


# Twierdzenie Sparre–Andersena


Łukasz RAJKOWSKI

W pewnej szkole w Symulandii każde z 1000 uczęszczających do niej dzieci dostało takie oto zadanie domowe: Trzeba rzucić 10 razy kostką sześcienną. W zależności od wyniku dziecko ma oddać lub pobrać od swoich rodziców kwotę określoną przez następującą tabelkę (ujemne kwoty oznaczają obowiązek oddania pieniędzy rodzicom):


liczba oczek	1	2	3	4	5	6
wypłata	-4	-3	-2	1	3	5



Rys. 1. Przy takim przebiegu rozgrywki mamy  $D = 6$  i  $L = 2$



Rys. 2. Przy takim przebiegu rozgrywki mamy  $D = 10$  i  $L = 1$



Rys. 3. Przy takim przebiegu rozgrywki mamy  $D = 1$  i  $L = 10$

Następnie dzieci miały narysować wykres zależności stanu swojego konta od liczby rzutów (uwzględniając stan konta 0 w „zerowym rzucie”) i na jego podstawie stwierdzić, ile rzutów kończyło się dodatnim stanem konta (co oznaczmy przez  $D$ ) oraz po którym rzucie stan konta po raz pierwszy osiągnął największą wartość (co oznaczmy przez  $L$ ). Rysunek 1 przedstawia przykładowy przebieg. Na pierwszy rzut oka wartości  $D$  i  $L$  nie są specjalnie związane – łatwo skonstruować przykłady, gdzie jedna z nich jest duża, a druga mała (rys. 2 i rys. 3). Gdy jednak dyrektor szkoły opublikował podsumowanie wyników pracy domowej, uwagę wszystkich zwróciła poniższa tabelka, przedstawiająca liczby uczniów, którzy uzyskali poszczególne wartości  $D$  (pierwszy wiersz) oraz poszczególne wartości  $L$  (drugi wiersz).

	0	1	2	3	4	5	6	7	8	9	10
$D$	188	101	71	66	70	58	60	67	67	93	159
$L$	188	103	63	81	61	58	62	75	71	81	157

To, że tyle samo uczniów uzyskało wartości  $D$  i  $L$  równe 0, nie jest w ogóle zaskakujące – łatwo przekonać się, że byli to po prostu ci sami uczniowie. Dla pozostałych wartości  $D$  i  $L$  liczby uczniów, którzy je uzyskali, wydają się zaskakująco bliskie, choć przedstawione wcześniej przykłady pokazywały, że jeden uczeń mógł uzyskać istotnie różne wartości  $D$  i  $L$ . Dyrektor szkoły doniósł o swoim odkryciu premierowi Symulandii, który – poruszony tym nieoczekiwanym związkiem – zarządził ogólnokrajowy eksperyment. Każdy z  $10^6$  obywateli miał przeprowadzić to samo doświadczenie i przesłać uzyskane wyniki pocztą do Ministerstwa Liczenia. Pracujący tam urzędnicy skrupulatnie policzyli wszystkie wyniki i wyprodukowali tabelkę analogiczną do poprzedniej, z tą różnicą, że przedstawiała ona procentowy udział poszczególnych wyników w całej populacji, zaokrąglony do dziesiątych części procenta.

	0	1	2	3	4	5	6	7	8	9	10
$D$	19,5%	10,3%	7,8%	6,6%	6,2%	6,0%	6,1%	6,4%	6,9%	8,3%	15,9%
$L$	19,5%	10,3%	7,8%	6,6%	6,2%	6,0%	6,1%	6,4%	6,9%	8,3%	15,9%

Kto jak kto, ale mieszkańcy Symulandii wiedzieli, że w tej sytuacji nie może być mowy o żadnym przypadku. Najwyraźniej prawdopodobieństwa uzyskania poszczególnych wartości przez zmienne  $D$  i  $L$  są równe! Zależność ta utrzymywała się w kolejnych eksperymentach, z różnymi wypłatami oraz kośćmi, które nie były dobrze wyważone. Symulandcy uczeni prędko znaleźli uzasadnienie tej własności, które oparte jest na pewnym kombinatorycznym twierdzeniu. Zanim je sformułujemy, wprowadzimy kilka oznaczeń.

Niech  $\mathbf{x} = (x_1, \dots, x_n)$  będzie dowolnym ciągiem liczb rzeczywistych. Ustawieniem  $\mathbf{x}$  nazwiemy dowolny ciąg  $(x_{\sigma(1)}, \dots, x_{\sigma(n)})$ , gdzie  $\sigma$  jest pewną permutacją zbioru  $\{1, 2, \dots, n\}$ . Subtelna różnica między ustawieniami a permutacjami polega na tym, że ponieważ wyrazy ciągu  $\mathbf{x}$  mogą się powtarzać, ustawień tego ciągu może być mniej niż  $n!$ . W szczególności ciąg stały ma tylko jedno ustawienie. Niech  $\mathbf{s} = (s_0, \dots, s_n)$  będzie ciągiem sum częściowych  $\mathbf{x}$ ,

Dla ciągu  $\mathbf{x} = (1, 3, -2, -4, 1, 5, -3, -2, -2, 5)$  (którego sumy częściowe zostały zilustrowane na rysunku 1) kolejne kroki algorytmu przedstawia poniższa tabelka. W lewej kolumnie wypisana jest postać ciągu bazowego przed wykonaniem danego kroku, w środku suma tego ciągu bazowego, a w prawej kolumnie wartość dodawana na początku ciągu tworzonego po wykonaniu tego kroku.

ciąg bazowy	$\Sigma$	+
1, 3, -2, -4, 1, 5, -3, -2, -2, 5	2	1
3, -2, -4, 1, 5, -3, -2, -2, 5	1	3
-2, -4, 1, 5, -3, -2, -2, 5	-2	5
-2, -4, 1, 5, -3, -2, -2	-7	-2
-2, -4, 1, 5, -3, -2	-5	-2
-2, -4, 1, 5, -3	-3	-3
-2, -4, 1, 5	0	5
-2, -4, 1	-5	1
-2, -4	-6	-4
-2	-2	-2

W tej sytuacji  $\mathbf{x}' = (-2, -4, 1, 5, -3, -2, -2, 5, 3, 1)$ .  
Mamy wówczas  $\mathbf{s}' = (0, -2, -6, -5, 0, -3, -5, -7, -2, 1, 2)$ ,  
zatem  $D_{\mathbf{x}'} = 2 = L_{\mathbf{x}}$ .

tzn.  $s_0 = 0$  i  $s_k = \sum_{i=1}^k x_i$  dla  $1 \leq k \leq n$ . Niech  $D_{\mathbf{x}}$  oznacza liczbę dodatnich wyrazów w ciągu  $\mathbf{s}$  oraz niech  $L_{\mathbf{x}}$  będzie najmniejszym indeksem w ciągu  $\mathbf{s}$ , dla którego przyjmuje on największą wartość. Okazuje się, że dla każdego ciągu  $\mathbf{x}$  możemy znaleźć jego ustawienie  $\mathbf{x}'$  tak, aby  $L_{\mathbf{x}} = D_{\mathbf{x}'}$ .

**Twierdzenie.** *Istnieje taka bijekcja  $\Psi: \mathbb{R}^n \rightarrow \mathbb{R}^n$ , że dla dowolnego  $\mathbf{x} \in \mathbb{R}^n$  ciąg  $\mathbf{x}' = \Psi(\mathbf{x})$  jest ustawieniem  $\mathbf{x}$  oraz  $L_{\mathbf{x}} = D_{\mathbf{x}'}$ .*

**Dowód.** Wybierzmy dowolnie ciąg  $\mathbf{x} = (x_1, \dots, x_n)$ . Ciąg  $\mathbf{x}'$  tworzymy zgodnie z następującą procedurą. Na początku naszym „ciągiem bazowym” jest  $\mathbf{x}$ , a „ciągiem tworzoną” jest ciąg pusty. W każdym kroku procedury patrzmy na sumę wszystkich wyrazów obecnego ciągu bazowego – jeśli jest ona dodatnia, zabieramy z niego pierwszy wyraz, w przeciwnym wypadku wyraz ostatni. Zabraną wyraz wstawiamy na początek ciągu tworzonego. Dla przykładu, w przypadku przedstawionym na marginesie, w szóstym kroku ciągiem bazowym jest  $(-2, -4, 1, 5, -3)$ . Suma jego wyrazów to  $-3$ , zatem zabieramy z niego ostatni wyraz i dokładamy do ciągu tworzonego, którym po wykonaniu tego kroku jest  $(-3, -2, -2, 5, 3, 1)$ .

Postulowany w twierdzeniu ciąg  $\mathbf{x}'$  to ciąg utworzony po  $n$  krokach opisanej procedury. Oczywiście  $\mathbf{x}'$  jest ustawieniem ciągu  $\mathbf{x}$ . Niech  $\mathbf{s}$  i  $\mathbf{s}'$  będą ciągami sum częściowych ciągów odpowiednio  $\mathbf{x}$  i  $\mathbf{x}'$ . Za pomocą prostej indukcji możemy uzasadnić, że suma wyrazów  $k$ -tego ciągu bazowego to  $s'_{n-k+1}$  (pamiętajmy, że wyrazy zabierane z ciągów bazowych przechodzą na początek ciągu tworzonego). W tej sytuacji liczba dodatnich wyrazów ciągu  $\mathbf{s}'$  (czyli  $D_{\mathbf{x}'}$ ) to liczba etapów konstrukcji, w których suma ciągu bazowego była dodatnia. Pokażemy teraz, że ta liczba jest równa  $L_{\mathbf{x}}$ .

Załóżmy, że  $L_{\mathbf{x}} = l$ , tzn. maksimum ciągu sum częściowych  $\mathbf{s}$  pojawia się po raz pierwszy na indeksie  $l$ . Zwróćmy uwagę, że zmiany w ciągu bazowym mają „gąsienicowy” charakter, tzn. zawsze zabieramy któryś z dwóch jego krańcowych wyrazów. Uzasadnimy, że wyrazy  $x_i$  dla  $i \leq l$  są zabierane z ciągu bazowego tylko „z lewej strony”, a wyrazy  $x_i$  dla  $i > l$  tylko „z prawej strony”. Wynika to z poniższych dwóch obserwacji:

- jeśli ciąg bazowy zaczyna się od  $x_{l+1}$ , to jego suma jest niedodatnia, gdyż  $\sum_{i=l+1}^{l+m} x_i = s_{l+m} - s_l \leq 0$ , więc w takim wypadku będziemy już czerpać tylko „z prawej strony” ciągu bazowego.
- jeśli ciąg bazowy kończy się na  $x_l$ , to jego suma jest dodatnia, gdyż  $\sum_{i=l-m}^l x_i = s_l - s_{l-m} > 0$ , więc wtedy będziemy już czerpać tylko „z lewej strony” ciągu bazowego.

W tej sytuacji dokładnie  $l$  razy czerpiemy „z lewej strony” ciągu bazowego, zatem tyle razy ma on dodatnią sumę. Zgodnie z wcześniejszymi obserwacjami oznacza to, że  $D_{\mathbf{x}'} = l$ . Pozostaje uzasadnić, że przekształcenie  $\Psi$  faktycznie jest bijekcją, co wynika z istnienia „procedury odwrotnej”, której nietrudną konstrukcję pozostawiamy Czytelnikowi.  $\square$

Jaki jest związek przedstawionego twierdzenia z niesamowitym zjawiskiem zaobserwowanym w Symulandii? Możemy w tym wypadku utożsamiać zdarzenia elementarne z ciągami wyników kolejnych gier. Jeśli  $\mathbf{x} = (x_1, \dots, x_{10})$  jest pewnym takim ciągiem, to każde ustawienie tego ciągu ma to samo prawdopodobieństwo wystąpienia. W związku z tym, na mocy naszego twierdzenia, zdarzenia elementarne ze zbioru  $\{D = d\} = \{\mathbf{x}: D_{\mathbf{x}} = d\}$  (dla pewnej ustalonej wartości  $d$ ) są połączone we wzajemnie jednoznaczne pary ze zdarzeniami elementarnymi (o tym samym prawdopodobieństwie) ze zbioru  $\{L = d\} = \{\mathbf{x}: L_{\mathbf{x}} = d\}$ . Oznacza to, że prawdopodobieństwa uzyskania poszczególnych wartości przez zmienne  $D$  i  $L$  faktycznie są równe, tak jak sugerowały to badania przeprowadzone w Symulandii.

Czytelnicy trochę bardziej obcy z rachunkiem prawdopodobieństwa bez trudu zauważą, że przedstawione rozumowanie może być zastosowane dla dowolnych zmiennych losowych (nie tylko tych o rozkładzie dyskretnym), a także, że dowodzi ono tak naprawdę równości rozkładów wektorów losowych  $(D, S)$  i  $(L, S)$ , gdzie  $S$  jest sumą wszystkich wypłat. Obserwacja ta nosi nazwę twierdzenia Sparre–Andersena, które w pełnym brzmieniu przytaczamy poniżej.

**Twierdzenie (Sparre–Andersen).** *Niech  $X_1, \dots, X_n$  będą niezależnymi zmiennymi losowymi o tym samym rozkładzie. Niech  $S_0 = 0$ ,  $S_k = \sum_{i=1}^k X_i$  dla  $1 \leq k \leq n$  oraz*

$$D = \sum_{i=1}^n \mathbf{1}_{\{S_i > 0\}}, \quad L = \min\{0 \leq i \leq n: S_i = \max_{0 \leq j \leq n} S_j\}.$$

*Wówczas wektory losowe  $(D, S)$  i  $(L, S)$  mają ten sam rozkład prawdopodobieństwa.*