

# Systemy uczące się – wykład 4

dr Przemysław Juszczuk

Katedra Inżynierii Wiedzy, Uniwersytet Ekonomiczny

XII 2018

## Przykład

Miażdżyca powoduje często zwężenie tętnic wieńcowych. Prowadzi to zazwyczaj do zmniejszenia przepływu krwi w tych naczyniach, co może wywołać niedotlenienie mięśnia sercowego, zwłaszcza przy wysiłku fizycznym.

---

- Które fragmenty wskazują na niepewność wnioskowania?
- Jak przekształcić powyższy tekst w taki sposób, aby można było do niego zastosować jedną z poznanych dotychczas reprezentacji wiedzy.
- Czy do tak przekształconego tekstu można zadać pytania:
  - jaki ma wpływ wysiłek fizyczny na niedotlenienie mięśnia sercowego u ludzi z jednakowo posuniętą miażdżycą, wykonujących wysiłek fizyczny o różnym natężeniu?
  - w jakim stopniu człowiek, u którego nie występuje niedotlenienie z powodu wysiłku, narażony jest na zwężenie tętnic z powodu miażdżycy?

## Definicje

Podejście probabilistyczne:

Mając dany zbiór hipotez:

$$H = \{h_1, \dots, h_n\}$$


dla których:

$$P(h_i) > 0 \text{ dla każdego } i$$

Mając zbiór pewnych obserwacji:

$$E = \{e_1, \dots, e_m\}$$


każdy fragment obserwacji  $e_j$  jest niezależny warunkowo względem każdej hipotezy.



Rysunek: Przesłanka a hipoteza

Obserwacja  $e$  oraz hipoteza  $h$  są reprezentowane przez wierzchołki grafu, natomiast natomiast wnioskowanie przez krawędź. Rozpatrywana reguła może być rozpatrywana w modelu Bayesa następująco:

$$P(h|e) = \frac{P(e|h) \cdot P(h)}{P(e)}$$



gdzie a, b, c, d to obserwacje, E, F, G to hipotez

Rysunek: Sieć wnioskowania

## Sieć Bayesa

$$B = \{N, E, CP\}$$

gdzie dwójka  $\{N, E\}$  jest skierowanym grafem acyklicznym zbudowanym na podstawie zadanych prawdopodobieństw warunkowych zawartych w zbiorze CP. Przykład:


Dany jest zbiór pewnych zmiennych identyfikujących obserwacje i hipotezy. P Niech zbiór tych zmiennych ma następującą postać:

$$Z = A, B, C, D, E, F, G, H$$

Dane są również informacje opisujące związki przyczynowo-skutkowe pomiędzy tymi zmiennymi w postaci zbioru prawdopodobieństw warunkowych CP:

$$CP =$$

$$\{P(A), P(B|A), P(C|B), P(C|F), P(D|C), P(E|CH), P(F|G), P(G), P(H|G)\}$$



Rysunek: Wynikowa sieć Bayesa

## CF

Współczynniki pewności CF:

Jeżeli  $e_1 \& \dots \& e_n$  To  $h$  ze stopniem pewności CF

gdzie:

$e_1, e_2, \dots, e_n$  to przesłanki reguły a  $h$  to konkluzja,  $\&$  to operator logiczny And.



## Współczynnik CF

- CF nie jest interpretowany jako klasyczne prawdopodobieństwo
- Współczynnik pewności CF jest połączeniem stopnia wiedzy, oraz niewiedzy.
- Stopień wiedzy - inaczej miara wiarygodności - MB.
- Stopień niewiedzy - miara niewiarygodności - MD.

Założmy istnienie prostej reguły:

Jeżeli  $e$  to  $h$

## Współczynniki CF

Współczynniki dla powyższej reguły określone są następująco:

- $MB(h,e)$
- $MD(h,e)$
- $CF(h,e)$

Sam współczynnik CF definiowany jest jako:

$$CF(h, e) = MB(h, e) - MD(h, e)$$

## Miary CF

Interpretacja powyższych miar może być następująca:

- jeżeli  $P(h|e) = 1$  to  $h$  jest prawdziwe na pewno, wtedy  
 $MB(h, e) = 1$ ,  $MD(h, e) = 0$ , oraz  $CF(h, e) = 1$ ,
- jeżeli  $P(h|e) = 0$  to  $h$  jest fałszywe na pewno, wtedy  
 $MB(h, e) = 0$ ,  $MD(h, e) = 1$ , oraz  $CF(h, e) = -1$ ,
- jeżeli  $P(h|e) = P(h)$  to  $h$  co znaczy, że  $h$  i  $e$  są niezależne, wtedy  
 $MB(h, e) = 0$ , oraz  $MD(h, e) = 0$ ,  $CF(h, e) = 0$ .

$$CF(h, e) = \begin{cases} 1, & P(h) = 1, \\ MB(h, e) & P(h|e) > P(h) \\ 0, & P(h|e) = P(h) \\ -MD(h, e), & P(h|e) < P(h) \\ -1, & P(h) = 0 \end{cases}$$

Rysunek: Wartości CF

## Propagacja współczynników niepewności

Mając daną regułę R:

Jeżeli  $e$  to  $h$  ze stopniem pewności  $CF$

- przesłanka reguły  $e$  ma pewien współczynnik  $CF$
- konkluzja reguły  $h$  również ma współczynnik  $CF$

Końcowy współczynnik pewności wyznaczany jest w następujący sposób:

$$CF(h, e) = CF(e) \cdot CF(h)$$

## Współczynniki pewności

- W przypadku gdy przesłanka reguły zawiera wyrażenie zawierające operator AND (&) :

Jeżeli  $e1 \& e2$  to  $h$  ze stopniem pewności  $CF$  to współczynnik pewności konkluzji  $h$  wyznaczany jest w następujący sposób:

$$CF(h, e1 \& e2) = \text{Minimum} \{CF(e1), CF(e2)\} \cdot CF(h)$$


- W przypadku gdy przesłanka reguły zawiera wyrażenie zawierające funktor OR (|) :

Jeżeli  $e1 | e2$  to  $h$  ze stopniem pewności  $CF$  to współczynnik pewności konkluzji  $h$  wyznaczany jest w następujący sposób:

$$CF(h, e1 | e2) = \text{Maksimum} \{CF(e1), CF(e2)\} \cdot CF(h)$$

W przypadku, gdy jedna hipoteza  $h$  jest konkluzją więcej niż jednej reguły:

- Jeżeli  $e_1$  to  $h$
- Jeżeli  $e_2$  to  $h$



Rysunek: Obliczanie CF

$$CF(h, e_1, e_2) = \begin{cases} CF(h, e_1) + CF(h, e_2) - CF(h, e_1)CF(h, e_2), & CF(h, e_1) \text{ i } CF(h, e_2) \geq 0 \\ \frac{CF(h, e_1) + CF(h, e_2)}{1 - \min(|CF(h, e_1)|, |CF(h, e_2)|)}, & CF(h, e_1) * CF(h, e_2) < 0, \\ CF(h, e_1) + CF(h, e_2) + CF(h, e_1)CF(h, e_2), & CF(h, e_1) \text{ i } CF(h, e_2) < 0 \end{cases}$$

Rysunek: Obliczanie CF


Połączenie szeregowe reguł:

- Jeżeli e1 to e2
- Jeżeli e2 to h




Rysunek: Szeregowe połączenie reguł  $CF(h, e1) = CF(e2, e1) \cdot CF(h, e2)$





Rysunek: Propagacja CF


$$CF(e4, e1) = CF(e2, e1) \cdot CF(e4, e2)$$



Rysunek: Propagacja CF


$$CF(e4, e1, e3) = \frac{CF(e4, e1) + CF(e4, e3)}{1 - \min(|CF(e4, e1)|, |CF(e4, e3)|)}$$

$$CF(e4, e1, e3) = \frac{0.25}{1 - 0.2} = \frac{0.25}{0.8} = 0.3125$$




Rysunek: Propagacja CF

$$CF(h, e4) = CF(e4, e1e3) \cdot CF(h, e1e3)$$



Rysunek: Propagacja CF

$$CF(h, e1e3, e5) = CF(h, e1e3) + CF(h, e5) - CF(h, e1e3) \cdot CF(h, e5)$$



Rysunek: Propagacja CF

$$CF(h, e1e3e5) = 0.5937$$

## Definicja

Sieć składająca się z następujących elementów:

- zbiór obiektów  $\{o_j\} = O$
- zbiór cech  $\{c_j\} = C$
- zbiór wartości  $\{v_j\} = V$

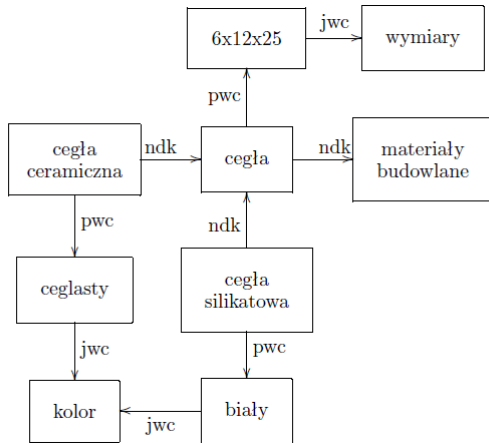
Elementami zbioru obiektów mogą być symbole oznaczające konkrety lub abstrakcje, np: samochód - to symbol abstrakcji, zaś Fiat 126 p KAE 0321 - to symbol konkretny.

## Relacje

- $O \times O$  relacja między obiektami, relacja określona na zbiorze obiektów.
  - ISA - relacja typu „część- całość” (nadrzędność)
  - ISPART - relacja podrzędności, czyli „(coś) jest częścią (czegoś)”

Relacje te są przechodnie.


- $O \times C$  - relacja przysługiwania obiektom pewnych cech - „posiada cechę”.
- $V \times C$  - relacja postaci „jest wartością cechy”.
- $V \times V$  - relacja uporządkowania elementów zbioru wartości cech, np.: relacja typu: „(coś) poprzedza (coś)”, lub „(coś) następuje po (czymś)”.
- $O \times V$  - relacja typu „posiada wartość cechy”, czyli przypisania obiektom wartości cechy. Czasem relacja ta jest tworzona przez złączenie relacji  $O \times C$  oraz  $V \times C$ .



Rysunek: Sieć semantyczna - przykład



- Wszystkie kosi są ptakami:



Rysunek: Budowanie sieci semantycznej - przykład


- Jaś jest kosem



Rysunek: Budowanie sieci semantycznej - przykład

Możliwe jest następujące wnioskowanie:

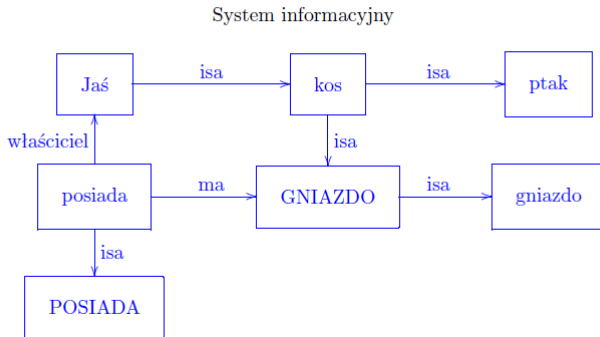
- Jaś jest kosem,
- kos jest ptakiem,
- Jaś jest ptakiem.



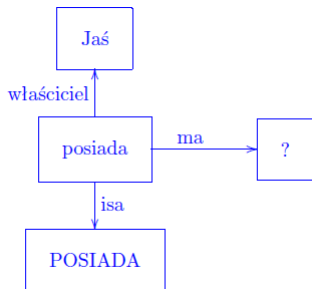
Rysunek: Sieć semantyczna - błąd wnioskowania

Ale: „uczeni badają Jasia”, co może ale nie musi być prawdą.

Co posiada Jaś ?



Rysunek: Sieć semantyczna - system informacyjny



Rysunek: Sieć semantyczna - zapytanie

## Zastosowanie sieci semantycznych

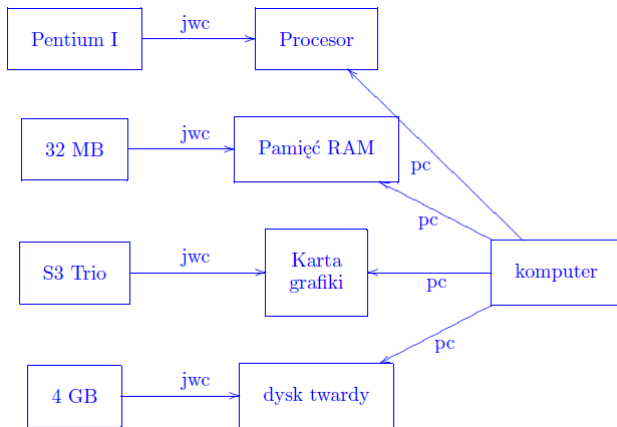
- projektowanie systemów informacyjnych (baz danych);
- rozumienie języka naturalnego;
- rozpoznawanie mowy;
- budowania systemów odpowiadających na pytania

## Przykład 1

Komputer jest opisywany przez następujące parametry:

- procesor;
- pamięć RAM;
- karta grafiki;
- dysk twardy.

Przedstaw sieć semantyczną opisującą powyższe zależności. Jako przykład przyjmij komputer: procesor Pentium I, pamięć RAM 32 MB, karta grafiki S3 Trio, dysk HDD 4GB.



Rysunek: Rozwiązanie

Dziękuję za uwagę