

Rušenje rekorda: o jednom problemu iz teorije vjerojatnosti



Dario Lovreković,
Goran Trupčević
i Andja Valent, Zagreb

1. Uvod

Problem kojim se bavimo u ovom članku ukratko je opisan pitanjem: *Koliko se često ruše rekordi?* Prepostavimo da vršimo n nezavisnih mjerjenja neke pojave (npr. prosječne godišnje temperature ili količine padalina na nekom području) ili da jednostavno n puta biramo slučajan broj. Rekordnom vrijednošću smatramo onu koja je veća od svih do tad izmjerениh vrijednosti (naravno da na isti način možemo promatrati i rekordno male vrijednosti). Koliki broj rekorda možemo očekivati?

Naglasak rada nije na samom rješenju problema, već na različitim pristupima i stupnjevima rješavanja. Tako ćemo problem najprije rješiti na intuitivan, matematički neformalan način. U idućem koraku želimo potaknuti učenike da svoje rezultate eksperimentalno provjere, a za što su problemi iz područja vjerojatnosti osobito pogodni. I konično, ostaje nam pitanje dokaza rješenja. Svoj ćemo rezultat dokazati na dva načina. Prvi dokaz je kombinatoran i smatramo ga razumljivim učenicima upoznatim sa osnovnim kombinatornim principima i tehnikom deriviranja. Drugi dokaz u

potpunosti slijedi naše intuitivno rješenje i daje mu matematičku pozadinu, ali naglašavamo da nadilazi okvire srednjoškolskog znanja. U prvom čitanju može se i preskočiti i treba ga gledati kao motivaciju za neke daljnje teme iz područja vjerojatnosti.

Pa započnimo! Prepostavimo da na slučajan način n puta biramo realan broj iz nekog zadanoog intervala. Smatrat ćemo razumnim za pretpostaviti da je vjerojatnost višestrukog pojavljivanja iste vrijednosti jednak 0. Što možemo unaprijed, prije nego što odaberemo i jedan broj, zaključiti o vjerojatnosti da u nekom trenutku dobijemo rekord? Najprije, u prvom ćemo odabiru bez sumnje dobiti rekord, pa ako biramo samo jedan broj, očekivani broj rekorda je 1. Za drugi broj koji ćemo birati unaprijed znamo da će biti rekord s vjerojatnosti $\frac{1}{2}$, jer je jednako vjerojatno da će biti veći ili manji od prvog. Dakle, ako biramo dva broja, očekivani broj rekorda je $1 + \frac{1}{2}$. Isto tako, za treći broj koji ćemo birati možemo zaključiti da će biti rekord s vjerojatnosti $\frac{1}{3}$ jer ima jednaku šansu biti najveći kao i prva dva. Dakle, nakon tri odabira, očekivani broj

rekorda je $1 + \frac{1}{2} + \frac{1}{3}$. Nastavljajući na isti način zaključujemo da očekivani broj rekorda nakon n odabranih brojeva iznosi

$$H_n = 1 + \frac{1}{2} + \frac{1}{3} + \cdots + \frac{1}{n}.$$

2. Eksperimentalna provjera

Naše početno rješenje je intuitivno jasno, ali bez matematičke strogooće. Može li onda biti i točno? Prije pokušaja dokaza rezultat smo odlučili eksperimentalno provjeriti. U prvoj smo provjeri koristili program Microsoft Excel. S pomoću funkcije RAND koja generira slučajan realan broj u intervalu $[0,1)$ dobili smo 100 takvih brojeva i zapisali broj rekorda, pri čemu smo zasebno mjerili broj rekordno velikih i broj rekordno malih vrijednosti. Pokus smo ponovili 1000 puta. Za prosječnu vrijednost za rekordno velike vrijednosti dobili smo 5.1879, a za rekordno male vrijednosti 5.1989. Kako je $H_{100} = 1 + \frac{1}{2} + \frac{1}{3} + \cdots + \frac{1}{100} \approx 5.1873$, prvu provjeru svog rezultata smatramo uspješnom.

U drugoj smo se provjeri odlučili na nešto drukčiji pristup, opisan u [4]. Za svaki od 12 mjeseci u godini promatrati smo prosječnu izmjerenu mjesecnu temperaturu u gradu Zagrebu, na meteorološkoj postaji Zagreb-Grič, za posljednjih $n = 50$ godina, kao što je i prikazano u tablici 1. Prebrojavali smo izmjerene rekordne vrijednosti i pokus ponovili 24 puta, jer smo za svaki mjesec u godini gledali broj rekordno velikih i broj rekordno malih vrijednosti. Tako primjerice za mjesec veljaču imamo 3 rekordno izmjerene najveće prosječne temperature (za godine 1963., 1964. i 1966.) i 1 izmjerenu rekordno malu prosječnu temperaturu (za godinu 1963.) Prosječan broj ta 24 rekorda iznosi 4.4583 što je blizu našem izračunanim očekivanom broju rekorda $H_{50} \approx 4.4992$.

Naravno da je upitno koliko se mjerena klimatskih veličina mogu smatrati nezavisnim mjerenjima, pogotovo za vremenska razdoblja duža od 100 godina. Primjetimo i da se ponekad ponavljaju iste vrijednosti, a razlog je ponajprije taj što se prema uobičajenoj metodologiji prosječne tempera-

ture zaokružuju na jednu decimalu. Želimo napomenuti da su naši podaci dobiveni korištenjem ECA&D baze podataka [1], iz koje je moguće dobiti razne dnevno izmjerene podatke o klimatskim veličinama za mnogobrojne klimatske postaje u Europi. Tako su primjerice za klimatsku postaju Zagreb-Grič dostupni podatci od 1861. godine. Moguće je rezultat iz ovog rada, ali naravno i neke druge rezultate iz vjerojatnosti, testirati i na drugim izmjenim klimatskim veličinama ili drugim meteorološkim postajama.

3. Kombinatorni izračun očekivanog broja rekorda

U ovom ćemo odjeljku problemu određivanja očekivanog broja rekorda pristupiti na drukčiji način. Polazimo od pretpostavke da ćemo u n mjerjenja dobiti sve različite rezultate, pa će broj rekorda zapravo samo ovisiti o poretku dobivenih veličina. Zbog toga svaki skup od n mjerjenja identificiramo s permutacijom skupa $\{1, 2, \dots, n\}$. Ukupan broj takvih permutacija je $n!$. Cilj nam je odrediti broj takvih permutacija s točno k rekorda, za $k = 1, 2, \dots, n$. Zašto? Zato što očekivani broj rekorda nije ništa drugo nego prosječan broj rekorda koji ćemo onda izračunati formulom

$$\overline{R}(n) = \frac{R(n, 1) \cdot 1 + R(n, 2) \cdot 2 + \cdots + R(n, n) \cdot n}{n!} \\ = \frac{1}{n!} \sum_{k=1}^n k \cdot R(n, k)$$

pri čemu smo uveli oznaku $R(n, k)$ za broj permutacija skupa $\{1, 2, \dots, n\}$ s točno k rekorda.

Primjer. Za $n = 3$ postoji točno $3! = 6$ permutacija skupa $\{1, 2, 3\}$. Među njima permutacije (312) i (321) imaju točno jedan rekord, pa je $R(3, 1) = 2$. Permutacije (132) , (213) i (231) imaju točno dva rekorda, pa je $R(3, 2) = 3$, a permutacija (123) ima točno tri rekorda, pa je $R(3, 3) = 1$. Prosječan broj rekorda sada je

$$\overline{R}(3) = \frac{2 \cdot 1 + 3 \cdot 2 + 1 \cdot 3}{6} = \frac{11}{6}.$$

S druge je strane $H_3 = 1 + \frac{1}{2} + \frac{1}{3} = \frac{11}{6} = \overline{R}(3)$.

Tablica 1. Prosječne mjesečne temperature Zagreb–Grič, 1963. – 2012.

	1	2	3	4	5	6	7	8	9	10	11	12
1963.	-4.7	-2.1	5.5	13	16.1	20.6	23	21.5	17.9	11.5	12	-2.5
1964.	-4.8	2	4.6	12.8	16.2	21.4	21.6	19.6	16.7	11.4	8.6	1.4
1965.	2.5	-0.4	7.4	10.5	14.9	19.6	20.9	18.8	17.1	11.5	4.7	4
1966.	-1.7	8.9	6.5	14	16.2	20.5	19.9	19.5	17.5	15.5	4.8	2.8
1967.	-0.2	4.3	8.7	10.9	17.1	18.8	23.1	21.1	17.9	13.3	7	0.9
1968.	-0.2	3.3	8.2	14.2	16.7	19.5	21.2	19.4	16.2	12.7	7	-0.9
1969.	-0.9	1.2	5	11.5	18.1	18.7	21.1	19.2	17.3	11.5	9.8	-1.8
1970.	0.2	2.2	5.5	10.7	14.1	20.7	20.9	20.8	16.9	10.9	9.5	1.3
1971.	0.8	4.6	3.8	13	17.6	18.7	22.2	22	14.8	11.4	6.2	2
1972.	-0.6	5	9.7	11.6	15.4	20	21.1	19.8	14.1	10.5	6.5	2
1973.	0.3	3.4	7	9.6	17.5	19.7	21.3	21	17.4	10.2	4.8	2.6
1974.	2.2	7.2	9.3	11.3	15	19	21	22.1	16.8	7.7	7.3	4.6
1975.	5.6	3.2	8.4	11.9	17.6	18.4	21.3	20	19.3	10.9	5.2	2.1
1976.	2.5	1.7	4.1	11.8	16.5	19.2	22.1	17.7	15.5	11.5	8.4	1.8
1977.	3.2	6.3	11	10.4	16.4	20	20.7	20.2	14.7	12.5	6.9	0.9
1978.	1.4	2.1	8.4	10.6	14	18.8	19.5	19	15.8	11.1	2.2	2.1
1979.	-0.3	3.1	9.1	10.9	17.5	21.5	19.9	19.7	16.8	10.6	7	5.4
1980.	-0.7	4.2	6.9	9.4	13.5	18.9	20.2	20.7	16.5	11.4	5.1	0.6
1981.	-0.5	1.8	10.3	12.2	16.1	19.9	21.3	20.9	17.2	13.6	6.2	2.1
1982.	-0.9	0.7	6.9	9.4	17	20.6	22.2	20.7	19.5	12.5	7.1	5.1
1983.	4.3	0.7	8.7	14.1	17.8	19.3	23.8	21.4	17.3	12.1	3.9	2.3
1984.	1.5	1.3	6.2	11.3	14.5	18.4	19.5	19.9	16.8	12.8	7	1.9
1985.	-3.4	-1.3	6.1	11.7	17.5	17.6	22	21.5	17.8	11.5	4.2	6.4
1986.	2.2	-2.1	4.5	12.8	19.2	18.3	20.5	21.9	16.1	11.6	7.1	0.7
1987.	-1.8	3	2.7	12.6	14.8	19.5	23.2	19.8	20.6	12.8	6.1	2.7
1988.	5	5	6.8	11.5	16.8	18.8	23.3	22	17.2	11.5	2.6	2.6
1989.	0.2	5.4	11	12.9	15.7	17.7	21.8	20.8	16.9	12.3	5.5	4.3
1990.	1.1	8.6	11.3	11.2	17.9	19.1	21.6	22.2	15.8	12.5	6.8	2.2
1991.	2.8	0.2	10.3	10.5	13.3	19.8	23	21.4	18.3	10.2	7.1	0.2
1992.	2.9	5.8	8.3	12.8	17.3	20.2	22.5	25.8	18.7	11.2	8	2.3
1993.	3.1	2.3	7.1	13	19.3	20.6	21.7	22.4	16.5	12.9	2.9	3.3
1994.	5.2	4	11.7	12.3	17	20.4	23.9	23.4	19.3	10.2	9	3.4
1995.	1.9	7.4	6.7	13.1	16.2	18.6	23.8	20.4	15.6	13.3	5.8	2
1996.	0	0.7	4.6	12.1	17.6	21.1	20.2	20.8	13.8	12.6	8.9	-0.3
1997.	-0.3	6	8.3	9.3	17.8	20.6	21.4	21.6	17.9	10.4	6.7	4
1998.	5.1	7.7	6.5	13.6	17.1	21.3	22.4	22.5	16.7	12.6	4.8	-1.5
1999.	1.7	3.2	9.6	13.5	17.4	20.7	22.4	21.6	19.7	13	4.6	2.9
2000.	-0.2	6.5	8.9	15.4	18.5	22.3	21.5	24.4	17.8	14.2	10.5	5.9
2001.	4.6	5.9	10.9	11.8	18.7	19.1	22.9	23.6	15	15.4	4.7	-0.7
2002.	2.2	7.6	10.4	11.4	18.9	21.9	22.5	21.6	16.1	12.3	10.8	2.7
2003.	0.5	-0.1	8.9	11.9	20.4	24.5	23.6	25.8	17	10.1	9.4	3
2004.	0.9	4	6.7	12.5	15.6	19.6	21.7	21.7	17	13.9	7.7	2.9
2005.	2	-0.1	6.8	12.7	17.5	20.5	22.1	19.2	17.5	13.1	6	2.6
2006.	-0.1	2.8	6.4	13.5	16.7	21.2	24.7	19.3	18.8	14.6	9.9	5.2
2007.	7.5	8.1	10.2	15.9	18.8	22.7	23.8	22.1	15.5	11.2	6.1	1.4
2008.	3.8	6.8	8.3	13	18.2	21.6	22.8	22.5	16.5	14	8.8	4.3
2009.	0	4.1	8.4	15.8	19.2	20.2	23.2	23.6	19.7	12.7	9.3	4.1
2010.	0.3	3.6	7.8	13.3	16.7	21	24.1	21.7	15.9	10.6	9.9	1.7
2011.	3.1	2.9	8.7	14.9	18.1	21.6	22.9	24.3	21.4	11.7	4.3	4.8
2012.	3.8	-0.2	11.5	13.3	17.5	22.9	25	25.4	18.9	12.9	10	2.8

Kako bismo odredili brojeve $R(n, k)$, polazimo od sljedeće rekurzivne relacije.

Lema. Za $k > 0$ vrijedi

$$R(n, k) = R(n - 1, k - 1) + (n - 1) \cdot R(n - 1, k)$$

Dokaz. Skup permutacija skupa $\{1, 2, \dots, n\}$ s točno k rekorda rastavljamo na dva podskupa, ovisno o poziciji jedinice. Broj takvih permutacija s 1 na prvom mjestu jednak je $R(n - 1, k - 1)$ jer je tada 1 rekord, pa u permutaciji preostalih $n - 1$ elemenata trebamo još $k - 1$ rekorda. Drugi podskup čine permutacije u kojima je 1 na nekom drugom mjestu, njih ukupno $n - 1$. Tada 1 nije rekord, pa za svako takvo mjesto, u permutaciji preostalih $n - 1$ elemenata trebamo točno k rekorda. Broj takvih permutacija jednak je dakle $(n - 1) \cdot R(n - 1, k)$ iz čega slijedi tvrdnja leme. ■

U nastavku izračuna brojeva $R(n, k)$ uvodimo funkciju $f_n(x)$ formulom

$$f_n(x) = \sum_{k=1}^n R(n, k) \cdot x^k.$$

Tako je primjerice $f_1(x) = R(1, 1) \cdot x = x$.

Zašto tražimo takvu funkciju? Deriviranjem funkcije $f_n(x)$ dobivamo

$$f'_n(x) = \sum_{k=1}^n k \cdot R(n, k) \cdot x^{k-1}$$

to jest

$$f'_n(1) = \sum_{k=1}^n k \cdot R(n, k)$$

pa će očekivani broj rekorda biti jednak

$$\bar{R}(n) = \frac{1}{n!} \sum_{k=1}^n k \cdot R(n, k) = \frac{1}{n!} f'_n(1).$$

Sada ćemo odrediti eksplisitnu formulu za funkciju $f_n(x)$. Iz definicije funkcije $f_n(x)$ i rekurzije iz leme dobivamo da vrijedi

$$f_n(x) = x \cdot f_{n-1}(x) + (n - 1) \cdot f_{n-1}(x),$$

a odavde

$$f_n(x) = (x + n - 1) f_{n-1}(x).$$

Višestrukim korištenjem posljednje formule dobivamo

$$f_n(x) = (x + n - 1) \cdot (x + n - 2) \cdot \dots \cdot (x + 1) \cdot f_1(x)$$

to jest

$$f_n(x) = (x + n - 2) \cdot \dots \cdot (x + 1) \cdot x.$$

Radi lakšeg deriviranja, gornji izraz logaritmiramo i dobivamo

$$\ln f_n(x) = \ln x + \ln(x + 1) + \dots + \ln(x + n - 1).$$

Deriviranjem slijedi

$$\frac{1}{f_n(x)} \cdot f'_n(x) = \frac{1}{x} + \frac{1}{x + 1} + \dots + \frac{1}{x + n - 1}.$$

Uvrstimo li $x = 1$ dobivamo

$$\frac{1}{n!} f'_n(1) = 1 + \frac{1}{2} + \dots + \frac{1}{n} = H_n$$

pa konačno dobivamo

$$\bar{R}(n) = \frac{1}{n!} f'_n(1) = H_n,$$

što smo i željeli pokazati.

Osvrnamo se kratko na metodu izračuna. Problem smo rješili standardnim kombinatornim metodama – s pomoću rekurzivne relacije i, iako to nije posebno napomenuto, s pomoću funkcije izvodnice. Za obje metode, više detalja i puno zadataka prikladnih srednjoškolskoj razini može se pronaći u [2].

Napomenimo i da se brojevi $(-1)^{n-k} R(n, k)$ nazivaju Stirlingovi brojevi prve vrste. O njima se više može pročitati u [6].

4. Osvrt na početno rješenje problema

U prethodnom smo odjeljku uspješno dokazali naše početno neformalno rješenje, ali bitno drugačijim pristupom. Kao što smo najavili u uvodu, rad ćemo završiti dokazom koji prati naš prvi način razmišljanja. Nije nam cilj objasniti sve detalje, već zaokružiti problem i motivirati neke nove teme iz područja vjerojatnosti ([3], [5]).

Radi jednostavnosti, promatrat ćemo slučaj $n = 3$ i prepostaviti da bismo tri slučajna broja X_1, X_2, X_3 iz intervala $[0, 1]$. Mi dakle vršimo pokus čiji ishod nije unaprijed određen. Skup svih mogućih ishoda je skup $\Omega = [0, 1] \times [0, 1] \times [0, 1] \subset \mathbf{R}^3$. Za $k = 1, 2, 3$ uvodimo funkcije Y_k čije vrijednosti ovise o ishodu našeg pokusa

$$Y_k = \begin{cases} 1, & \text{ako je } X_k \text{ rekord} \\ 0, & \text{ako } X_k \text{ nije rekord.} \end{cases}$$

Ovakve funkcije koje slučajnom događaju pridružuju neki realni broj, nazivaju se diskretne slučajne varijable. Ako je Y neka diskretna slučajna varijabla koja poprima vrijednosti y_1, y_2, \dots, y_n i ako je p_i vjerojatnost da Y poprimi vrijednost y_i , onda se očekivana vrijednost od Y označava s $E(Y)$ i računa kao $E(Y) = p_1y_1 + \dots + p_ny_n$. Prema tomu, očekivane vrijednosti slučajnih varijabli Y_k iznose

$$\begin{aligned} E(Y_k) &= p(X_k \text{ rekord}) \cdot 1 + p(X_k \text{ nije rekord}) \cdot 0 \\ &= p(X_k \text{ rekord}). \end{aligned}$$

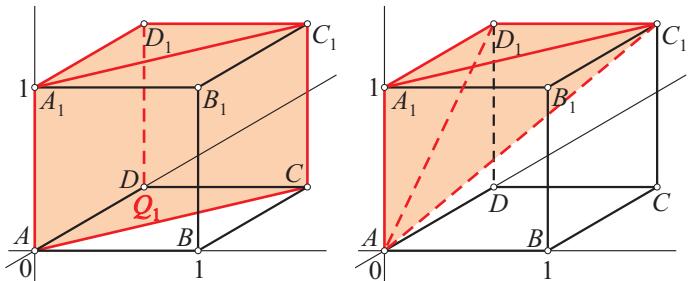
Kako nas zanima ukupan broj rekorda, uvodimo novu slučajnu varijablu $Y = Y_1 + Y_2 + Y_3$. Matematičko očekivanje ima svojstvo linearnosti, pa očekivani broj rekorda iznosi

$$E(Y) = E(Y_1) + E(Y_2) + E(Y_3).$$

Sada, baš kao i u uvodu najprije očito vrijedi $E(Y_1) = p(X_1 \text{ rekord}) = 1$. Vjerojatnosti da su X_2 i X_3 rekordi, izračunat ćemo s pomoću geometrijske vjerojatnosti. Skup svih mogućih ishoda $\Omega = [0, 1] \times [0, 1] \times [0, 1]$, te skup svih ishoda takvih da je X_2 , odnosno X_3 , rekord, možemo prikazati u koordinatnom sustavu, kako je prikazano na slici 1. Tražene vjerojatnosti računamo s pomoću formula

$$p(X_i \text{ rekord}) = \frac{\text{obujam}(X_i \text{ rekord})}{\text{obujam}(\Omega)}.$$

Skupu $\{X_2 \text{ rekord}\}$ odgovara prizma $ABCA_1B_1C_1$, a skupu $\{X_3 \text{ rekord}\}$ piramida $A_1C_1D_1A$.



Slika 1. Skup Ω svih mogućih ishoda u koordinatnom sustavu prikazan je kockom $ABCA_1B_1C_1D_1$.

Primijetimo da je Ω jedinična kocka volumena 1, skup $\{X_2 \text{ rekord}\}$ je prizma volumena $\frac{1}{2}$, a skup $\{X_3 \text{ rekord}\}$ je piramida volumena $\frac{1}{3}$. Stoga je $E(Y_2) = p(X_2 \text{ rekord}) = \frac{1}{2}$, odnosno $E(Y_3) = p(X_3 \text{ rekord}) = \frac{1}{3}$. Sada je

$$E(Y) = E(Y_1) + E(Y_2) + E(Y_3) = 1 + \frac{1}{2} + \frac{1}{3} = H_3,$$

upravo što smo željeli i pokazati.

Za kraj, prisjetimo se da je red $1 + \frac{1}{2} + \dots + \frac{1}{n}$ divergentan što znači da kad $n \rightarrow \infty$, broj rekorda također neograničeno raste. Štoviše, za velike vrijednosti od n vrijedi da je $H_n \approx \ln n + \gamma$, gdje je $\gamma \approx 0.5772$ Euler-Mascheronijeva konstanta. To znači da za npr. $n = 1000$ bez izračuna H_{1000} odmah možemo procijeniti da će očekivani broj rekorda iznositi $\approx \ln 1000 + 0.5722 \approx 7.485$.

LITERATURA

- 1/ www.ecad.eu/
- 2/ M. Cvitković, *Kombinatorika*, Element, Zagreb, 2007.
- 3/ N. Elezović, *Diskretna vjerojatnost*, Element, Zagreb, 2011.
- 4/ N. Glick, *Breaking Records and Breaking Boards*, American Mathematical Monthly 85(1), 2–26, 1978.
- 5/ N. Sarapa, *Teorija vjerojatnosti*, Školska knjiga, Zagreb, 1992.
- 6/ D. Veljan, *Kombinatorika s teorijom grafova*, Školska knjiga, Zagreb, 1989.