

Rachunek Prawdopodobieństwa MAP1181
Wydział Matematyki, Matematyka Stosowana
Paradoks Simpsona - przykłady
Opracowanie: Zofia Wróblewska

Paradoks Simpsona ¹ pokazuje jak trudne jest wnioskowanie oparte na prawdopodobieństwie warunkowym. Dla zilustrowania tego paradoksu przeanalizujemy następujące przykłady...

1. Umieralność na gruźlicę

Powiedzmy, że wylosowano ze spisu zmarłych w latach powojennych (np. 1945-1950) dane osoby z miasta M_1 lub miasta M_2 . Jeżeli przyjmujemy następujące oznaczenia dla zdarzeń A , B i C : A = „osoba z miasta M_1 umarła na gruźlicę”, B = „osoba z miasta M_2 umarła na gruźlicę”, C = „osoba jest kobietą”, to według Simpsona może zdarzyć się, że ... *W mieście M_1 jest większa umieralność chorych na gruźlicę niż w mieście M_2 , a mimo to większa umieralność chorych kobiet, a także większa umieralność chorych mężczyzn, na gruźlicę, jest w mieście M_2 .* ² Powyższy efekt możemy zapisać za pomocą wzorów w następujący sposób:

$$P(A) > P(B)$$

i jednocześnie

$$P(A|C) < P(B|C) \text{ oraz } P(A|C^C) < P(B|C^C).$$

Zatem jeśli do pary cech (A i B) dołączy trzecia (C), to powstaje układ, który jest bardziej skomplikowany, niżby się to z pozoru wydawało.

Poniżej, w Tabelach 1 i 2, postaramy się tak dobrać dane dla obu miast, aby wystąpił paradoks Simpsona.

Tabela 1. Dane dla miasta M_1

	Osoba umarła na gruźlicę		Procentowe TAK
	TAK	NIE	
Kobieta	20	7000	0,28%
Mężczyzna	260	8000	3,15%
Łącznie	280	15000	1,83%

Tabela 2. Dane dla miasta M_2

	Osoba umarła na gruźlicę		Procentowe TAK
	TAK	NIE	
Kobieta	60	13000	0,46%
Mężczyzna	110	2000	5,21%
Łącznie	170	15000	1,12%

Rzeczywiście umieralność na gruźlicę w mieście M_1 ($P(A)$) jest o 0,71% większa niż w mieście M_2 ($P(B)$). Jeżeli uwzględnimy płeć jako zmienną grupującą to umieralność chorych kobiet w mieście M_2 ($P(B|C)$) jest o 0,18% większa niż w mieście M_1 ($P(A|C)$) oraz umieralność chorych mężczyzn w mieście M_2 ($P(B|C^C)$) jest o 2,06% większa niż w mieście M_1 ($P(A|C^C)$). Paradoks ten ostrzega nas, że w rozważaniu relacji prawdopodobieństw zdarzeń (tu $P(A)$ i $P(B)$) nie wystarczy udowodnić, że dana relacja zachodzi dla wszystkich przypadków pewnej zmiennej grupującej (tu taką zmienną jest płeć: C i C^C). Ostateczna konkluzja, jak widać, i tak może być inna.

Jak można wyjaśnić paradoks Simpsona? Zauważmy, że w pierwszym mieście umarło więcej mężczyzn, a wśród mężczyzn umieralność na gruźlicę była większa. To podwyższa umieralność na gruźlicę w mieście M_1 . Ponieważ

¹ Nie chodzi bynajmniej o Barta Simpsona, bohatera popularnej kreskówki, lecz o brytyjskiego statystyka o tymże nazwisku, który w 1951 roku opisał ten statystyczny efekt.

² Przykład częściowo pochodzi z książki: J. Jakubowski i R. Sztencel, **Wstęp do teorii prawdopodobieństwa**, SCRIPT, Warszawa 2001.

w drugim mieście umarło mniej mężczyzn, więc możemy zadbać o to, aby procentowa umieralność na gruźlicę, wśród mężczyzn, była tu wyższa niż w pierwszym mieście, przy łącznej umieralności na gruźlicę niższej.

2. Kara śmierci

W Przykładzie 2 rozważymy wpływ rasy ofiary i rasy sprawcy na orzeczenie kary śmierci. W Tabeli 3 zebrano dane 674 morderstw popełnionych na Florydzie między 1976 a 1987. ³ Zamiast dwóch tabel 2x2, jak w Przykładzie 1, można rozważyć jedną tabelę wyższego wymiaru 2x2x2.

Tabela 3. Kara śmierci a rasa sprawcy i ofiary

Rasa Ofiary	Rasa Sprawcy	Kara śmierci		Procentowe TAK
		TAK	NIE	
Biała	Biała	53	414	11.3%
	Czarna	11	37	22.9%
Czarna	Biała	0	16	0.0%
	Czarna	4	139	2.8%
Łącznie	Biała	53	430	11.0%
	Czarna	15	176	7.9%

Przyjmijmy oznaczenia. Niech A = „orzeczone karę śmierci”, B = „sprawca jest Biała” oraz C = „ofiara jest Biała”. Podobnie jak w poprzednio obliczamy odpowiednie prawdopodobieństwa:

$$P(A|B) = \frac{53}{483} \approx 0,110 \text{ oraz } P(A|B^C) = \frac{15}{191} \approx 0,079 \text{ czyli } P(A|B) > P(A|B^C);$$

natomiast

$$P(A|B \cap C) = \frac{53}{467} \approx 0,113 \text{ oraz } P(A|B^C \cap C) = \frac{11}{48} \approx 0,229$$

czyli $P(A|B \cap C) < P(A|B^C \cap C)$;

$$P(A|B \cap C^C) = \frac{0}{16} = 0 \text{ oraz } P(A|B^C \cap C^C) = \frac{4}{143} \approx 0,028$$

czyli $P(A|B \cap C^C) < P(A|B^C \cap C^C)$.

Jeżeli ofiarą jest biała osoba to kara śmierci jest orzeczona o 11,6% częściej w przypadku czarnego sprawcy niż w przypadku białego sprawcy. Jeżeli ofiarą jest czarna osoba to kara śmierci jest orzeczona o 2,8% częściej w przypadku czarnego sprawcy niż w przypadku białego sprawcy. Natomiast nie uwzględniając rasy ofiary konkluzja jest odwrotna: kara śmierci jest orzeczona o 3,1% częściej w przypadku białego sprawcy niż w przypadku czarnego sprawcy.

Ten pozornie niemożliwy efekt niespodziewanie pojawia się w naukach społecznych i statystyce związanej z medycyną, kiedy zmienna ważona, która różni się od wartości określonej indywidualnie dla poszczególnych grup, jest używana do oceny połączonych grup. ⁴

³ Dane pochodzą z: M. L. Radelet i G. E. Pierce, *Florida Law Review*, vol. 43, 1-34, 1991.

⁴ <https://pl.wikipedia.org/wiki/Paradoks.Simpsona>