



# W sieci Bayesa

Łukasz Rajkowski

*67. Szkoła Matematyki Poglądowej  
Siedlce, 23 sierpnia 2024*

# Co to jest sieć Bayesa?

Co to jest sieć ~~Bayesa?~~ bayesowska?

Co to jest sieć ~~Bayesa?~~ bayesowska?

60%



40%



Co to jest sieć ~~Bayesa?~~ bayesowska?



Co to jest sieć ~~Bayesa?~~ bayesowska?



Co to jest sieć ~~Bayesa?~~ bayesowska?



90%




70%

Co to jest sieć ~~Bayesa?~~ bayesowska?






# Co to jest sieć ~~Bayesa?~~ bayesowska?




## Co to jest sieć ~~Bayesa?~~ bayesowska?



*Sieć bayesowska* to graf skierowany ilustrujący bezpośrednie zależności między zmiennymi.


## Co to jest sieć ~~Bayesa?~~ bayesowska?



*Sieć bayesowska* to graf skierowany ilustrujący bezpośrednie zależności między zmiennymi. U nas:

- zeznania świadków mają bezpośredni wpływ na werdykt


## Co to jest sieć ~~Bayesa?~~ bayesowska?



*Sieć bayesowska* to graf skierowany ilustrujący bezpośrednie zależności między zmiennymi. U nas:

- zeznania świadków mają bezpośredni wpływ na werdykt
- to, jaka taksówka spowodowała wypadek, ma oczywiście wpływ na werdykt, jednak nie bezpośredni


## Co to jest sieć ~~Bayesa?~~ bayesowska?



*Sieć bayesowska* to graf skierowany ilustrujący bezpośrednie zależności między zmiennymi. U nas:

- zeznania świadków mają bezpośredni wpływ na werdykt
- to, jaka taksówka spowodowała wypadek, ma oczywiście wpływ na werdykt, jednak nie bezpośredni  
jeśli znane są zeznania, prawda jest nieistotna dla werdyktu

## Co to jest sieć ~~Bayesa?~~ bayesowska?



*Sieć bayesowska* to graf skierowany ilustrujący bezpośrednie zależności między zmiennymi. U nas:

- zeznania świadków mają bezpośredni wpływ na werdykt
- to, jaka taksówka spowodowała wypadek, ma oczywiście wpływ na werdykt, jednak nie bezpośredni  
jeśli znane są zeznania, prawda jest nieistotna dla werdyktu

**Formalna definicja już wkrótce!**

## Przykłady małych sieci bayesowskich

- **Dwie zmienne:**

## Przykłady małych sieci bayesowskich

- Dwie zmienne:

(a)  



## Przykłady małych sieci bayesowskich

- Dwie zmienne:



## Przykłady małych sieci bayesowskich

- Dwie zmienne:



Piszemy  $\mu \perp\!\!\!\perp \$$  (niezależne)

## Przykłady małych sieci bayesowskich

- Dwie zmienne:



Piszemy  $\mathcal{M} \perp\!\!\!\perp \$$  (niezależne) oraz  $\hat{\text{diplom}} \not\perp\!\!\!\perp \$$  (zależne)

## Przykłady małych sieci bayesowskich

- Dwie zmienne:



Piszemy  $\text{scorpion} \perp\!\!\!\perp \$$  (niezależne) oraz  $\text{graduation cap} \not\perp\!\!\!\perp \$$  (zależne)

- Trzy zmienne:


## Przykłady małych sieci bayesowskich

- Dwie zmienne:



Piszemy  $\mathcal{M} \perp\!\!\!\perp \$$  (niezależne) oraz  $\text{diplom} \not\perp\!\!\!\perp \$$  (zależne)

- Trzy zmienne:



## Przykłady małych sieci bayesowskich

- Dwie zmienne:



Piszemy  $\mathcal{M} \perp\!\!\!\perp \$$  (niezależne) oraz  $\text{diplom} \not\perp\!\!\!\perp \$$  (zależne)

- Trzy zmienne:



## Przykłady małych sieci bayesowskich

- Dwie zmienne:



Piszemy  $\mathcal{M} \perp\!\!\!\perp \$$  (niezależne) oraz  $\text{diplom} \not\perp \$$  (zależne)

- Trzy zmienne:



## Przykłady małych sieci bayesowskich

- Dwie zmienne:



Piszemy  $\mathcal{M} \perp\!\!\!\perp \$$  (niezależne) oraz  $\text{diplom} \not\perp\!\!\!\perp \$$  (zależne)

- Trzy zmienne:






## Przykłady małych sieci bayesowskich

- Dwie zmienne:



Piszemy  $\perp\!\!\!\perp$  \$ (niezależne) oraz  $\rightarrow$  \$ (zależne)

- Trzy zmienne:



## Przykłady małych sieci bayesowskich

- Dwie zmienne:



Piszemy  $\mathcal{M} \perp\!\!\!\perp \$$  (niezależne) oraz  $\text{diplom} \not\perp\!\!\!\perp \$$  (zależne)

- Trzy zmienne:



## Przykłady małych sieci bayesowskich

- Dwie zmienne:



Piszemy  $\mathcal{M} \perp\!\!\!\perp \$$  (niezależne) oraz  $\text{diplom} \not\perp\!\!\!\perp \$$  (zależne)

- Trzy zmienne:



Mamy   $\not\perp\!\!\!\perp$  , ale   $\perp\!\!\!\perp$   |  (warunkowa niezależność)

## Przykłady małych sieci bayesowskich

- Dwie zmienne:



Piszemy  $\mathcal{M} \perp\!\!\!\perp \$$  (niezależne) oraz  $\text{graduation cap} \not\perp\!\!\!\perp \$$  (zależne)

- Trzy zmienne:



Mamy   $\not\perp\!\!\!\perp$  , ale   $\perp\!\!\!\perp$   |  (warunkowa niezależność)



## Przykłady małych sieci bayesowskich

- Dwie zmienne:



Piszemy  $\mathcal{M} \perp\!\!\!\perp \$$  (niezależne) oraz  $\text{diplom} \not\perp\!\!\!\perp \$$  (zależne)

- Trzy zmienne:



Mamy   $\not\perp\!\!\!\perp$  , ale   $\perp\!\!\!\perp$   |  (warunkowa niezależność)



## Przykłady małych sieci bayesowskich

- Dwie zmienne:




Piszemy  $\mathcal{M} \perp\!\!\!\perp \$$  (niezależne) oraz  $\text{diplom} \not\perp\!\!\!\perp \$$  (zależne)

- Trzy zmienne:



Mamy  $\text{mama} \not\perp\!\!\!\perp \text{zęb}$ , ale  $\text{mama} \perp\!\!\!\perp \text{zęb} \mid \text{dziecko}$  (warunkowa niezależność)



## Przykłady małych sieci bayesowskich

- Dwie zmienne:




Piszemy  $\text{♏} \perp \text{\$}$  (niezależne) oraz  $\text{🎓} \not\perp \text{\$}$  (zależne)

- Trzy zmienne:




Mamy  $\text{🎺} \not\perp \text{🦷}$ , ale  $\text{🎺} \perp \text{🦷} \mid \text{👶}$  (warunkowa niezależność)



## Przykłady małych sieci bayesowskich

- Dwie zmienne:




Piszemy  $\mathcal{M} \perp\!\!\!\perp \$$  (niezależne) oraz  $\text{diplom} \not\perp \$$  (zależne)

- Trzy zmienne:



Mamy   $\not\perp$  , ale   $\perp\!\!\!\perp$   |  (warunkowa niezależność)




Tutaj   $\not\perp$  



## Przykłady małych sieci bayesowskich

- Dwie zmienne:




Piszemy  $\mathcal{M} \perp\!\!\!\perp \$$  (niezależne) oraz  $\text{diplom} \not\perp\!\!\!\perp \$$  (zależne)

- Trzy zmienne:



Mamy  $\text{mama} \not\perp\!\!\!\perp \text{zęb}$ , ale  $\text{mama} \perp\!\!\!\perp \text{zęb} \mid \text{dziecko}$  (warunkowa niezależność)



Tutaj  $\text{lody} \not\perp\!\!\!\perp \text{row}$ , ale  $\text{lody} \perp\!\!\!\perp \text{row} \mid \text{słońce}$

## Przykłady małych sieci bayesowskich

- Dwie zmienne:




Piszemy  $\perp\!\!\!\perp$  \$ (niezależne) oraz  $\text{graduation cap} \not\perp\!\!\!\perp$  \$ (zależne)

- Trzy zmienne:



Mamy   $\not\perp\!\!\!\perp$  , ale   $\perp\!\!\!\perp$   |  (warunkowa niezależność)



Tutaj   $\not\perp\!\!\!\perp$  , ale   $\perp\!\!\!\perp$   | 



## Przykłady małych sieci bayesowskich

- Dwie zmienne:




Piszemy  $\perp\!\!\!\perp$  \$ (niezależne) oraz  $\text{graduation cap} \not\perp\!\!\!\perp$  \$ (zależne)

- Trzy zmienne:



Mamy   $\not\perp\!\!\!\perp$  , ale   $\perp\!\!\!\perp$   |  (warunkowa niezależność)



Tutaj   $\not\perp\!\!\!\perp$  , ale   $\perp\!\!\!\perp$   | 



## Przykłady małych sieci bayesowskich

- Dwie zmienne:




Piszemy  $\infty \perp\!\!\!\perp \$$  (niezależne) oraz  $\text{graduation cap} \not\perp\!\!\!\perp \$$  (zależne)

- Trzy zmienne:



Mamy   $\not\perp\!\!\!\perp$  , ale   $\perp\!\!\!\perp$   |  (warunkowa niezależność)



Tutaj   $\not\perp\!\!\!\perp$  , ale   $\perp\!\!\!\perp$   | 



## Przykłady małych sieci bayesowskich

- Dwie zmienne:









Piszemy  $\mathcal{M} \perp\!\!\!\perp \$$  (niezależne) oraz  $\text{diplom} \not\perp\!\!\!\perp \$$  (zależne)


- Trzy zmienne:



Mamy   $\not\perp\!\!\!\perp$  , ale   $\perp\!\!\!\perp$   |  (warunkowa niezależność)



Tutaj   $\not\perp\!\!\!\perp$  , ale   $\perp\!\!\!\perp$   | 



## Przykłady małych sieci bayesowskich

- Dwie zmienne:




Piszemy  $\mathfrak{M} \perp\!\!\!\perp \$$  (niezależne) oraz  $\text{diplom} \not\perp\!\!\!\perp \$$  (zależne)


- Trzy zmienne:



Mamy  $\text{trąbacz} \not\perp\!\!\!\perp \text{ząbek}$ , ale  $\text{trąbacz} \perp\!\!\!\perp \text{ząbek} \mid \text{dziecko}$  (warunkowa niezależność)



Tutaj  $\text{lody} \not\perp\!\!\!\perp \text{rower}$ , ale  $\text{lody} \perp\!\!\!\perp \text{rower} \mid \text{słońce}$



Tutaj  $\text{♂} \perp\!\!\!\perp \text{🇯🇵}$

# Przykłady małych sieci bayesowskich

- Dwie zmienne:




Piszemy  $\mathcal{M} \perp\!\!\!\perp \$$  (niezależne) oraz  $\text{diplom} \not\perp\!\!\!\perp \$$  (zależne)


- Trzy zmienne:



Mamy   $\not\perp\!\!\!\perp$  , ale   $\perp\!\!\!\perp$   |  (warunkowa niezależność)



Tutaj   $\not\perp\!\!\!\perp$  , ale   $\perp\!\!\!\perp$   | 



Tutaj  $\text{♂} \perp\!\!\!\perp$  , ale  $\text{♂} \perp\!\!\!\perp$   | 

## Przykłady małych sieci bayesowskich

- Dwie zmienne:








Piszemy  $\mathcal{M} \perp\!\!\!\perp \$$  (niezależne) oraz  $\text{diplom} \not\perp\!\!\!\perp \$$  (zależne)


- Trzy zmienne:



Mamy   $\not\perp\!\!\!\perp$  , ale   $\perp\!\!\!\perp$   |  (warunkowa niezależność)




Tutaj   $\not\perp\!\!\!\perp$  , ale   $\perp\!\!\!\perp$   | 




Tutaj  $\text{♂} \perp\!\!\!\perp$  , ale  $\text{♂} \perp\!\!\!\perp$   | 





## Pytanie


*Jak wygląda przepływ informacji w sieci bayesowskiej?*



## Pytanie

*Jak wygląda przepływ informacji w sieci bayesowskiej?*

(tzn. jakie warunkowe niezależności są przez nią implikowane?)





## Pytanie

*Jak wygląda przepływ informacji w sieci bayesowskiej?*

(tzn. jakie warunkowe niezależności są przez nią implikowane?)

**Przykład:**







## Pytanie

*Jak wygląda przepływ informacji w sieci bayesowskiej?*

(tzn. jakie warunkowe niezależności są przez nią implikowane?)

**Przykład:**






# Pytanie

*Jak wygląda przepływ informacji w sieci bayesowskiej?*

(tzn. jakie warunkowe niezależności są przez nią implikowane?)

**Przykład:**



Czy  $\text{Blue} \perp\!\!\!\perp \text{Red} \mid \text{Grey}$ ?

## Przepływ informacji w sieci bayesowskiej


- Informacja może płynąć po krawędziach sieci w obu kierunkach

## Przepływ informacji w sieci bayesowskiej

- Informacja może płynąć po krawędziach sieci w obu kierunkach

### Legenda:

●: warunkowe   ○: niewarunkowe   ◐: brak informacji




## Przepływ informacji w sieci bayesowskiej

- Informacja może płynąć po krawędziach sieci w obu kierunkach

### Legenda:

●: warunkowe   ○: niewarunkowe   ●: brak informacji






## Przepływ informacji w sieci bayesowskiej

- Informacja może płynąć po krawędziach sieci w obu kierunkach

### Legenda:

●: warunkowe   ○: niewarunkowe   ●: brak informacji




## Przepływ informacji w sieci bayesowskiej

- Informacja może płynąć po krawędziach sieci w obu kierunkach

### Legenda:

●: warunkowe   ○: niewarunkowe   ●: brak informacji




## Przepływ informacji w sieci bayesowskiej

- Informacja może płynąć po krawędziach sieci w obu kierunkach

### Legenda:

●: warunkowe   ○: niewarunkowe   ●: brak informacji




## Przepływ informacji w sieci bayesowskiej

- Informacja może płynąć po krawędziach sieci w obu kierunkach

### Legenda:

●: warunkowe   ○: niewarunkowe   ●: brak informacji




## Przepływ informacji w sieci bayesowskiej

- Informacja może płynąć po krawędziach sieci w obu kierunkach

### Legenda:

●: warunkowe   ○: niewarunkowe   ●: brak informacji

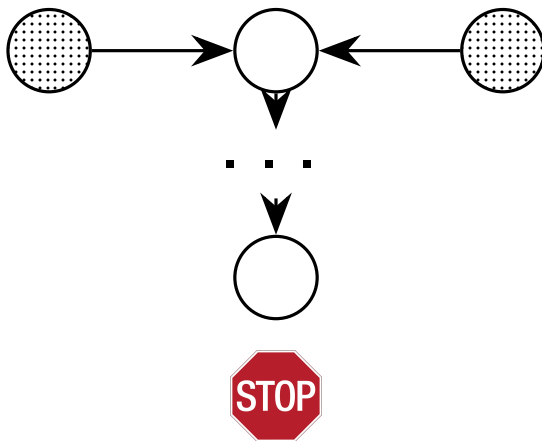


## Przepływ informacji w sieci bayesowskiej

- Informacja może płynąć po krawędziach sieci w obu kierunkach

### Legenda:

●: warunkowe    ○: niewarunkowe    ⊘: brak informacji



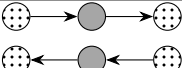
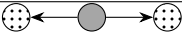
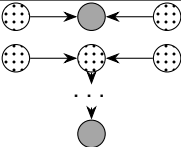


## Przepływ informacji w sieci bayesowskiej

- Informacja może płynąć po krawędziach sieci w obu kierunkach

### Legenda:


●: warunkowe    ⊙: brak informacji

		
<i>łańcuch</i>		w p. przyp.
<i>widelec</i>		
<i>zderzacz</i>	w p. przyp.	

## Przykład

### Legenda:

●: zmienne „zwarunkowane”    ○: pozostałe






# Przykład

## Legenda:


●: zmienne „zwarunkowane”    ○: pozostałe



# Przykład

## Legenda:


●: zmienne „zwarunkowane”    ○: pozostałe



# Przykład

## Legenda:


●: zmienne „zwarunkowane”    ○: pozostałe



## Przykład

### Legenda:

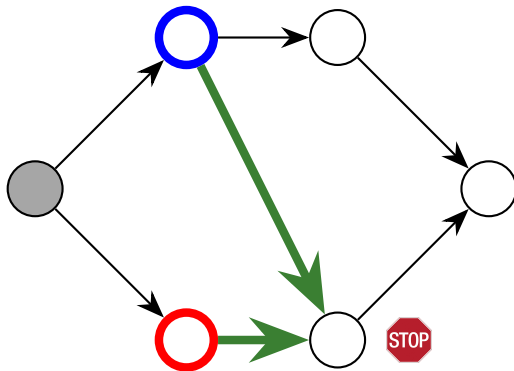
●: zmienne „zwarunkowane”    ○: pozostałe



## Przykład

### Legenda:

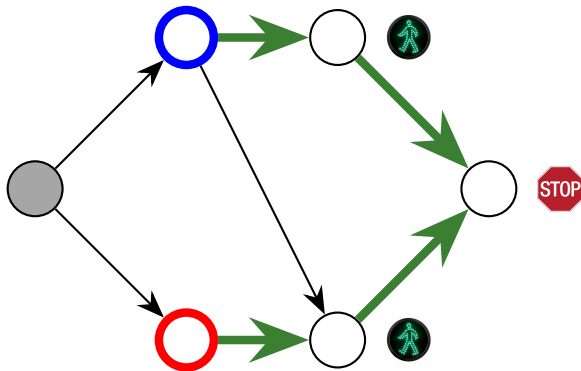
●: zmienne „zwarunkowane”    ○: pozostałe



# Przykład

## Legenda:


●: zmienne „zwarunkowane”    ○: pozostałe




## Przykład

### Legenda:

●: zmienne „zwarunkowane”    ○: pozostałe





**Bayesball :)**



## Kilka komentarzy

- termin *sieci bayesowskie* został ukuty przez Judeę Pearla (laureat Nagrody Turinga 2011) w latach 80-tych

## Kilka komentarzy

- termin *sieci bayesowskie* został ukuty przez Judeę Pearlą (laureat Nagrody Turinga 2011) w latach 80-tych
- brak opisanego wcześniej przepływu informacji nosi nazwę *d-separacji* (ozn.  $A \not\rightarrow B \mid S$ )

## Kilka komentarzy

- termin *sieci bayesowskie* został ukuty przez Judeę Pearlą (laureat Nagrody Turinga 2011) w latach 80-tych
- brak opisanego wcześniej przepływu informacji nosi nazwę *d-separacji* (ozn.  $A \not\rightarrow B \mid S$ )
- **Twierdzenie Pearlą:** *d-separacja implikuje warunkową niezależność*

## Kilka komentarzy

- termin *sieci bayesowskie* został ukuty przez Judeę Pearlą (laureat Nagrody Turinga 2011) w latach 80-tych
- brak opisanego wcześniej przepływu informacji nosi nazwę *d-separacji* (ozn.  $A \not\rightarrow B \mid S$ )
- **Twierdzenie Pearlą:** *d-separacja implikuje warunkową niezależność*
- dalsza część wykładu poświęcona będzie formalizacji twierdzenia Pearlą oraz jego dowodowi

## Kilka komentarzy

- termin *sieci bayesowskie* został ukuty przez Judeę Pearlą (laureat Nagrody Turinga 2011) w latach 80-tych
- brak opisanego wcześniej przepływu informacji nosi nazwę *d-separacji* (ozn.  $A \not\leftrightarrow B \mid S$ )
- **Twierdzenie Pearlą:** *d-separacja implikuje warunkową niezależność*
- dalsza część wykładu poświęcona będzie formalizacji twierdzenia Pearlą oraz jego dowodowi
- schemat dowodu

$d$ -separacja  
w grafie skierowanym  $\longrightarrow$  warunkowa niezależność


## Kilka komentarzy

- termin *sieci bayesowskie* został ukuty przez Judeę Pearlą (laureat Nagrody Turinga 2011) w latach 80-tych
- brak opisanego wcześniej przepływu informacji nosi nazwę *d-separacji* (ozn.  $A \not\leftrightarrow B \mid S$ )
- **Twierdzenie Pearlą:** *d-separacja implikuje warunkową niezależność*
- dalsza część wykładu poświęcona będzie formalizacji twierdzenia Pearlą oraz jego dowodowi
- schemat dowodu




## Kilka komentarzy

- termin *sieci bayesowskie* został ukuty przez Judeę Pearlą (laureat Nagrody Turinga 2011) w latach 80-tych
- brak opisanego wcześniej przepływu informacji nosi nazwę *d-separacji* (ozn.  $A \not\rightarrow B \mid S$ )
- **Twierdzenie Pearlą:** *d-separacja implikuje warunkową niezależność*
- dalsza część wykładu poświęcona będzie formalizacji twierdzenia Pearlą oraz jego dowodowi
- schemat dowodu



## Kilka komentarzy


- termin *sieci bayesowskie* został ukuty przez Judeę Pearlą (laureat Nagrody Turinga 2011) w latach 80-tych
- brak opisanego wcześniej przepływu informacji nosi nazwę *d-separacji* (ozn.  $A \not\rightarrow B \mid S$ )
- **Twierdzenie Pearlą:** *d-separacja implikuje warunkową niezależność*
- dalsza część wykładu poświęcona będzie formalizacji twierdzenia Pearlą oraz jego dowodowi
- schemat dowodu





## Kilka komentarzy

- termin *sieci bayesowskie* został ukuty przez Judeę Pearlą (laureat Nagrody Turinga 2011) w latach 80-tych
- brak opisanego wcześniej przepływu informacji nosi nazwę *d-separacji* (ozn.  $A \not\rightarrow B \mid S$ )
- **Twierdzenie Pearlą:** *d-separacja implikuje warunkową niezależność*
- dalsza część wykładu poświęcona będzie formalizacji twierdzenia Pearlą oraz jego dowodowi
- schemat dowodu



## (Nie)zależności zmiennych + notacja

- $X, Y, Z, \dots$  – zmienne losowe (dyskretne)

## (Nie)zależności zmiennych + notacja

- $X, Y, Z, \dots$  – zmienne losowe (dyskretne)
- $p_X(x)$  – *funkcja prawdopodobieństwa* zmiennej  $X$

## (Nie)zależności zmiennych + notacja

- $X, Y, Z, \dots$  – zmienne losowe (dyskretne)
- $p_X(x)$  – *funkcja prawdopodobieństwa* zmiennej  $X$ ,  $p_X(x) = \mathbb{P}(X = x)$

## (Nie)zależności zmiennych + notacja

- $X, Y, Z, \dots$  – zmienne losowe (dyskretne)
- $p_X(x)$  – **funkcja prawdopodobieństwa** zmiennej  $X$ ,  $p_X(x) = \mathbb{P}(X = x)$
- *Przykład.*  $X$  – wynik rzutu kością sześcienną  
 $p_X(1) = p_X(2) = \dots = p_X(6) = \frac{1}{6}$

## (Nie)zależności zmiennych + notacja

- $X, Y, Z, \dots$  – zmienne losowe (dyskretne)
- $p_X(x)$  – **funkcja prawdopodobieństwa** zmiennej  $X$ ,  $p_X(x) = \mathbb{P}(X = x)$
- *Przykład.*  $X$  – wynik rzutu kością sześcienną  
 $p_X(1) = p_X(2) = \dots = p_X(6) = \frac{1}{6}$
- $p_{X,Y}(x, y)$  – **łączna** funkcja prawdopodobieństwa dla zmiennych  $X, Y$

$$p_{X,Y}(x, y) = \mathbb{P}(X = x, Y = y)$$

## (Nie)zależności zmiennych + notacja

- $X, Y, Z, \dots$  – zmienne losowe (dyskretne)
- $p_X(x)$  – **funkcja prawdopodobieństwa** zmiennej  $X$ ,  $p_X(x) = \mathbb{P}(X = x)$
- *Przykład.*  $X$  – wynik rzutu kością sześcienną  
 $p_X(1) = p_X(2) = \dots = p_X(6) = \frac{1}{6}$
- $p_{X,Y}(x, y)$  – *łączna* funkcja prawdopodobieństwa dla zmiennych  $X, Y$

$$p_{X,Y}(x, y) = \mathbb{P}(X = x, Y = y)$$

- $\circ p_X(x) = \sum_y p_{X,Y}(x, y)$

## (Nie)zależności zmiennych + notacja

- $X, Y, Z, \dots$  – zmienne losowe (dyskretne)
- $p_X(x)$  – **funkcja prawdopodobieństwa** zmiennej  $X$ ,  $p_X(x) = \mathbb{P}(X = x)$
- *Przykład.*  $X$  – wynik rzutu kością sześcienną  
 $p_X(1) = p_X(2) = \dots = p_X(6) = \frac{1}{6}$
- $p_{X,Y}(x, y)$  – *łączna* funkcja prawdopodobieństwa dla zmiennych  $X, Y$

$$p_{X,Y}(x, y) = \mathbb{P}(X = x, Y = y)$$

- $\circ p_X(x) = \sum_y p_{X,Y}(x, y), p_Y(y) = \sum_x p_{X,Y}(x, y)$



## (Nie)zależności zmiennych + notacja

- $X, Y, Z, \dots$  – zmienne losowe (dyskretne)
- $p_X(x)$  – **funkcja prawdopodobieństwa** zmiennej  $X$ ,  $p_X(x) = \mathbb{P}(X = x)$
- *Przykład.*  $X$  – wynik rzutu kością sześcienną  
 $p_X(1) = p_X(2) = \dots = p_X(6) = \frac{1}{6}$
- $p_{X,Y}(x, y)$  – **łączna** funkcja prawdopodobieństwa dla zmiennych  $X, Y$

$$p_{X,Y}(x, y) = \mathbb{P}(X = x, Y = y)$$

- - $p_X(x) = \sum_y p_{X,Y}(x, y)$ ,  $p_Y(y) = \sum_x p_{X,Y}(x, y)$
  - $p_{X|Y}(x|y) := \frac{p_{X,Y}(x,y)}{p_Y(y)}$

## (Nie)zależności zmiennych + notacja

- $X, Y, Z, \dots$  – zmienne losowe (dyskretne)
- $p_X(x)$  – **funkcja prawdopodobieństwa** zmiennej  $X$ ,  $p_X(x) = \mathbb{P}(X = x)$
- *Przykład.*  $X$  – wynik rzutu kością sześcienną  
 $p_X(1) = p_X(2) = \dots = p_X(6) = \frac{1}{6}$
- $p_{X,Y}(x, y)$  – **łączna** funkcja prawdopodobieństwa dla zmiennych  $X, Y$

$$p_{X,Y}(x, y) = \mathbb{P}(X = x, Y = y)$$

- - $p_X(x) = \sum_y p_{X,Y}(x, y)$ ,  $p_Y(y) = \sum_x p_{X,Y}(x, y)$
  - $p_{X|Y}(x|y) := \frac{p_{X,Y}(x,y)}{p_Y(y)}$  (szansa na  $X = x$  pod warunkiem  $Y = y$ )

## (Nie)zależności zmiennych + notacja

- $X, Y, Z, \dots$  – zmienne losowe (dyskretne)
- $p_X(x)$  – **funkcja prawdopodobieństwa** zmiennej  $X$ ,  $p_X(x) = \mathbb{P}(X = x)$
- *Przykład.*  $X$  – wynik rzutu kością sześcienną  
 $p_X(1) = p_X(2) = \dots = p_X(6) = \frac{1}{6}$
- $p_{X,Y}(x, y)$  – **łączna funkcja prawdopodobieństwa** dla zmiennych  $X, Y$

$$p_{X,Y}(x, y) = \mathbb{P}(X = x, Y = y)$$

- $\circ p_X(x) = \sum_y p_{X,Y}(x, y)$ ,  $p_Y(y) = \sum_x p_{X,Y}(x, y)$
- $\circ p_{X|Y}(x|y) := \frac{p_{X,Y}(x,y)}{p_Y(y)}$  (szansa na  $X = x$  pod warunkiem  $Y = y$ )
- **niezależność**  $X$  i  $Y$  to stwierdzenie  $p_{X|Y}(x|y) = p_X(x)$

## (Nie)zależności zmiennych + notacja

- $X, Y, Z, \dots$  – zmienne losowe (dyskretne)
- $p_X(x)$  – **funkcja prawdopodobieństwa** zmiennej  $X$ ,  $p_X(x) = \mathbb{P}(X = x)$
- *Przykład.*  $X$  – wynik rzutu kością sześcienną  
 $p_X(1) = p_X(2) = \dots = p_X(6) = \frac{1}{6}$
- $p_{X,Y}(x, y)$  – **łączna funkcja prawdopodobieństwa** dla zmiennych  $X, Y$

$$p_{X,Y}(x, y) = \mathbb{P}(X = x, Y = y)$$

- - $p_X(x) = \sum_y p_{X,Y}(x, y)$ ,  $p_Y(y) = \sum_x p_{X,Y}(x, y)$
  - $p_{X|Y}(x|y) := \frac{p_{X,Y}(x,y)}{p_Y(y)}$  (szansa na  $X = x$  pod warunkiem  $Y = y$ )
- **niezależność**  $X$  i  $Y$  to stwierdzenie  $p_{X|Y}(x|y) = p_X(x)$ , czyli

$$p_{X,Y}(x, y) = p_X(x) \cdot p_Y(y)$$

## (Nie)zależności zmiennych + notacja

- $X, Y, Z, \dots$  – zmienne losowe (dyskretne)
- $p_X(x)$  – **funkcja prawdopodobieństwa** zmiennej  $X$ ,  $p_X(x) = \mathbb{P}(X = x)$
- *Przykład.*  $X$  – wynik rzutu kością sześcienną  
 $p_X(1) = p_X(2) = \dots = p_X(6) = \frac{1}{6}$
- $p_{X,Y}(x, y)$  – **łączna** funkcja prawdopodobieństwa dla zmiennych  $X, Y$

$$p_{X,Y}(x, y) = \mathbb{P}(X = x, Y = y)$$

- $\circ p_X(x) = \sum_y p_{X,Y}(x, y)$ ,  $p_Y(y) = \sum_x p_{X,Y}(x, y)$
- $\circ p_{X|Y}(x|y) := \frac{p_{X,Y}(x,y)}{p_Y(y)}$  (szansa na  $X = x$  pod warunkiem  $Y = y$ )
- **niezależność**  $X$  i  $Y$  to stwierdzenie  $p_{X|Y}(x|y) = p_X(x)$ , czyli

$$p_{X,Y}(x, y) = p_X(x) \cdot p_Y(y)$$

Równoważnie

$$p_{X,Y}(x, y) = \phi(x) \cdot \psi(y)$$

dla pewnych funkcji  $\phi, \psi$ .

## (Nie)zależności zmiennych + notacja

- $X, Y, Z, \dots$  – zmienne losowe (dyskretne)
- $p_X(x)$  – **funkcja prawdopodobieństwa** zmiennej  $X$ ,  $p_X(x) = \mathbb{P}(X = x)$
- *Przykład.*  $X$  – wynik rzutu kością sześcienną  
 $p_X(1) = p_X(2) = \dots = p_X(6) = \frac{1}{6}$
- $p_{X,Y}(x, y)$  – **łączna funkcja prawdopodobieństwa** dla zmiennych  $X, Y$

$$p_{X,Y}(x, y) = \mathbb{P}(X = x, Y = y)$$

- $\circ p_X(x) = \sum_y p_{X,Y}(x, y)$ ,  $p_Y(y) = \sum_x p_{X,Y}(x, y)$
- $\circ p_{X|Y}(x|y) := \frac{p_{X,Y}(x,y)}{p_Y(y)}$  (szansa na  $X = x$  pod warunkiem  $Y = y$ )
- **niezależność**  $X$  i  $Y$  to stwierdzenie  $p_{X|Y}(x|y) = p_X(x)$ , czyli

$$p_{X,Y}(x, y) = p_X(x) \cdot p_Y(y)$$

Równoważnie

$$p_{X,Y}(x, y) = \phi(x) \cdot \psi(y)$$

dla pewnych funkcji  $\phi, \psi$ . Piszemy  $X \perp\!\!\!\perp Y$ .

## (Nie)zależności zmiennych + notacja

- **niezależność**  $X$  i  $Y$  to stwierdzenie  $p_{X|Y}(x|y) = p_X(x)$ , czyli

$$p_{X,Y}(x,y) = p_X(x) \cdot p_Y(y)$$

Równoważnie

$$p_{X,Y}(x,y) = \phi(x) \cdot \psi(y)$$

dla pewnych funkcji  $\phi$ ,  $\psi$ . Piszemy  $X \perp\!\!\!\perp Y$ .

## (Nie)zależności zmiennych + notacja

- **niezależność**  $X$  i  $Y$  to stwierdzenie  $p_{X|Y}(x|y) = p_X(x)$ , czyli

$$p_{X,Y}(x,y) = p_X(x) \cdot p_Y(y)$$

Równoważnie

$$p_{X,Y}(x,y) = \phi(x) \cdot \psi(y)$$

dla pewnych funkcji  $\phi$ ,  $\psi$ . Piszemy  $X \perp\!\!\!\perp Y$ .

- **niezależność  $X$  i  $Y$  pod warunkiem  $Z$**  to stwierdzenie  $p_{X|Y,Z}(x|y,z) = p_{X|Z}(x|z)$



## (Nie)zależności zmiennych + notacja

- **niezależność**  $X$  i  $Y$  to stwierdzenie  $p_{X|Y}(x|y) = p_X(x)$ , czyli

$$p_{X,Y}(x,y) = p_X(x) \cdot p_Y(y)$$

Równoważnie

$$p_{X,Y}(x,y) = \phi(x) \cdot \psi(y)$$

dla pewnych funkcji  $\phi$ ,  $\psi$ . Piszemy  $X \perp\!\!\!\perp Y$ .

- **niezależność  $X$  i  $Y$  pod warunkiem  $Z$**  to stwierdzenie  $p_{X|Y,Z}(x|y,z) = p_{X|Z}(x|z)$ , czyli

$$p_{X,Y,Z}(x,y,z) = p_{X,Z}(x,z) \cdot p_{Y,Z}(y,z) / p_Z(z)$$

## (Nie)zależności zmiennych + notacja

- **niezależność**  $X$  i  $Y$  to stwierdzenie  $p_{X|Y}(x|y) = p_X(x)$ , czyli

$$p_{X,Y}(x,y) = p_X(x) \cdot p_Y(y)$$

Równoważnie

$$p_{X,Y}(x,y) = \phi(x) \cdot \psi(y)$$

dla pewnych funkcji  $\phi, \psi$ . Piszemy  $X \perp\!\!\!\perp Y$ .

- **niezależność  $X$  i  $Y$  pod warunkiem  $Z$**  to stwierdzenie  $p_{X|Y,Z}(x|y,z) = p_{X|Z}(x|z)$ , czyli

$$p_{X,Y,Z}(x,y,z) = p_{X,Z}(x,z) \cdot p_{Y,Z}(y,z)/p_Z(z)$$

Równoważnie

$$p_{X,Y,Z}(x,y,z) = \Phi(x,z) \cdot \Psi(y,z)$$

dla pewnych funkcji  $\Phi, \Psi$ .

## (Nie)zależności zmiennych + notacja

- **niezależność**  $X$  i  $Y$  to stwierdzenie  $p_{X|Y}(x|y) = p_X(x)$ , czyli

$$p_{X,Y}(x,y) = p_X(x) \cdot p_Y(y)$$

Równoważnie

$$p_{X,Y}(x,y) = \phi(x) \cdot \psi(y)$$

dla pewnych funkcji  $\phi, \psi$ . Piszemy  $X \perp\!\!\!\perp Y$ .

- **niezależność  $X$  i  $Y$  pod warunkiem  $Z$**  to stwierdzenie  $p_{X|Y,Z}(x|y,z) = p_{X|Z}(x|z)$ , czyli

$$p_{X,Y,Z}(x,y,z) = p_{X,Z}(x,z) \cdot p_{Y,Z}(y,z) / p_Z(z)$$

Równoważnie

$$p_{X,Y,Z}(x,y,z) = \Phi(x,z) \cdot \Psi(y,z)$$

dla pewnych funkcji  $\Phi, \Psi$ . Piszemy  $X \perp\!\!\!\perp Y | Z$ .

## (Nie)zależności zmiennych + notacja

- **niezależność**  $X$  i  $Y$  to stwierdzenie  $p_{X|Y}(x|y) = p_X(x)$ , czyli

$$p_{X,Y}(x,y) = p_X(x) \cdot p_Y(y)$$

Równoważnie

$$p_{X,Y}(x,y) = \phi(x) \cdot \psi(y)$$

dla pewnych funkcji  $\phi, \psi$ . Piszemy  $X \perp\!\!\!\perp Y$ .

- **niezależność  $X$  i  $Y$  pod warunkiem  $Z$**  to stwierdzenie  $p_{X|Y,Z}(x|y,z) = p_{X|Z}(x|z)$ , czyli

$$p_{X,Y,Z}(x,y,z) = p_{X,Z}(x,z) \cdot p_{Y,Z}(y,z) / p_Z(z)$$

Równoważnie

$$p_{X,Y,Z}(x,y,z) = \Phi(x,z) \cdot \Psi(y,z)$$

dla pewnych funkcji  $\Phi, \Psi$ . Piszemy  $X \perp\!\!\!\perp Y | Z$ .

- pomijamy dolny indeks funkcji  $p$

## (Nie)zależności zmiennych + notacja

- **niezależność**  $\mathbf{X}$  i  $\mathbf{Y}$  to stwierdzenie  $p_{\mathbf{X}|\mathbf{Y}}(\mathbf{x}|\mathbf{y}) = p_{\mathbf{X}}(\mathbf{x})$ , czyli

$$p_{\mathbf{X},\mathbf{Y}}(\mathbf{x},\mathbf{y}) = p_{\mathbf{X}}(\mathbf{x}) \cdot p_{\mathbf{Y}}(\mathbf{y})$$

Równoważnie

$$p_{\mathbf{X},\mathbf{Y}}(\mathbf{x},\mathbf{y}) = \phi(\mathbf{x}) \cdot \psi(\mathbf{y})$$

dla pewnych funkcji  $\phi, \psi$ . Piszemy  $\mathbf{X} \perp\!\!\!\perp \mathbf{Y}$ .

- **niezależność  $\mathbf{X}$  i  $\mathbf{Y}$  pod warunkiem  $\mathbf{Z}$**  to stwierdzenie  $p_{\mathbf{X}|\mathbf{Y},\mathbf{Z}}(\mathbf{x}|\mathbf{y},\mathbf{z}) = p_{\mathbf{X}|\mathbf{Z}}(\mathbf{x}|\mathbf{z})$ , czyli

$$p_{\mathbf{X},\mathbf{Y},\mathbf{Z}}(\mathbf{x},\mathbf{y},\mathbf{z}) = p_{\mathbf{X},\mathbf{Z}}(\mathbf{x},\mathbf{z}) \cdot p_{\mathbf{Y},\mathbf{Z}}(\mathbf{y},\mathbf{z})/p_{\mathbf{Z}}(\mathbf{z})$$

Równoważnie

$$p_{\mathbf{X},\mathbf{Y},\mathbf{Z}}(\mathbf{x},\mathbf{y},\mathbf{z}) = \Phi(\mathbf{x},\mathbf{z}) \cdot \Psi(\mathbf{y},\mathbf{z})$$

dla pewnych funkcji  $\Phi, \Psi$ . Piszemy  $\mathbf{X} \perp\!\!\!\perp \mathbf{Y} | \mathbf{Z}$ .

- pomijamy dolny indeks funkcji  $p$
- to samo zachodzi dla wektorów losowych  $\mathbf{X}, \mathbf{Y}$  i  $\mathbf{Z}$

## Notacji ciąg dalszy

- Niech  $\mathbf{x} = (x_1, \dots, x_n)$ , wtedy  $\mathbf{x}_A = (x_i : i \in A)$ , np.

$$\mathbf{x}_{\{2,5,7\}} := (x_2, x_5, x_7)$$

## Notacji ciąg dalszy

- Niech  $\mathbf{x} = (x_1, \dots, x_n)$ , wtedy  $\mathbf{x}_A = (x_i : i \in A)$ , np.

$$\mathbf{x}_{\{2,5,7\}} := (x_2, x_5, x_7)$$

Ta sama konwencja dotyczy ciągu zmiennych losowych.


## Notacji ciąg dalszy

- Niech  $\mathbf{x} = (x_1, \dots, x_n)$ , wtedy  $\mathbf{x}_A = (x_i : i \in A)$ , np.

$$\mathbf{x}_{\{2,5,7\}} := (x_2, x_5, x_7)$$

Ta sama konwencja dotyczy ciągu zmiennych losowych.

- Definicje grafowe:






## Notacji ciąg dalszy

- Niech  $\mathbf{x} = (x_1, \dots, x_n)$ , wtedy  $\mathbf{x}_A = (x_i : i \in A)$ , np.

$$\mathbf{x}_{\{2,5,7\}} := (x_2, x_5, x_7)$$

Ta sama konwencja dotyczy ciągu zmiennych losowych.

- Definicje grafowe:



- rodzice  
 $pa(4) = \{1, 5\}$


## Notacji ciąg dalszy

- Niech  $\mathbf{x} = (x_1, \dots, x_n)$ , wtedy  $\mathbf{x}_A = (x_i : i \in A)$ , np.

$$\mathbf{x}_{\{2,5,7\}} := (x_2, x_5, x_7)$$

Ta sama konwencja dotyczy ciągu zmiennych losowych.

- Definicje grafowe:



- rodzice  
 $pa(4) = \{1, 5\}$
- przodkowie  
 $an(4) = \{1, 2, 3, 5, 6\}$


## Notacji ciąg dalszy

- Niech  $\mathbf{x} = (x_1, \dots, x_n)$ , wtedy  $\mathbf{x}_A = (x_i : i \in A)$ , np.

$$\mathbf{x}_{\{2,5,7\}} := (x_2, x_5, x_7)$$

Ta sama konwencja dotyczy ciągu zmiennych losowych.

- Definicje grafowe:



- rodzice  
 $pa(4) = \{1, 5\}$
- przodkowie  
 $an(4) = \{1, 2, 3, 5, 6\}$
- dzieci  
 $ch(4) = \{7, 8\}$


## Notacji ciąg dalszy

- Niech  $\mathbf{x} = (x_1, \dots, x_n)$ , wtedy  $\mathbf{x}_A = (x_i : i \in A)$ , np.

$$\mathbf{x}_{\{2,5,7\}} := (x_2, x_5, x_7)$$


Ta sama konwencja dotyczy ciągu zmiennych losowych.

- Definicje grafowe:




- rodzice  
 $pa(4) = \{1, 5\}$
- przodkowie  
 $an(4) = \{1, 2, 3, 5, 6\}$
- dzieci  
 $ch(4) = \{7, 8\}$
- potomkowie  
 $de(4) = \{7, 8, 9\}$

## Co to jest sieć bayesowska?



- jeśli znane są zeznania, prawda jest nieistotna dla werdyktu

## Co to jest sieć bayesowska?




- jeśli znane są zeznania, prawda jest nieistotna dla werdyktu

**Definicja.** Rozważmy zmienne  $X_1, \dots, X_n$  o funkcji prawdopodobieństwa  $p$ . Powiemy, że acykliczny graf skierowany  $\mathcal{G}$  o wierzchołkach w  $1, \dots, n$  jest *siecią bayesowską* dla  $p$ , jeśli  $pa(i) \subseteq \{1, \dots, i-1\}$  oraz

$$X_i \perp\!\!\!\perp \mathbf{X}_{\{1, \dots, i-1\} \setminus pa(i)} \mid \mathbf{X}_{pa(i)},$$

## Co to jest sieć bayesowska?




- jeśli znane są **zeznania**, prawda jest nieistotna dla werdyktu

**Definicja.** Rozważmy zmienne  $X_1, \dots, X_n$  o funkcji prawdopodobieństwa  $p$ . Powiemy, że acykliczny graf skierowany  $\mathcal{G}$  o wierzchołkach w  $1, \dots, n$  jest *siecią bayesowską* dla  $p$ , jeśli  $pa(i) \subseteq \{1, \dots, i-1\}$  oraz

$$X_i \perp\!\!\!\perp \mathbf{X}_{\{1, \dots, i-1\} \setminus pa(i)} \mid \mathbf{X}_{pa(i)},$$

## Co to jest sieć bayesowska?



- jeśli znane są **zeznania**, prawda jest nieistotna dla werdyktu

**Definicja.** Rozważmy zmienne  $X_1, \dots, X_n$  o funkcji prawdopodobieństwa  $p$ . Powiemy, że acykliczny graf skierowany  $\mathcal{G}$  o wierzchołkach w  $1, \dots, n$  jest *siecią bayesowską* dla  $p$ , jeśli  $pa(i) \subseteq \{1, \dots, i-1\}$  oraz

$$X_i \perp\!\!\!\perp \mathbf{X}_{\{1, \dots, i-1\} \setminus pa(i)} \mid \mathbf{X}_{pa(i)},$$

a także  $X_i \not\perp\!\!\!\perp \mathbf{X}_{\{1, \dots, i-1\} \setminus A} \mid X_A$  dla dowolnego  $A \subsetneq pa(i)$



## Faktoryzacja funkcji prawdopodobieństwa

$X_1, X_2, X_3, X_4, X_5, X_6$  – zmienne losowe


## Faktoryzacja funkcji prawdopodobieństwa

$X_1, X_2, X_3, X_4, X_5, X_6$  – zmienne losowe

$$\begin{aligned} p(x_1, x_2, x_3, x_4, x_5, x_6) &= p(x_1) \cdot \\ & p(x_2 \mid x_1) \cdot \\ & p(x_3 \mid x_1, x_2) \cdot \\ & p(x_4 \mid x_1, x_2, x_3) \cdot \\ & p(x_5 \mid x_1, x_2, x_3, x_4) \cdot \\ & p(x_6 \mid x_1, x_2, x_3, x_4, x_5) \end{aligned}$$

## Faktoryzacja funkcji prawdopodobieństwa

$X_1, X_2, X_3, X_4, X_5, X_6$  – zmienne losowe



$$p(x_1, x_2, x_3, x_4, x_5, x_6) = p(x_1) \cdot$$

$$p(x_2 | x_1) \cdot$$

$$p(x_3 | x_1, x_2) \cdot$$


$$p(x_4 | x_1, x_2, x_3) \cdot$$

$$p(x_5 | x_1, x_2, x_3, x_4) \cdot$$

$$p(x_6 | x_1, x_2, x_3, x_4, x_5)$$

## Faktoryzacja funkcji prawdopodobieństwa

$X_1, X_2, X_3, X_4, X_5, X_6$  – zmienne losowe



$$p(x_1, x_2, x_3, x_4, x_5, x_6) = p(x_1) \cdot$$

$$p(x_2 | x_1) \cdot$$

$$p(x_3 | x_1, x_2) \cdot$$


$$p(x_4 | x_1, x_2, x_3) \cdot$$

$$p(x_5 | x_1, x_2, x_3, x_4) \cdot$$

$$p(x_6 | x_1, x_2, x_3, x_4, x_5)$$

## Faktoryzacja funkcji prawdopodobieństwa

$X_1, X_2, X_3, X_4, X_5, X_6$  – zmienne losowe



$$p(x_1, x_2, x_3, x_4, x_5, x_6) = p(x_1) \cdot$$

$$p(x_2 | x_1) \cdot$$

$$p(x_3 | x_1, x_2) \cdot$$


$$p(x_4 | x_1, x_2, x_3) \cdot$$

$$p(x_5 | x_1, x_2, x_3, x_4) \cdot$$

$$p(x_6 | x_1, x_2, x_3, x_4, x_5)$$

## Faktoryzacja funkcji prawdopodobieństwa

$X_1, X_2, X_3, X_4, X_5, X_6$  – zmienne losowe



$$p(x_1, x_2, x_3, x_4, x_5, x_6) = p(x_1) \cdot$$

$$p(x_2 | x_1) \cdot$$

$$p(x_3 | x_1, x_2) \cdot$$


$$x_4 \perp\!\!\!\perp (x_1, x_3) | x_2 \rightarrow p(x_4 | x_1, x_2, x_3) \cdot$$

$$p(x_5 | x_1, x_2, x_3, x_4) \cdot$$

$$p(x_6 | x_1, x_2, x_3, x_4, x_5)$$

## Faktoryzacja funkcji prawdopodobieństwa

$X_1, X_2, X_3, X_4, X_5, X_6$  – zmienne losowe



$$p(x_1, x_2, x_3, x_4, x_5, x_6) = p(x_1) \cdot$$

$$p(x_2 | x_1) \cdot$$

$$p(x_3 | x_1, x_2) \cdot$$


$$x_4 \perp\!\!\!\perp (x_1, x_3) | x_2 \rightarrow p(x_4 | x_1, x_2, x_3) \cdot$$

$$p(x_5 | x_1, x_2, x_3, x_4) \cdot$$

$$p(x_6 | x_1, x_2, x_3, x_4, x_5)$$

## Faktoryzacja funkcji prawdopodobieństwa

$X_1, X_2, X_3, X_4, X_5, X_6$  – zmienne losowe



$$p(x_1, x_2, x_3, x_4, x_5, x_6) = p(x_1) \cdot$$

$$p(x_2 | x_1) \cdot$$

$$p(x_3 | x_1, x_2) \cdot$$

$$p(x_4 | x_1, x_2, x_3) \cdot$$

$$x_5 \perp\!\!\!\perp (x_1, x_4) | (x_2, x_3)$$


$$\rightarrow p(x_5 | x_1, x_2, x_3, x_4) \cdot$$

$$p(x_6 | x_1, x_2, x_3, x_4, x_5)$$



## Faktoryzacja funkcji prawdopodobieństwa

$X_1, X_2, X_3, X_4, X_5, X_6$  – zmienne losowe



$$p(x_1, x_2, x_3, x_4, x_5, x_6) = p(x_1) \cdot$$

$$p(x_2 | x_1) \cdot$$

$$p(x_3 | x_1, x_2) \cdot$$

$$p(x_4 | x_1, x_2, x_3) \cdot$$


$$p(x_5 | x_1, x_2, x_3, x_4) \cdot$$

$$x_6 \perp\!\!\!\perp (x_1, x_2, x_3) | (x_4, x_5)$$

$$\rightarrow p(x_6 | x_1, x_2, x_3, x_4, x_5)$$

## Faktoryzacja funkcji prawdopodobieństwa


$X_1, X_2, X_3, X_4, X_5, X_6$  – zmienne losowe



$$\begin{aligned} p(x_1, x_2, x_3, x_4, x_5, x_6) &= p(x_1) \cdot \\ &\quad p(x_2 \mid x_1) \cdot \\ &\quad p(x_3 \mid x_1, x_2) \cdot \\ &\quad p(x_4 \mid x_1, x_2, x_3) \cdot \\ &\quad p(x_5 \mid x_1, x_2, x_3, x_4) \cdot \\ &\quad p(x_6 \mid x_1, x_2, x_3, x_4, x_5) = \\ &= \prod_{i=1}^6 p(x_i \mid \mathbf{x}_{\text{pa}(i)}) \end{aligned}$$

## Faktoryzacja funkcji prawdopodobieństwa


$X_1, X_2, X_3, X_4, X_5, X_6$  – zmienne losowe



$$\begin{aligned} p(x_1, x_2, x_3, x_4, x_5, x_6) &= p(x_1) \cdot \\ &\quad p(x_2 \mid x_1) \cdot \\ &\quad p(x_3 \mid x_1, x_2) \cdot \\ &\quad p(x_4 \mid x_1, x_2, x_3) \cdot \\ &\quad p(x_5 \mid x_1, x_2, x_3, x_4) \cdot \\ &\quad p(x_6 \mid x_1, x_2, x_3, x_4, x_5) = \\ &= \prod_{i=1}^6 p(x_i \mid \mathbf{x}_{\text{pa}(i)}) \end{aligned}$$

## Faktoryzacja funkcji prawdopodobieństwa

$X_1, X_2, X_3, X_4, X_5, X_6$  – zmienne losowe




$$\begin{aligned} p(x_1, x_2, x_3, x_4, x_5, x_6) &= p(x_1) \cdot \\ & p(x_2 | x_1) \cdot \\ & p(x_3 | x_1, x_2) \cdot \\ & p(x_4 | x_1, x_2, x_3) \cdot \\ & p(x_5 | x_1, x_2, x_3, x_4) \cdot \\ & p(x_6 | x_1, x_2, x_3, x_4, x_5) = \\ &= \prod_{i=1}^6 p(x_i | \mathbf{x}_{\text{pa}(i)}) \end{aligned}$$

Zauważmy ponadto, że

$$p(x_1, x_2, x_3, x_5) = p(x_1)p(x_2 | x_1)p(x_3 | x_1)p(x_5 | x_3)$$

## Faktoryzacja funkcji prawdopodobieństwa

$X_1, X_2, X_3, X_4, X_5, X_6$  – zmienne losowe



$$\begin{aligned} p(x_1, x_2, x_3, x_4, x_5, x_6) &= p(x_1) \cdot \\ & p(x_2 | x_1) \cdot \\ & p(x_3 | x_1, x_2) \cdot \\ & p(x_4 | x_1, x_2, x_3) \cdot \\ & p(x_5 | x_1, x_2, x_3, x_4) \cdot \\ & p(x_6 | x_1, x_2, x_3, x_4, x_5) = \\ &= \prod_{i=1}^6 p(x_i | \mathbf{x}_{\text{pa}(i)}) \end{aligned}$$

Zauważmy ponadto, że

$$p(x_1, x_2, x_3, x_5) = p(x_1)p(x_2 | x_1)p(x_3 | x_1)p(x_5 | x_3) = \prod_{i \in \{1, 2, 3, 5\}} p(x_i | \mathbf{x}_{\text{pa}(i)})$$

**Obserwacja.** Jeśli  $\mathcal{G}$  jest siecią bayesowską dla zmiennych  $X_1, \dots, X_n$ , to

$$p(x_1, \dots, x_n) = \prod_{i=1}^n p(x_i \mid \mathbf{x}_{\text{pa}(i)}).$$


**Obserwacja.** Jeśli  $\mathcal{G}$  jest siecią bayesowską dla zmiennych  $X_1, \dots, X_n$ , oraz  $A$  jest **zbiorem samorodnym**, tzn.  $\text{pa}(A) \subseteq A$ , to

$$p(\mathbf{x}_A) = \prod_{i \in A} p(x_i \mid \mathbf{x}_{\text{pa}(i)}).$$

- **zbiór ancestralny do  $A$  w  $\mathcal{G}$**  to  $\text{An}(A) := A \cup \{\text{an}(i) : i \in A\}$

## Kolejne grafowe definicje

- **zbiór ancestralny do  $A$  w  $\mathcal{G}$**  to  $An(A) := A \cup \{an(i) : i \in A\}$
- **graf indukowany**




$\mathcal{G}$



## Kolejne grafowe definicje


- *zbiór ancestralny do  $A$  w  $\mathcal{G}$*  to  $An(A) := A \cup \{an(i) : i \in A\}$
- *graf indukowany*




$\mathcal{G}$

## Kolejne grafowe definicje

- **zbiór ancestralny do  $A$  w  $\mathcal{G}$**  to  $An(A) := A \cup \{an(i) : i \in A\}$
- **graf indukowany**




$\mathcal{G}$



$\mathcal{G}_A$

## Kolejne grafowe definicje


- *moralizacja grafu skierowanego*



$\mathcal{G}$

## Kolejne grafowe definicje


- *moralizacja grafu skierowanego*



$\mathcal{G}$

## Kolejne grafowe definicje


- *moralizacja grafu skierowanego*




$\mathcal{G}$

## Kolejne grafowe definicje

- moralizacja grafu skierowanego*



$\mathcal{G}$




$\mathcal{G}^m$

**Twierdzenie.** W grafie skierowanym  $\mathcal{G}$  zachodzi  $A \not\rightarrow B \mid S$  wtedy i tylko wtedy, gdy w grafie  $\mathcal{G}_{An(A \cup B \cup S)}^m$  każda ścieżka łącząca  $A$  i  $B$  przecina  $S$  (ozn.  $A \not\rightarrow B \mid S$ ).

**Twierdzenie.** W grafie skierowanym  $\mathcal{G}$  zachodzi  $A \not\rightarrow B \mid S$  wtedy i tylko wtedy, gdy w grafie  $\mathcal{G}_{An(A \cup B \cup S)}^m$  każda ścieżka łącząca  $A$  i  $B$  przecina  $S$  (ozn.  $A \not\rightarrow B \mid S$ ).


**Przykład 1:**





**Twierdzenie.** W grafie skierowanym  $\mathcal{G}$  zachodzi  $A \not\rightarrow B \mid S$  wtedy i tylko wtedy, gdy w grafie  $\mathcal{G}_{An(A \cup B \cup S)}^m$  każda ścieżka łącząca  $A$  i  $B$  przecina  $S$  (ozn.  $A \rightarrow B \mid S$ ).


**Przykład 1:**



$\mathcal{G}_{An(A \cup B \cup S)}^m$

**Twierdzenie.** W grafie skierowanym  $\mathcal{G}$  zachodzi  $A \not\rightarrow B \mid S$  wtedy i tylko wtedy, gdy w grafie  $\mathcal{G}_{An(A \cup B \cup S)}^m$  każda ścieżka łącząca  $A$  i  $B$  przecina  $S$  (ozn.  $A \not\rightarrow B \mid S$ ).


**Przykład 1:**



$\mathcal{G}_{An(A \cup B \cup S)}^m$


**Twierdzenie.** W grafie skierowanym  $\mathcal{G}$  zachodzi  $A \not\rightarrow B \mid S$  wtedy i tylko wtedy, gdy w grafie  $\mathcal{G}_{An(A \cup B \cup S)}^m$  każda ścieżka łącząca  $A$  i  $B$  przecina  $S$  (ozn.  $A \not\rightarrow B \mid S$ ).

Przykład 2:



**Twierdzenie.** W grafie skierowanym  $\mathcal{G}$  zachodzi  $A \not\rightarrow B \mid S$  wtedy i tylko wtedy, gdy w grafie  $\mathcal{G}_{An(A \cup B \cup S)}^m$  każda ścieżka łącząca  $A$  i  $B$  przecina  $S$  (ozn.  $A \not\rightarrow B \mid S$ ).


Przykład 2:



$\mathcal{G}_{An(A \cup B \cup S)}^m$

**Twierdzenie.** W grafie skierowanym  $\mathcal{G}$  zachodzi  $A \not\rightarrow B \mid S$  wtedy i tylko wtedy, gdy w grafie  $\mathcal{G}_{An(A \cup B \cup S)}^m$  każda ścieżka łącząca  $A$  i  $B$  przecina  $S$  (ozn.  $A \not\rightarrow B \mid S$ ).


**Przykład 2:**



$\mathcal{G}_{An(A \cup B \cup S)}^m$

**Twierdzenie.** W grafie skierowanym  $\mathcal{G}$  zachodzi  $A \not\rightarrow B \mid S$  wtedy i tylko wtedy, gdy w grafie  $\mathcal{G}_{An(A \cup B \cup S)}^m$  każda ścieżka łącząca  $A$  i  $B$  przecina  $S$  (ozn.  $A \not\rightarrow B \mid S$ ).

Przykład 2:



$\mathcal{G}_{An(A \cup B \cup S)}^m$

**Twierdzenie.** (*Hammersley-Clifford*) Rozważmy zmienne losowe  $X_1, \dots, X_n$  o łącznej funkcji prawdopodobieństwa  $p(x_1, \dots, x_n)$ . Niech  $\mathcal{H}$  będzie grafem (nieskierowanym) o wierzchołkach  $V = 1, \dots, n$ . Wówczas implikacja

$$A \not\sim B \mid S \Rightarrow \mathbf{X}_A \perp\!\!\!\perp \mathbf{X}_B \mid \mathbf{X}_S$$

zachodzi dla dowolnych  $A, B, S \subseteq V$  wtedy i tylko wtedy, gdy

$$p(\mathbf{x}) = \prod_{C \in \mathcal{C}} \xi(\mathbf{x}_C) \tag{HC}$$

gdzie  $\mathcal{C}$  to rodzina wszystkich klik w grafie  $\mathcal{H}$ .

**Twierdzenie.** (*Hammersley-Clifford*) Rozważmy zmienne losowe  $X_1, \dots, X_n$  o łącznej funkcji prawdopodobieństwa  $p(x_1, \dots, x_n)$ . Niech  $\mathcal{H}$  będzie grafem (nieskierowanym) o wierzchołkach  $V = 1, \dots, n$ . Wówczas implikacja


$$A \not\sim B \mid S \Rightarrow \mathbf{X}_A \perp\!\!\!\perp \mathbf{X}_B \mid \mathbf{X}_S$$

zachodzi dla dowolnych  $A, B, S \subseteq V$  wtedy i tylko wtedy, gdy

$$p(\mathbf{x}) = \prod_{C \in \mathcal{C}} \xi(\mathbf{x}_C) \quad (\text{HC})$$

gdzie  $\mathcal{C}$  to rodzina wszystkich klik w grafie  $\mathcal{H}$ .

**Przykład.**





**Twierdzenie.** (Hammersley-Clifford) Rozważmy zmienne losowe  $X_1, \dots, X_n$  o łącznej funkcji prawdopodobieństwa  $p(x_1, \dots, x_n)$ . Niech  $\mathcal{H}$  będzie grafem (nieskierowanym) o wierzchołkach  $V = 1, \dots, n$ . Wówczas implikacja


$$A \not\sim B \mid S \Rightarrow \mathbf{X}_A \perp\!\!\!\perp \mathbf{X}_B \mid \mathbf{X}_S$$

zachodzi dla dowolnych  $A, B, S \subseteq V$  wtedy i tylko wtedy, gdy

$$p(\mathbf{x}) = \prod_{C \in \mathcal{C}} \xi(\mathbf{x}_C) \quad (\text{HC})$$

gdzie  $\mathcal{C}$  to rodzina wszystkich klik w grafie  $\mathcal{H}$ .

**Przykład.**



$$p(\mathbf{x}) = V_a(x_1, x_2, x_3, x_4) \cdot V_b(x_3, x_5) \cdot V_c(x_5, x_6, x_7)$$

**Twierdzenie.** (Hammersley-Clifford) Rozważmy zmienne losowe  $X_1, \dots, X_n$  o łącznej funkcji prawdopodobieństwa  $p(x_1, \dots, x_n)$ . Niech  $\mathcal{H}$  będzie grafem (nieskierowanym) o wierzchołkach  $V = 1, \dots, n$ . Wówczas implikacja


$$A \not\sim B \mid S \Rightarrow \mathbf{X}_A \perp\!\!\!\perp \mathbf{X}_B \mid \mathbf{X}_S$$

zachodzi dla dowolnych  $A, B, S \subseteq V$  wtedy i tylko wtedy, gdy

$$p(\mathbf{x}) = \prod_{C \in \mathcal{C}} \xi(\mathbf{x}_C) \quad (\text{HC})$$

gdzie  $\mathcal{C}$  to rodzina wszystkich klik w grafie  $\mathcal{H}$ .

**Przykład.**



$$p(\mathbf{x}) = V_a(x_1, x_2, x_3, x_4) \cdot V_b(x_3, x_5) \cdot V_c(x_5, x_6, x_7)$$

$$\{X_1, X_2\} \perp\!\!\!\perp \{X_6, X_7\} \mid X_3?$$

**Twierdzenie.** (Hammersley-Clifford) Rozważmy zmienne losowe  $X_1, \dots, X_n$  o łącznej funkcji prawdopodobieństwa  $p(x_1, \dots, x_n)$ . Niech  $\mathcal{H}$  będzie grafem (nieskierowanym) o wierzchołkach  $V = 1, \dots, n$ . Wówczas implikacja


$$A \not\sim B \mid S \Rightarrow \mathbf{X}_A \perp\!\!\!\perp \mathbf{X}_B \mid \mathbf{X}_S$$

zachodzi dla dowolnych  $A, B, S \subseteq V$  wtedy i tylko wtedy, gdy

$$p(\mathbf{x}) = \prod_{C \in \mathcal{C}} \xi(\mathbf{x}_C) \quad (\text{HC})$$

gdzie  $\mathcal{C}$  to rodzina wszystkich klik w grafie  $\mathcal{H}$ .

**Przykład.**




$$p(\mathbf{x}) = V_a(x_1, x_2, x_3, x_4) \cdot V_b(x_3, x_5) \cdot V_c(x_5, x_6, x_7)$$


$$\{X_1, X_2\} \perp\!\!\!\perp \{X_6, X_7\} \mid X_3? \text{ TAK!}$$

**Przypadek I.**  $A \cup B \cup S = V$

Przypadek I.  $A \cup B \cup S = V$




Przypadek I.  $A \cup B \cup S = V$




$C =$

Przypadek I.  $A \cup B \cup S = V$



$$\mathcal{C} = \mathcal{C}_A \sqcup$$


Przypadek I.  $A \cup B \cup S = V$



$$\mathcal{C} = \mathcal{C}_A \sqcup \mathcal{C}_B \sqcup$$




Przypadek I.  $A \cup B \cup S = V$




$$\mathcal{C} = \mathcal{C}_A \sqcup \mathcal{C}_B \sqcup \mathcal{C}_S$$

Przypadek I.  $A \cup B \cup S = V$



$$\mathcal{C} = \mathcal{C}_A \sqcup \mathcal{C}_B \sqcup \mathcal{C}_S$$


$$(\text{HC}) \quad p(\mathbf{x}) = \prod_{C \in \mathcal{C}} V_C(\mathbf{x}_C)$$

Przypadek I.  $A \cup B \cup S = V$ 

$$\mathcal{C} = \mathcal{C}_A \sqcup \mathcal{C}_B \sqcup \mathcal{C}_S$$

$$(\text{HC}) \quad p(\mathbf{x}) = \prod_{C \in \mathcal{C}} V_C(\mathbf{x}_C)$$


$$p(\underbrace{\mathbf{x}_A, \mathbf{x}_B, \mathbf{x}_S}_{\mathbf{x}}) = \prod_{C \in \mathcal{C}_A} V_C(\mathbf{x}_C) \cdot \prod_{C \in \mathcal{C}_B} V_C(\mathbf{x}_C) \cdot \prod_{C \in \mathcal{C}_S} V_C(\mathbf{x}_C)$$

Przypadek I.  $A \cup B \cup S = V$ 

$$\mathcal{C} = \mathcal{C}_A \sqcup \mathcal{C}_B \sqcup \mathcal{C}_S$$

$$(HC) \quad p(\mathbf{x}) = \prod_{C \in \mathcal{C}} V_C(\mathbf{x}_C)$$


$$p(\underbrace{\mathbf{x}_A, \mathbf{x}_B, \mathbf{x}_S}_{\mathbf{x}}) = \underbrace{\prod_{C \in \mathcal{C}_A} V_C(\mathbf{x}_C)}_{\Phi(\mathbf{x}_A, \mathbf{x}_S)} \cdot \prod_{C \in \mathcal{C}_B} V_C(\mathbf{x}_C) \cdot \prod_{C \in \mathcal{C}_S} V_C(\mathbf{x}_C)$$

Przypadek I.  $A \cup B \cup S = V$ 

$$\mathcal{C} = \mathcal{C}_A \sqcup \mathcal{C}_B \sqcup \mathcal{C}_S$$

$$(HC) \quad p(\mathbf{x}) = \prod_{C \in \mathcal{C}} V_C(\mathbf{x}_C)$$

$$p(\underbrace{\mathbf{x}_A, \mathbf{x}_B, \mathbf{x}_S}_{\mathbf{x}}) = \underbrace{\prod_{C \in \mathcal{C}_A} V_C(\mathbf{x}_C)}_{\Phi(\mathbf{x}_A, \mathbf{x}_S)} \cdot \underbrace{\prod_{C \in \mathcal{C}_B} V_C(\mathbf{x}_C) \cdot \prod_{C \in \mathcal{C}_S} V_C(\mathbf{x}_C)}_{\Psi(\mathbf{x}_B, \mathbf{x}_S)}$$

Przypadek I.  $A \cup B \cup S = V$ 

$$\mathcal{C} = \mathcal{C}_A \sqcup \mathcal{C}_B \sqcup \mathcal{C}_S$$


$$(\text{HC}) \quad p(\mathbf{x}) = \prod_{C \in \mathcal{C}} V_C(\mathbf{x}_C)$$

$$p(\underbrace{\mathbf{x}_A, \mathbf{x}_B, \mathbf{x}_S}_{\mathbf{x}}) = \underbrace{\prod_{C \in \mathcal{C}_A} V_C(\mathbf{x}_C)}_{\Phi(\mathbf{x}_A, \mathbf{x}_S)} \cdot \underbrace{\prod_{C \in \mathcal{C}_B} V_C(\mathbf{x}_C) \cdot \prod_{C \in \mathcal{C}_S} V_C(\mathbf{x}_C)}_{\Psi(\mathbf{x}_B, \mathbf{x}_S)}$$

... a zatem  $\mathbf{X}_A \perp\!\!\!\perp \mathbf{X}_B \mid \mathbf{X}_S$


**Przypadek II.**  $A \cup B \cup S \neq V$

Przypadek II.  $A \cup B \cup S \neq V$






Przypadek II.  $A \cup B \cup S \neq V$




$A'$ : połączone z  $A$  ścieżką poza  $S$

Przypadek II.  $A \cup B \cup S \neq V$ 

$A'$ : połączone z  $A$  ścieżką poza  $S$


$$B' = V \setminus (A' \cup S)$$

Przypadek II.  $A \cup B \cup S \neq V$ 

$A'$ : połączone z  $A$  ścieżką poza  $S$

$$B' = V \setminus (A' \cup S)$$

Wówczas nie można przejść z  $A'$  do  $B'$  omijając  $S$ .


Przypadek II.  $A \cup B \cup S \neq V$ 

$A'$ : połączone z  $A$  ścieżką poza  $S$

$$B' = V \setminus (A' \cup S)$$

Wówczas nie można przejść z  $A'$  do  $B'$  omijając  $S$ .

Ponadto  $V = A' \cup B' \cup S$

Przypadek II.  $A \cup B \cup S \neq V$ 


$A'$ : połączone z  $A$  ścieżką poza  $S$

$$B' = V \setminus (A' \cup S)$$

Wówczas nie można przejść z  $A'$  do  $B'$  omijając  $S$ .

Ponadto  $V = A' \cup B' \cup S$

Z wcześniejszych rozważań wynika  $\mathbf{X}_{A'} \perp\!\!\!\perp \mathbf{X}_{B'} \mid \mathbf{X}_S$

Przypadek II.  $A \cup B \cup S \neq V$ 

$A'$ : połączone z  $A$  ścieżką poza  $S$

$$B' = V \setminus (A' \cup S)$$

Wówczas nie można przejść z  $A'$  do  $B'$  omijając  $S$ .

Ponadto  $V = A' \cup B' \cup S$

Z wcześniejszych rozważań wynika  $\mathbf{X}_{A'} \perp\!\!\!\perp \mathbf{X}_{B'} \mid \mathbf{X}_S$

Ponieważ  $A \subseteq A'$  i  $B \subseteq B'$ , więc  $\mathbf{X}_A \perp\!\!\!\perp \mathbf{X}_B \mid \mathbf{X}_S$



## Dowód twierdzenia Pearl'a

Niech  $\mathcal{G}$  będzie siecią bayesowską dla zmiennych  $X_1, \dots, X_n$ .

## Dowód twierdzenia Pearla

Niech  $\mathcal{G}$  będzie siecią bayesowską dla zmiennych  $X_1, \dots, X_n$ . Mamy

$$p(\mathbf{x}) = \prod_{i=1}^n p(x_i \mid \mathbf{x}_{\text{pa}(i)})$$



## Dowód twierdzenia Pearla

Niech  $\mathcal{G}$  będzie siecią bayesowską dla zmiennych  $X_1, \dots, X_n$ . Mamy

$$p(\mathbf{x}) = \prod_{i=1}^n p(x_i \mid \mathbf{x}_{\text{pa}(i)})$$

Niech  $W = \text{An}(A \cup B \cup S)$ .

## Dowód twierdzenia Pearla

Niech  $\mathcal{G}$  będzie siecią bayesowską dla zmiennych  $X_1, \dots, X_n$ . Mamy

$$p(\mathbf{x}) = \prod_{i=1}^n p(x_i \mid \mathbf{x}_{\text{pa}(i)})$$

Niech  $W = \text{An}(A \cup B \cup S)$ . Ponieważ  $W$  jest samorodny

## Dowód twierdzenia Pearl'a

Niech  $\mathcal{G}$  będzie siecią bayesowską dla zmiennych  $X_1, \dots, X_n$ . Mamy

$$p(\mathbf{x}) = \prod_{i=1}^n p(x_i \mid \mathbf{x}_{\text{pa}(i)})$$

Niech  $W = \text{An}(A \cup B \cup S)$ . Ponieważ  $W$  jest samorodny więc

$$p(\mathbf{x}_W) = \prod_{i \in W} p(x_i \mid \mathbf{x}_{\text{pa}(i)})$$

## Dowód twierdzenia Pearl'a

Niech  $\mathcal{G}$  będzie siecią bayesowską dla zmiennych  $X_1, \dots, X_n$ . Mamy

$$p(\mathbf{x}) = \prod_{i=1}^n p(x_i \mid \mathbf{x}_{\text{pa}(i)})$$

Niech  $W = \text{An}(A \cup B \cup S)$ . Ponieważ  $W$  jest samorodny więc

$$p(\mathbf{x}_W) = \prod_{i \in W} p(\underbrace{x_i \mid \mathbf{x}_{\text{pa}(i)}}_{\text{klika w } \mathcal{G}_W^m})$$


## Dowód twierdzenia Pearl'a

Niech  $\mathcal{G}$  będzie siecią bayesowską dla zmiennych  $X_1, \dots, X_n$ . Mamy

$$p(\mathbf{x}) = \prod_{i=1}^n p(x_i | \mathbf{x}_{\text{pa}(i)})$$

Niech  $W = \text{An}(A \cup B \cup S)$ . Ponieważ  $W$  jest samorodny więc

$$p(\mathbf{x}_W) = \prod_{i \in W} p(\underbrace{x_i | \mathbf{x}_{\text{pa}(i)}}_{\text{klika w } \mathcal{G}_W^m})$$




## Dowód twierdzenia Pearl'a

Niech  $\mathcal{G}$  będzie siecią bayesowską dla zmiennych  $X_1, \dots, X_n$ . Mamy

$$p(\mathbf{x}) = \prod_{i=1}^n p(x_i \mid \mathbf{x}_{\text{pa}(i)})$$

Niech  $W = \text{An}(A \cup B \cup S)$ . Ponieważ  $W$  jest samorodny więc

$$p(\mathbf{x}_W) = \prod_{i \in W} p(\underbrace{x_i \mid \mathbf{x}_{\text{pa}(i)}}_{\text{klika w } \mathcal{G}_W^m})$$




## Dowód twierdzenia Pearl'a

Niech  $\mathcal{G}$  będzie siecią bayesowską dla zmiennych  $X_1, \dots, X_n$ . Mamy

$$p(\mathbf{x}) = \prod_{i=1}^n p(x_i | \mathbf{x}_{\text{pa}(i)})$$

Niech  $W = \text{An}(A \cup B \cup S)$ . Ponieważ  $W$  jest samorodny więc

$$p(\mathbf{x}_W) = \prod_{i \in W} p(\underbrace{x_i | \mathbf{x}_{\text{pa}(i)}}_{\text{klika w } \mathcal{G}_W^m})$$



Zmienne  $\mathbf{X}_W$  spełniają zatem warunek (HC) względem grafu  $\mathcal{G}_W^m$ .


## Dowód twierdzenia Pearla

Niech  $\mathcal{G}$  będzie siecią bayesowską dla zmiennych  $X_1, \dots, X_n$ . Mamy

$$p(\mathbf{x}) = \prod_{i=1}^n p(x_i | \mathbf{x}_{\text{pa}(i)})$$

Niech  $W = \text{An}(A \cup B \cup S)$ . Ponieważ  $W$  jest samorodny więc

$$p(\mathbf{x}_W) = \prod_{i \in W} p(\underbrace{x_i | \mathbf{x}_{\text{pa}(i)}}_{\text{klika w } \mathcal{G}_W^m})$$



Zmienne  $\mathbf{X}_W$  spełniają zatem warunek (HC) względem grafu  $\mathcal{G}_W^m$ .

Czyli  $A \not\perp B | S$  w  $\mathcal{G}_W^m$  implikuje  $\mathbf{X}_A \not\perp \mathbf{X}_B | \mathbf{X}_S$ .




## Dowód twierdzenia Pearla

Niech  $\mathcal{G}$  będzie siecią bayesowską dla zmiennych  $X_1, \dots, X_n$ . Mamy

$$p(\mathbf{x}) = \prod_{i=1}^n p(x_i | \mathbf{x}_{\text{pa}(i)})$$

Niech  $W = \text{An}(A \cup B \cup S)$ . Ponieważ  $W$  jest samorodny więc

$$p(\mathbf{x}_W) = \prod_{i \in W} p(\underbrace{x_i | \mathbf{x}_{\text{pa}(i)}}_{\text{klika w } \mathcal{G}_W^m})$$



Zmienne  $\mathbf{X}_W$  spełniają zatem warunek (HC) względem grafu  $\mathcal{G}_W^m$ .

Czyli  $A \not\perp B | S$  w  $\mathcal{G}_W^m$  implikuje  $\mathbf{X}_A \not\perp \mathbf{X}_B | \mathbf{X}_S$ .

Zatem  $A \not\perp B | S$  w  $\mathcal{G}$  implikuje  $\mathbf{X}_A \not\perp \mathbf{X}_B | \mathbf{X}_S$ . □

## Kilka komentarzy na koniec

- *Każdy z nas, matematyków, ma w pamięci pytanie, które zapoczątkowało uprawianą przez nas problematykę (...)*

## Kilka komentarzy na koniec

- *Każdy z nas, matematyków, ma w pamięci pytanie, które zapoczątkowało uprawianą przez nas problematykę (...)*
- rozważane przez nas pytanie leży u podstaw dwóch dziedzin (zapoczątkowanych przez J. Pearla)

## Kilka komentarzy na koniec


- *Każdy z nas, matematyków, ma w pamięci pytanie, które zapoczątkowało uprawianą przez nas problematykę (...)*
- rozważane przez nas pytanie leży u podstaw dwóch dziedzin (zapoczątkowanych przez J. Pearla)
  - teoria sieci bayesowskich

## Kilka komentarzy na koniec

- *Każdy z nas, matematyków, ma w pamięci pytanie, które zapoczątkowało uprawianą przez nas problematykę (...)*
- rozważane przez nas pytanie leży u podstaw dwóch dziedzin (zapoczątkowanych przez J. Pearla)
  - teoria sieci bayesowskich
  - **teoria przyczynowości**


## Kilka komentarzy na koniec

- *Każdy z nas, matematyków, ma w pamięci pytanie, które zapoczątkowało uprawianą przez nas problematykę (...)*
- rozważane przez nas pytanie leży u podstaw dwóch dziedzin (zapoczątkowanych przez J. Pearla)
  - teoria sieci bayesowskich
  - **teoria przyczynowości**



## Kilka komentarzy na koniec


- *Każdy z nas, matematyków, ma w pamięci pytanie, które zapoczątkowało uprawianą przez nas problematykę (...)*
- rozważane przez nas pytanie leży u podstaw dwóch dziedzin (zapoczątkowanych przez J. Pearla)
  - teoria sieci bayesowskich
  - **teoria przyczynowości**



- kupno lodu nie zwiększa szans na ładną pogodę!

## Kilka komentarzy na koniec

- *Każdy z nas, matematyków, ma w pamięci pytanie, które zapoczątkowało uprawianą przez nas problematykę (...)*
- rozważane przez nas pytanie leży u podstaw dwóch dziedzin (zapoczątkowanych przez J. Pearla)
  - teoria sieci bayesowskich
  - **teoria przyczynowości**




- kupno lodu nie zwiększa szans na ładną pogodę!
- warunkowanie przez interwencję  $\neq$  warunkowanie przez obserwację



## Kilka komentarzy na koniec


- *Każdy z nas, matematyków, ma w pamięci pytanie, które zapoczątkowało uprawianą przez nas problematykę (...)*
- rozważane przez nas pytanie leży u podstaw dwóch dziedzin (zapoczątkowanych przez J. Pearla)
  - teoria sieci bayesowskich
  - **teoria przyczynowości**



- kupno lodu nie zwiększa szans na ładną pogodę!
- warunkowanie przez interwencję  $\neq$  warunkowanie przez obserwację
- kiedy można pr. interwencyjne obliczyć na podstawie obserwacyjnych?

## Kilka komentarzy na koniec

- *Każdy z nas, matematyków, ma w pamięci pytanie, które zapoczątkowało uprawianą przez nas problematykę (...)*
- rozważane przez nas pytanie leży u podstaw dwóch dziedzin (zapoczątkowanych przez J. Pearla)
  - teoria sieci bayesowskich
  - **teoria przyczynowości**



- kupno lodu nie zwiększa szans na ładną pogodę!
  - warunkowanie przez interwencję  $\neq$  warunkowanie przez obserwację
  - kiedy można pr. interwencyjne obliczyć na podstawie obserwacyjnych?
- zainteresowanym polecam J. Pearl „Przyczyny i skutki”

## Kilka komentarzy na koniec

- *Każdy z nas, matematyków, ma w pamięci pytanie, które zapoczątkowało uprawianą przez nas problematykę (...)*
- rozważane przez nas pytanie leży u podstaw dwóch dziedzin (zapoczątkowanych przez J. Pearla)

- teoria sieci bayesowskich
- **teoria przyczynowości**



- kupno lodu nie zwiększa szans na ładną pogodę!
  - warunkowanie przez interwencję  $\neq$  warunkowanie przez obserwację
  - kiedy można pr. interwencyjne obliczyć na podstawie obserwacyjnych?
- zainteresowanym polecam J. Pearl „Przyczyny i skutki”





**Dziękuję za uwagę!**