, $X(1)$, $X(2)$, ... mohou být složité statistické vazby, tyto veličiny mohou být různě korelované a najít odhad základních charakteristik tohoto procesu a stanovit predikci budoucího vývoje procesu, najít pravděpodobnosti $p_i(t)$ pro velká t (zejména v situacích, kdy je k dispozici pouze jediný záznam realizace procesu) může být problém značně obtížný. Je ovšem možné klást na pravděpodobnostní strukturu procesu $X(t)$ jisté zjednodušující předpoklady, které dobře postihnou charakter některých procesů na straně jedné a na straně druhé po matematické stránce celou situaci zjednoduší. Typickým příkladem takového předpokladu je **markovská vlastnost** sledovaného procesu, která znamená, že pravděpodobnost budoucího vývoje procesu v čase $t + 1$, známe-li stav procesu v přítomném čase t , už nezávisí na minulém vývoji procesu v časech $t - 1$, $t - 2$, ..., 2 , 1 , 0 . Markovskou vlastnost lze formálně vyjádřit pomocí podmíněných pravděpodobností tak, že pro všechna $t = 0, 1, 2, \dots$ a všechny stavy $i, j, i_{t-1}, \dots, i_0 \in E$ platí

$$P(X_{t+1} = j | X_t = i, X_{t-1} = i_{t-1}, \dots, X_0 = i_0) = P(X_{t+1} = j | X_t = i), \quad (1)$$

pokud podmíněná pravděpodobnost vlevo existuje (tj. když $P(X_t = i, X_{t-1} = i_{t-1}, \dots, X_0 = i_0) > 0$). Splňuje-li proces $X(t)$ vlastnost (1) říkáme, že $X(t)$ je **markovský proces s diskrétním časem** nebo stručněji, že $X(t)$ je **markovský řetězec**. Pro pravděpodobnosti (1) pak zavádíme označení

$$p_{ij}(t, t+1) = P(X_{t+1} = j | X_t = i)$$

a pravděpodobnosti $p_{ij}(t, t+1)$, pokud jsou definovány, nazýváme **pravděpodobnosti přechodu ze stavu i v čase t do stavu j v $t+1$** . Někdy se tyto pravděpodobnosti nazývají **pravděpodobnosti přechodu 1. řádu**, protože jde o pravděpodobnost přechodu za jednu jednotku času. Dále zavádíme podmíněné pravděpodobnosti

$$p_{ij}(t, t+s) = P(X_{t+s} = j | X_t = i),$$

které definujeme pro $t, t+s \in T$ a $i, j \in E$ a pokud existují, nazýváme je **pravděpodobnosti přechodu ze stavu i v čase t do stavu j v čase $t+s$** . Jinak se též nazývají **pravděpodobnosti přechodu s -tého řádu**. V některých situacích se může stát, že pravděpodobnost přechodu $p_{ij}(t, t+s)$ nezávisí na časových okamžicích t a $t+s$, ale pouze na jejich vzdálenosti, tedy na jejich rozdílu s . Pak říkáme, že markovský řetězec $X(t)$ je

INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

homogenní. V další části tohoto odstavce budeme uvažovat jenom homogenní markovské řetězce a zavedeme následující terminologii a označení:

$p_i(0) = P(X(0) = i)$	nazveme počáteční pravděpodobnost stavu i ,
$\mathbf{p}(0) = (p_1(0), p_2(0), \dots, p_N(0))$	nazveme počáteční rozdělení stavů markovského řetězce,
$p_i(t) = P(X(t) = i)$	nazveme absolutní pravděpodobnost stavu i v čase t ,
$\mathbf{p}(t) = (p_1(t), p_2(t), \dots, p_N(t))$	nazveme absolutní rozdělení stavů markovského řetězce v čase t .

Dále pro homogenní řetězec platí, že $p_{ij}(t, t+1)$ nezávisí na t a můžeme proto místo $p_{ij}(t, t+1)$ psát pouze $p_{ij}(1) = p_{ij}$. Pravděpodobnost p_{ij} nazýváme pravděpodobností přechodu homogenního řetězce po jednom kroku a matici

$$\mathbf{P} = \begin{pmatrix} p_{11}, p_{12}, \dots, p_{1N} \\ p_{21}, p_{22}, \dots, p_{2N} \\ \vdots \\ p_{N1}, p_{N2}, \dots, p_{NN} \end{pmatrix}$$

nazýváme **maticí pravděpodobností přechodu homogenního markovského řetězce** stručně jenom **maticí pravděpodobností přechodu**. Pro každý řádek matice pravděpodobností přechodu $\mathbf{P}$ platí, že $\sum_{j=1}^N p_{ij} = 1$, a protože $p_{ij} \geq 0$, $i, j \in E$, platí, že matice $\mathbf{P}$ je **stochastická matice**.

Pomocí matice pravděpodobností přechodu $\mathbf{P}$ a vektoru počátečních stavů $\mathbf{p}(0)$ lze jednoduše popsat dynamiku procesu $X(t)$ (tj. jeho konečněrozměrná rozdělení pravděpodobností). Platí

$$P(X(0) = i_0, X(1) = i_1, \dots, X(k) = i_k) = p_{i_0}(0) p_{i_0 i_1} p_{i_1 i_2} \cdots p_{i_{k-1} i_k}$$

pro libovolné stavy $i_0, i_1, \dots, i_k \in E$. Uvedeného vztahu je možné využít k popisu pravděpodobností přechodu s -tého řádu. Pro homogenní markovský řetězec platí, že $p_{ij}(t, t+s)$ nezávisí na t , můžeme proto zavést označení

$$p_{ij}^{(s)} = p_{ij}(t, t+s) \text{ pro } s = 1, 2, \dots \text{ a } p_{ij}^{(0)} = \begin{cases} 0 & \text{pro } i \neq j, \\ 1 & \text{pro } i = j. \end{cases}$$

Pravděpodobnosti $p_{ij}^{(s)}$ pak udávají pravděpodobnosti přechodu homogenního řetězce ze stavu i do stavu j po s krocích. Můžeme je zapsat do matice

$$\mathbf{P}^{(s)} = \begin{pmatrix} p_{11}^{(s)}, \dots, p_{1N}^{(s)} \\ \vdots \\ p_{N1}^{(s)}, \dots, p_{NN}^{(s)} \end{pmatrix},$$

kterou nazýváme **maticí pravděpodobností přechodu homogenního markovského řetězce po s krocích** nebo též s -tého řádu. Pomocí vzorce pro celkovou pravděpodobnost a markovské vlastnosti snadno nahlédneme, že platí

$$\begin{aligned} p_{ij}^{(2)} &= P(X(t+2) = j | X(t) = i) = \\ &= \sum_{k=1}^N P(X(t+2) = j | X(t+1) = k, X(t) = i) \cdot P(X(t+1) = k | X(t) = i) = \\ &= \sum_{k=1}^N P(X(t+2) = j | X(t+1) = k) P(X(t+1) = k | X(t) = i) = \sum_{k=1}^N p_{kj} p_{ik} \end{aligned}$$

INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

pro $i, j \in E$. Když získaný výsledek zapíšeme v maticovém tvaru, dostaneme

$$\mathbf{P}^{(2)} = \mathbf{P}^2.$$

Analogicky lze odvodit, že platí

$$\mathbf{P}^{(s)} = \mathbf{P}^s.$$

Slovně vyjádřeno, matice pravděpodobností přechodu homogenního markovského řetězce po s krocích je rovna s -té mocnině matice pravděpodobností přechodu tohoto řetězce. Ze vzorce pro celkovou pravděpodobnost dostaneme vyjádření absolutní pravděpodobnosti stavu i v čase t ve tvaru

$$\begin{aligned} p_i(t) &= P(X(t) = i) = \sum_{k=1}^N P(X(0) = k) P(X(t) = i | X(0) = k) = \\ &= \sum_{k=1}^N p_k(0) p_{ki}^{(t)}, \quad i \in E. \end{aligned}$$

Potom užitím maticového zápisu dostaneme

$$\mathbf{p}(t) = \mathbf{p}(0) \mathbf{P}^{(t)} = \mathbf{p}(0) \mathbf{P}^t. \quad (2)$$

Vidíme, že absolutní pravděpodobnosti stavů homogenního markovského řetězce v čase t lze jednoduše vyjádřit pomocí počátečních pravděpodobností stavů a matice pravděpodobností přechodu. Z uvedeného vztahu lze snadno získat pravděpodobnosti rizikových stavů sledovaného procesu, když známe počáteční rozdělení stavů a matici pravděpodobností přechodu.

Z hlediska dlouhodobého sledování řetězce $X(t)$ je užitečné umět stanovit absolutní pravděpodobnosti stavů $p_i(t)$ pro velká t . Tedy pro $t \rightarrow \infty$ je potřeba stanovit $\lim_{t \rightarrow \infty} p_i(t)$, $i \in E$. Vzhledem k (2) závisí tato limita na vlastnostech matice pravděpodobností přechodu $\mathbf{P}$. Lze ukázat, že v případě, kdy existuje přirozené číslo r tak, že r -tá mocnina matice $\mathbf{P}$, tedy matice $\mathbf{P}^r$ má v některém sloupci jenom kladné prvky, tak existují limity

$$\begin{aligned} \lim_{t \rightarrow \infty} p_{ik}^{(t)} &= \pi_k, \\ \lim_{t \rightarrow \infty} p_k(t) &= \pi_k \end{aligned}$$

pro $i, k \in E$, přičemž limitní pravděpodobnosti $\pi_1, \pi_2, \dots, \pi_N$ jsou jediným řešením rovnic

$$\pi_k = \sum_{j=1}^N \pi_j p_{jk}, \quad k \in E \quad \text{a} \quad \sum_{j=1}^N \pi_j = 1. \quad (3)$$

Když položíme $\boldsymbol{\pi} = (\pi_1, \dots, \pi_N)$ a

$$\boldsymbol{\Pi} = \begin{pmatrix} \boldsymbol{\pi} \\ \boldsymbol{\pi} \\ \dots \\ \boldsymbol{\pi} \end{pmatrix} = \begin{pmatrix} \pi_1, \pi_2, \dots, \pi_N \\ \pi_1, \pi_2, \dots, \pi_N \\ \dots \\ \pi_1, \pi_2, \dots, \pi_N \end{pmatrix},$$

lze uvedené limitní vztahy zapsat maticově ve tvaru

$$\begin{aligned} \lim_{t \rightarrow \infty} \mathbf{P}^{(t)} &= \lim_{t \rightarrow \infty} \mathbf{P}^t = \boldsymbol{\Pi} \\ \text{a} \quad \lim_{t \rightarrow \infty} \mathbf{p}(t) &= \lim_{t \rightarrow \infty} \mathbf{p}(0) \mathbf{P}^t = \boldsymbol{\pi}, \end{aligned}$$

INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

přičemž π je jediným řešením soustavy rovnic

$$\pi = \pi P, \quad \pi \mathbf{1} = 1, \quad (4)$$

kde $\mathbf{1}$ je sloupcový vektor délky N tvořený samými jedničkami.

Vektor $\pi = (\pi_1, \dots, \pi_N)$ pak definuje tzv. **stacionární rozdělení pravděpodobností** řetězce $X(t)$.

Jestliže počáteční rozdělení pravděpodobnosti je stacionární, tj. když $p(0) = \pi$, pak všechna absolutní rozdělení pravděpodobnosti $p(t)$ jsou stacionární, tj. $p(t) = \pi$ a říkáme, že řetězec je ve **statistické rovnováze**.

Příklad

Vyjdeme z předpokladů, že při pojištění motorových vozidel používá pojišťovna tři kategorizací pojistného: 0 – základní pojistné, 1 – bonus 30 % a 2 – bonus 50 %. Označme $X(t)$ náhodný proces, který značí kategorii pojistného v t -tém pojistném období. Množina stavů tohoto procesu je $E = \{0, 1, 2\}$. Pojištěnec je zařazen do příslušné kategorie podle toho, jaký počet pojistných událostí nahlásil v předchozím období. V prvním pojistném období je pojištěnec zařazen do kategorie 0 a platí základní pojištění. Jestliže v prvním pojistném období měl pojištěnec bezeškodní průběh, je v následném období zařazen o kategorii výše (získá bonus). Pokud ale uplatní jeden pojistný nárok, je v příštím období zařazen o kategorii níže, při uplatnění více než jednoho pojistného nároku je zařazen o dvě kategorie níže. Předpokládejme, že počet pojistných událostí v pojistném období t je náhodná veličina Y_t , $t = 1, 2, \dots$. Potom proces $X(t)$ je definován následovně: $X(0) = 1$ a pro $t \geq 1$ platí

$$X(t+1) = \begin{cases} \min\{X(t) + 1; 2\} & \text{pro } Y_t = 0, \\ \max\{X(t) - 1; 0\} & \text{pro } Y_t = 1, \\ 0 & \text{pro } Y_t > 1. \end{cases}$$

Budeme předpokládat, že náhodné veličiny Y_t pro $t = 1, 2, \dots$ jsou nezávislé a mají stejné Poissonovo rozdělení s parametrem λ . Pak $X(t)$ je homogenní markovský řetězec s množinou stavů $E = \{0, 1, 2\}$, počátečním rozdělením pravděpodobností $p(0) = (1, 0, 0)$ a maticí pravděpodobností přechodu

$$P = \begin{pmatrix} 1 - e^{-\lambda} & e^{-\lambda} & 0 \\ 1 - e^{-\lambda} & 0 & e^{-\lambda} \\ 1 - e^{-\lambda} - \lambda e^{-\lambda} & \lambda e^{-\lambda} & e^{-\lambda} \end{pmatrix}.$$

Protože matice P má v prvním sloupci jenom kladné prvky, existuje stacionární rozdělení $\pi = \lim_{t \rightarrow \infty} p(t)$ a získáme jej řešením rovnice (3). Když položíme $a_0 = e^{-\lambda}$ a $a_1 = \lambda e^{-\lambda}$, dostaneme po dosazení do (3) soustavu rovnic

$$\begin{aligned} \pi_0 &= \pi_0(1 - a_0) + \pi_1(1 - a_0) + \pi_2(1 - a_0 - a_1), \\ \pi_1 &= \pi_0 a_0 + \pi_2 a_1, \\ \pi_2 &= \pi_1 a_0 + \pi_2 a_0, \\ \pi_0 + \pi_1 + \pi_2 &= 1. \end{aligned}$$

Odtud snadno nalezneme řešení

$$\begin{aligned} \pi_0 &= \frac{1 - a_0 - a_0 a_1}{1 - a_0 a_1} = \frac{1 - e^{-\lambda} - \lambda e^{-2\lambda}}{1 - \lambda e^{-2\lambda}}, \\ \pi_1 &= \frac{a_0(1 - a_0)}{1 - a_0 a_1} = \frac{e^{-\lambda}(1 - e^{-\lambda})}{1 - \lambda e^{-2\lambda}}, \\ \pi_2 &= \frac{a_0^2}{1 - a_0 a_1} = \frac{e^{-2\lambda}}{1 - \lambda e^{-2\lambda}}. \end{aligned}$$

INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

Odtud lze odvodit, že když základní výše pojištění za pojistné období je V , zaplatí pojištěnec při bonusu 30 % pro kategorii 1 a při bonusu 50 % pro kategorii 2 v dlouhodobém horizontu za pojišťovací období částku $\pi_0 V + 0,7\pi_1 V + 0,5\pi_2 V$. Uvedená částka závisí na parametru λ , který je roven střednímu počtu pojistných událostí pojištěnce. Při dlouhodobém sledování se dá odhadnout dlouhodobým průměrem počtu pojistných událostí pojištěnce za sledovaná pojistná období.

Příklady k procvičení

1. Počasí v jisté pobřežní oblasti je jednoduše klasifikováno jako „slunečno“ nebo „deštivo“. Po slunečném dni následuje opět slunečný den s pravděpodobností 0,9 a po deštivém dni přichází deštivý den s pravděpodobností 0,3.
 - a) Popište popsanou situaci pomocí markovského řetězce.
 - b) Jestliže v pátek bylo slunečno, jaká je pravděpodobnost, že neděle bude opět slunečná?
 - c) Jestliže v pátek bylo slunečno, jaká je pravděpodobnost, že sobota i neděle bude opět slunečná?
2. Předpokládejme, že daná osoba O_1 obdrží zprávu od osoby O_0 , že daný rizikový jev A pravděpodobně nastane. Zprávu předá osobě O_2 , která ji dále předá osobě O_3 atd. Předpokládejme, že každá z uvažovaných osob tuto zprávu předává v nezměněné podobě s pravděpodobností $1 - \theta$ a s pravděpodobností θ předá negaci původní zprávy, $0 < \theta < 1$. (Lze si představit, že θ je „malé“ číslo, blízké nule.) Otázkou je zjistit pravděpodobnost, že t -tá osoba O_t obdrží původní zprávu, že jev A pravděpodobně nastane. modelujte situaci pomocí markovského řetězce. Určete stacionární rozdělení pravděpodobností.