

# Vježbe - Slučajni procesi IX. dio

## Ergodski teorem

**Teorem 1 (Jaki zakon velikih brojeva).**

*Neka je  $\{Y_n, n \geq 1\}$  niz nezavisnih jednako distribuiranih slučajnih varijabli na vjerojatnosnom prostoru  $(\Omega, \mathcal{F}, P)$  takvih da je  $E|Y_1| < \infty$  i stavimo  $EY_1 = \mu$ . Tada je*

$$P\left(\lim_{n \rightarrow \infty} \frac{Y_1 + \dots + Y_n}{n} = \mu\right) = 1,$$

*tj.*

$$\frac{1}{n} \sum_{i=1}^n Y_i \xrightarrow{g.s.} \mu.$$

## Teorem 2 (Ergodski teorem).

Neka je  $\{X_n, n \in \mathbb{N}_0\}$  ireducibilan i pozitivno povratan Markovljev lanac s jedinstvenom stacionarnom distribucijom  $\pi$  te  $f$  nenegativna ili ograničena realna funkcija definirana na  $S$ . Tada vrijedi:

$$P \left( \lim_{n \rightarrow \infty} \frac{1}{n} \sum_{i=0}^{n-1} f(X_i) = \sum_{k \in S} f(k) \pi_k \right) = 1,$$

tj.

$$\frac{1}{n} \sum_{i=0}^{n-1} f(X_i) \xrightarrow{g.s.} \sum_{k \in S} f(k) \pi_k.$$

- Definirajmo

$$N_i(n) = \sum_{k=0}^{n-1} 1_{\{X_k=i\}}, \quad n \in \mathbb{N},$$

vrijeme koje lanac provede u stanju  $i$  prije trenutka  $n$ .

Specijalno, za  $f = 1_{\{j\}}$  iz ergodskog teorema dobivamo

### Korolar 1.

*Za ireducibilan i pozitivno povratan Markovljev lanac sa stacionarnom distribucijom  $\pi$  vrijedi*

$$P \left( \lim_{n \rightarrow \infty} \frac{N_j(n)}{n} = \pi_j \right) = 1, \quad \forall j \in S.$$

## Korolar 2.

Neka  $f : S \rightarrow \mathbb{R}$  ograničena funkcija. Tada za svaku početnu distribuciju lanca  $X$  vrijedi

$$\lim_{n \rightarrow \infty} \frac{1}{n} \sum_{k=0}^{n-1} E[f(X_k)] = \sum_{j \in S} f(j) \pi_j.$$

Specijalno, za  $f = 1_{\{j\}}$  te početno stanje  $i$  dobivamo

$$\lim_{n \rightarrow \infty} \frac{1}{n} \sum_{k=0}^{n-1} p_{ij}^{(k)} = \pi_j.$$

## Zadaci

## Zadatak 1.

Neka je Markovljev lanac sa skupom stanja  $S = \{0, 1, 2\}$  i matricom prijelaznih vjerojatnosti

$$\Pi = \begin{bmatrix} 0.4 & 0.6 & 0 \\ 0.2 & 0.5 & 0.3 \\ 0.1 & 0.7 & 0.2 \end{bmatrix}$$

model za predviđanje sutrašnjih vremenskih prilika na temelju poznatih informacija o današnjem vremenu. Pri tome je s 0 označeno oblačno vrijeme, s 1 kišno vrijeme, a s 2 sunčano vrijeme. Odredite dugoročno prosječan broj sunčanih dana (tj. prosječan broj sunčanih dana kroz dulji vremenski period).

## Zadatak 2 (Bonus-malus sustav automobilskog osiguranja).

*U bonus-malus sustavu automobilskog osiguranja visina osiguranikove premije proporcionalna je broju potraživanja od osiguravajućeg društva (odnosno broju šteta) u prethodno osiguranoj godini. Promotrimo pojednostavljen sustav bonus-malus osiguranja, tj. pretpostavimo da razlikujemo samo četiri skupine rizika: 0, 1, 2, 3 pri čemu je 0 skupina najnižeg rizika, a 3 skupina najvišeg rizika. Osiguranik prelazi u skupinu nižeg rizika samo ako nije imao nikakvih potraživanja od osiguravajućeg društva u prethodnoj godini. Ako je u prethodnoj godini imao  $k$  prijavljenih šteta, onda prelazi u skupinu  $k$  višeg rizika, do najviše 3. Npr. ako je bio u skupini 0 i prijavio dvije štete, u idućoj godini će biti svrstan u skupinu 2.*

*Pretpostavimo da broj šteta u jednoj godini možemo modelirati nezavisno od prethodnih Poissonovom slučajnom varijablom s parametrom  $\lambda = \frac{1}{2}$ .*

- Objasnite zašto prelaskes osiguranika iz jedne skupine rizika u drugu možemo modelirati Markovljevim lancem. Odredite skup stanja i matricu prijelaznih vjerojatnosti tog Markovljevog lanca. Je li on ireducibilan i aperiodičan?*
- Odredite graničnu distribuciju ovog Markovljevog lanca.*
- Neka su visine premija definirane funkcijom*

$$f(k) = \begin{cases} 200 & , \quad k = 0 \\ 200 + 50 \cdot 2^k & , \quad k \in \{1, 2, 3\} \end{cases} ,$$

*gdje je  $k$  oznaka skupine rizika. Odredite dugoročno prosječnu visinu premije osiguranja jedne police.*

## Zadatak 3.

Pretpostavimo da promatramo skladište ograničenog kapaciteta, tj. neka u promatrano skladište stane najviše  $c$  istovrsnih proizvoda. Potražnja za proizvodima u skladištu u  $n$ -tom danu modelirana je slučajnom varijablom  $D_n$  za koju vrijedi

$$P(D_n \geq i) = \frac{1}{2^i}, \quad i \in \mathbb{N}_0.$$

Ako na kraju  $n$ -tog dana u skladištu ostane  $m$  ili manje proizvoda skladište se nadopunjuje do punog kapaciteta, a u suprotnom (ako ostane više od  $m$  proizvoda) se ne nadopunjuje. Zbog jednostavnosti pretpostavimo da je  $c = 3$  i promotrimo slučajeve  $m = 0$ ,  $m = 1$  i  $m = 2$ .

- Definirajte slučajnu varijablu kojom modeliramo broj proizvoda u skladištu na kraju  $(n + 1)$ -og dana.
- Za sva tri slučaja odredite skup stanja i matricu prijelaznih vjerojatnosti Markovljevog lanca  $\{X_n, n \in \mathbb{N}_0\}$ . Provjerite jesu li u sva tri slučaja Markovljevi lanci ireducibilni i aperiodični.
- Odredite stacionarne distribucije ovih triju Markovljevih lanaca.
- Definirajte funkciju koja opisuje očekivanu nerealiziranu potražnju (tj. broj proizvoda koji su traženi ali nisu mogli biti isporučeni jer ih, zbog ograničenog kapaciteta skladišta, nije bilo)  $(n + 1)$ -og dana. Odredite dugoročno očekivanu nerealiziranu potražnju.



## Zadatak 4.

Rukometaš Fabijan igra u napadu i broj postignutih golova na jednoj utakmici ovisi o njegovim ozljedama. Ako je

- 0 - zdrav, onda daje 6 golova,
- 1 - lakše ozlijeđen, onda daje 4 gola,
- 2 - teže ozlijeđen, onda daje 1 gol.

Prijelazi njegove spremnosti između dvije utakmice modelirani su Markovljevim lancem sa skupom stanja  $S = \{0, 1, 2\}$  i matricom prijelaznih vjerojatnosti

$$P = \begin{bmatrix} 0.7 & 0.2 & 0.1 \\ 0.3 & 0.5 & 0.2 \\ 0.2 & 0.4 & 0.4 \end{bmatrix}.$$

- a) Kolika je dugoročna proporcija vremena u kojem je Fabijan zdrav?
- b) Koliki je očekivani broj utakmica između dvije teže ozljede?
- c) Koliki je dugoročno prosječan broj golova koje Fabijan da po utakmici?

## Primjer: Google PageRank

- Pretpostavimo da na svijetu postoji  $N$  web stranica. Postavimo model kretanja web stranicama kao Markovljev lanac u kojem je svako stanje jedna web stranica. Htjeli bi napraviti algoritam za rangiranje web stranica.

- 1 Svaka stranica je jedno stanje  $i = 1, \dots, N$ .
- 2 Dodajmo izmišljeno stanje - *restart stranica* - i označimo je kao stanje 0.
- 3 Definirajmo prijelazne vjerojatnosti:
  - (a) Neka je  $0 < d < 1$  konstanta takva da je  $1 - d$  vjerojatnost da surfajući stranicama prestanemo pratiti linkove i restartiramo navigiranje (npr. sami upišemo stranicu ili bookmark). Svako stanje  $i$ ,  $0 \leq i \leq N$  ima vjerojatnost  $1 - d$  prelaska u stanje 0, tj.  $p_{i0} = 1 - d$ . Dakle, na kojoj god stranici se nalazimo postoji fiksna vjerojatnost da ćemo restartirati surfanje umjesto ići po linkovima.
  - (b) Vjerojatnost prelaska iz stanja 0 u neko stanje  $j \neq 0$  je  $p_{0,j} = \frac{d}{N}$ , tj. iz restartirajućeg stanja vjerojatnost odlaska na bilo koju stvarnu stranicu je jednaka.
  - (c) Vjerojatnost prelaska iz stanja  $i \neq 0$  u stanje  $j \neq 0$  je

$$p_{ij} = \frac{d}{C(i)} \mathbf{1}_{\{i \text{ ima link na } j\}},$$

gdje je  $C(i)$  broj linkova sa stranice  $i$ . Znači, za svaku stranicu osim vjerojatnosti odlaska u restart  $1 - d$ , ostatak vjerojatnosti  $d$  je uniformno raspoređena među svim stranicama na koje se može putem linka otići s  $i$ . Ako  $i$  ne sadrži link na  $j$  tada je  $p_{ij} = 0$ .

- Intuitivno, htjeli bi rangirati stranice tako da ona na kojoj se dugoročno provede više vremena ima što bolji rang.
- Je li lanac ireducibilan? U svakom trenutku možemo restartirati surfanje i otići na svaku stranicu.
- Je li pozitivno povratan? Konačan skup stanja, ireducibilan pa i pozitivno povratan.
- Jedinствена stacionarna distribucija po ergodskom teoremu daje prosječno vrijeme boravka za svako stanje:

$$\pi_0 = \sum_{i=0}^N \pi_i p_{i0} = \sum_{i=0}^N \pi_i (1-d) = 1-d$$

$$\begin{aligned} \pi_j &= \pi_0 p_{0j} + \sum_{i=1}^N \pi_i p_{ij} \\ &= (1-d) \frac{d}{N} + \sum_{\{i: i \text{ ima link na } j\}} \pi_i \frac{d}{C(i)} \end{aligned}$$

- Da bi dobili originalni Google PageRank pomnožimo sve s  $\frac{N}{d}$ :

$$\frac{N}{d}\pi_j = (1 - d) + \sum_{\{i:i \text{ ima link na } j\}} \left(\frac{N}{d}\pi_i\right) \frac{d}{C(i)}$$

- Definiramo PageRank kao  $PR(j) = \frac{N}{d}\pi_j$  i dobijemo

$$PR(j) = (1 - d) + \sum_{\{i:i \text{ ima link na } j\}} PR(i) \frac{d}{C(i)},$$

što je izvorni Google PageRank.

- Ergodski teorem zapravo kaže da ako surfamo webom po ovom Markovljevom lancu tada vjerojatnost posjeta nekoj stranici u nekom trenutku konvergira, i ta vjerojatnost je ista bez obzira odakle krenemo sa surfanjem (početna distribucija)
- Za PageRank se prosječno provedeno vrijeme skalira s  $\frac{N}{d}$ , što je nebitno jer poredak ostaje isti.
- Neke procjene za  $d$  su oko 0.85.