

AI: Niepewność w wiedzy w systemach AI

KIERUNKI (PODEJŚCIA) W ROZWOJU AI



Niepewność wiedzy

Założmy, że zadaniem inżyniera wiedzy jest dobór właściwej reprezentacji wiedzy dla następującego fragmentu wiedzy medycznej, która będzie

zapisana w bazie wiedzy przyszłego systemu ekspertowego wspomagającego diagnozę w przypadku chorób serca:

> "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".

Wykorzystując reprezentacje wiedzy w postaci rachunku predykatów (czy np. reguł w postaci klauzul Horna) inżynier wiedzy zmuszony byłby

do przekształcenia powyższego zdania do ścisłej formy umożliwiającej

zastosowanie klarownych implikacji:

"Miażdżyca powoduje zwężenie tętnic wieńcowych. Prowadzi to do zmniejszenia przepływu krwi w tych naczyniach, co wywołuje niedotlenienie mięśnia sercowego przy wysiłku fizycznym".

Niepewność wiedzy

Niestety prowadzi to do znacznej **radyalizacji** prezentowanych stwierdzeń oraz potencjalnych problemów z odwzorowaniem ostatniej części zdania.

Najważniejszą wadą jest uniemożliwienie przywiązania różnych wag do poszczególnych symptomów.

Lekarz bowiem jest zainteresowany informacjami o dużo subtelniejszej naturze niż stwierdzenie, że pacjent z miażdżycą ma niedotlenionymięsień sercowy (co wydaje się oczywiste lecz nie zawsze prawdziwe).

Kardiolog może oczekiwać od przyszłego systemu ekspertowego, że będzie "umiał" on odpowiedzieć np. na 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?

Niepewność wiedzy

Wiedza uzyskana od ekspertów jest często

- niepewna;
- niekompletna;
- niespójna;
- **niedoskonała.**

Systemy ekspertowe muszą być w stanie radzić sobie z wiedzą tego typu.

Niepewność wiedzy

Istnieją różne podejścia umożliwiające odwzorowanie

przykładowego fragmentu wiedzy medycznej w swej pierwotnej postaci oraz umożliwiające realizację

procesu wnioskowania również w przypadku postawionych poprzednio pytań.

Podejścia te opierają się zwykle na metodach numerycznych.

Do najważniejszych należą **metody**:

- **probabilistyczne,**
- **wielowartościowe,**
- **rozmyte**
- **wykorzystujące teorię Dempstera-Shafera.**

Idea metod probabilistycznych i rozmytych



Niepewność wiedzy

Eksperti są w stanie podejmować decyzje w oparciu o swoją często niedoskonałą wiedzę.

Systemy ekspertowe również muszą być w stanie radzić sobie z wiedzą tego typu.

> Niepewność można zdefiniować jako brak dokładnej wiedzy, tzn. takiej, która umożliwia podejmowanie w

> pełni uzasadnionych decyzji i w pełni wiarygodnych wniosków.

Czym jest niepewność? Z formalnego punktu widzenia

Klasyczna logika zakłada, że dostępna wiedza jest doskonała oraz że zawsze jest spełnione **prawo wyłączonego środka**:

IF A jest TRUE THEN A nie jest FALSE IF A jest FALSE THEN A nie jest TRUE

Źródła niepewności

- Nieprecyzyjność języka naturalnego
- Trudności ze sformułowaniem zależności w postaci reguł
- Łączenie wiedzy kilku ekspertów
- Niekompletność danych, na których system ma operować

Nieprecyzyjność języka naturalnego

> ● Always 99 > ● Always 100

> ● Very often 88

● Usually 85

● Sometimes 20 ● Usualuy not 10 ● Never 0

> ● Very often 87

● Usually 79

● Sometimes 29 ● Usualuy not 16 ● Never 0

Łączenie wiedzy kilku ekspertów

W rozwoju systemów ekspertowych bierze udział wielu ekspertów.

Eksperci często mają odmienne zdanie na dany temat.

Ich wiedza często jest na różnym poziomie w zależności od zagadnienia w danej dziedzinie.

Metody umożliwiające reprezentacje niepewności wiedzy:

■ probabilistyczne,

■ wielowartościowe,

■ rozmyte

■ wykorzystujące teorię

Dempstera-Shafera.

Metody probabilistyczne POJĘCIA PODSTAWOWE

Systemy ekspertowe i wiedza niepewna Załóżmy, że mamy regułę w postaci:

IF E is TRUE THEN H is TRUE {z prawd. p} Reguła ta mówi, że jeśli wystąpi **E** to **H** wystąpi z prawdopodobieństwem **p**.

IF jest ładna pogoda THEN może pójść na spacer {0.9}

E: pogoda jest ładna

H: może pójść na spacer



Teoria prawdopodobieństwa

- Prawdopodobieństwo zdarzenia A to liczba z przedziału

$[0,1]$ wyrażająca proporcję przypadków, kiedy dane zdarzenie zachodzi.

- $p(A) = 0$ - całkowita niemożliwość ● $p(A) = 1$ - całkowita pewność

Jeśli wynikiem może być sukces lub porażka:

$$p(\text{sukces}) = \text{liczba_sukcesów} / \text{liczba_prób}$$

$$p(\text{porażka}) = \text{liczba_porażek} / \text{liczba_prób}$$

Aksjomaty prawdopodobieństwa



Rozkład zmiennej losowej (Gaussa)

1 $F(x)$

P-wo, że X

mieści się w Δ

$f(x)$

Δm

20



Prawdopodobieństwo warunkowe

Założmy, że zdarzenia A i B nie są wzajemnie wykluczające się.

Prawdopodobieństwo zdarzenia A może zależeć od tego,
czy miało miejsce zdarzenie B.

$$p(A|B) = \text{liczba_wystąpień_A_oraz_B} / \text{liczba_wystąpień_B}$$



Prawdopodobieństwo warunkowe

Prawdopodobieństwo tego, że wystąpi A i B nazywamy prawdopodobieństwem łącznym tych zdarzeń.



Zatem prawdopodobieństwo warunkowe definiujemy jako:



Prawdopodobieństwo warunkowe

Analogicznie prawdopodobieństwo B pod warunkiem A:

Prawdopodobieństwo łączne jest przemienne:

Twierdzenie Bayesa



Analogicznie prawdopodobieństwo B pod warunkiem A:



Wzór Bayesa

$p(A)$ - prawdopodobieństwo zdarzenia A

$p(B)$ - prawdopodobieństwo zdarzenia B

$p(A|B)$ - prawdopodobieństwo zdarzenia A pod warunkiem, że zaszło zdarzenie B $p(B|A)$ - prawdopodobieństwo zdarzenia B pod warunkiem, że zaszło zdarzenie A

prawdopodobieństwo zajścia jakiegoś zdarzenia (faktu). Jest to oczywiście

prawdopodobieństwo zajścia zdarzenia A pod warunkiem zdarzenia B - co odpowiada

prostej regule "**Jezeli B to A**", którego ogólna postać wygląda następująco:

Prawdopodobieństwo warunkowe



W przypadku, gdy A zależy od zdarzeń $B_1, B_2, \dots, B_n$ wzajemnie się wykluczających:

wtedy

Prawdopodobieństwo całkowite

Jeśli B_i $i=1 \dots n$ wyczerpują wszystkie

> możliwe zdarzenia:

> S - zbiór wszystkich możliwych zdarzeń;

wtedy prawdopodobieństwo całkowite

$p(A)$:



Prawdopodobieństwo całkowite



Jeśli A zależy jedynie od dwóch wykluczających się zdarzeń, np. **B** oraz **NOT B**:

Reguła Bayesa

Analogicznie dla B:



Korzystając z reguły Bayesa otrzymamy:



Reguła Bayesa



Wzór ten jest podstawą do obsługi **niepewności** w systemach ekspertowych z wykorzystaniem metod probabilistycznych.

Systemy ekspertowe i wiedza niepewna Załóżmy, że mamy regułę w postaci:

IF E is TRUE THEN H is TRUE {z prawd. p}

Reguła ta mówi, że jeśli wystąpi **E** to **H** wystąpi z

prawdopodobieństwem **p**.



Systemy ekspertowe i wiedza niepewna

> IF E is TRUE THEN H is TRUE {p}	> Jak obliczyć???
-----------------------------------	-------------------

Wiemy, że **E wystąpiło**.

Jak policzyć prawdopodobieństwo, że wystąpiło **H** ?

Odpowiedź (reguła Bayesa):

Systemy ekspertowe i wiedza niepewna



$p(H)$ - prawdopodobieństwo a priori wystąpienia H

$p(E|H)$ - prawdopodobieństwo, że jeśli wystąpi H, to wystąpiło też E

$p(\sim H)$ - prawdopodobieństwo a priori nie wystąpienia H

$p(E|\sim H)$ - prawdopodobieństwo, że jeśli nie wystąpi H, to mimo wszystko wystąpiło E

$p(H|E)$ - prawdopodobieństwo a posteriori wystąpienia H, jeśli wystąpiło E

Systemy ekspertowe i wiedza niepewna



Prawdopodobieństwa **$p(H)$, $p(E|H)$, $p(\sim H)$ oraz $p(E|\sim H)$**

są określane przez eksperta bądź też szacowane

statystycznie.

Systemy ekspertowe i wiedza niepewna Co w przypadku wystąpienia wielu hipotez?

(Hipotezy oraz przesłanki (dowody, ang. Evidences) muszą być

wzajemnie wykluczające się oraz wyczerpujące).



Systemy ekspertowe i wiedza niepewna

Co w przypadku wystąpienia wielu przesłanek E_i ?

(Hipotezy oraz przesłanki (dowody, ang. Evidences) muszą być wzajemnie wykluczające się oraz wyczerpujące).



Powyższy wzór wymaga obliczenia wszystkich prawdopodobieństw warunkowych dla wszystkich możliwych kombinacji przesłanek E_i oraz hipotez H_i .



W praktyce jest to często niemożliwe.

W przypadku szacowania na podstawie danych pojawiają się wątpliwości o jakość uzyskanych szacowań, jeśli np. przykładowych danych pokrywających dany przypadek jest mało.

Systemy ekspertowe i wiedza niepewna

Często zakłada się zatem, że **E1, E2,..., En są wzajemnie niezależne**.

Dwa zdarzenia **A oraz B są określane jako niezależne** wtedy i tylko wtedy, gdy:



Systemy ekspertowe i wiedza niepewna Zamiast:



otrzymujemy zatem:



Założenie takie nie jest zawsze uzasadnione i może przyczynić się do błędnego działania systemu.

Przykład

Warunki **E1, E2 oraz E3 są wzajemnie warunkowo niezależne**.

Trzy hipotezy **H1, H2 oraz H3 są wzajemnie wykluczające się oraz wyczerpujące**.

Ekspert dostarcza prawdopodobieństw a priori **p(H1), p(H2), p(H3)**

oraz prawdopodobieństwa warunkowe

p(Ei|Hj)

Hipoteza

Prawdopodobieństwo i=1		i=2	i=3
> p(Hi)	> 0.4		
p(E1 Hi)	0.3		
p(E2 Hi)	0.9		
p(E3 Hi)	0.6		
		> 0.35	> 0.25
		0.8	0.5
		0.0	0.7
		0.7	0.9

Przykład

Zakładamy, że jako pierwszy zaobserwowane jest **E3** :

☐

☐

☐

☐

Hipoteza

> p(Hi)	> 0.4	> 0.35 0.8	> 0.25
p(E1 Hi)	0.3	0.0	0.5
p(E2 Hi)	0.9	0.7	0.7
p(E3 Hi)	0.6		0.9

> p(Hi)	> 0.4	> 0.35 0.8	> 0.25
p(E1 Hi)	0.3	0.0	0.5
p(E2 Hi)	0.9	0.7	0.7
p(E3 Hi)	0.6		0.9

Następnie zaobserwowano **E1** :

Powinno być:

☐

Ale E1, E2, E3 są warunkowo niezależne, zatem:

☐

☐

☐

☐

> p(Hi)	> 0.4	> 0.35 0.8	> 0.25
p(E1 Hi)	0.3	0.0	0.5
p(E2 Hi)	0.9	0.7	0.7
p(E3 Hi)	0.6		0.9

Następnie zaobserwowano **E2** :

☐

☐

☐

☐

Ostatecznie zatem najbardziej prawdopodobna jest hipoteza **H3**.

Przykład 2 - Prognoza pogody

IF dzis jest deszcz

THEN jutro jest deszcz

IF dzis jest slonce

THEN jutro jest slonce

Zakładamy, że nie mając żadnych innych przesłanek,

deszcz jest równie prawdopodobny jak słońce – zatem

prawdopodobieństwa a priori wynoszą 0.5.

Przykład 2 - Prognoza pogody

IF dzis jest deszcz {LS=2.5, LN=0.6}

THEN jutro jest deszcz {a priori 0.5}

IF dzis jest slonce {LS=1.6, LN=0.4}

THEN jutro jest slonce {a priori 0.5}

LS (*likelihood of sufficiency*) - współczynnik wystarczalności

Miara przekonania eksperta, że **H** wystąpi, jeśli wystąpiło **E**.

LN (*likelihood of necessity*) - współczynnik konieczności

Miara przekonania eksperta, na ile **E** jest istotny dla wystąpienia **H**.

Przykład 2 - Prognoza pogody IF dzis jest deszcz {LS=2.5, LN=0.6}

THEN jutro jest deszcz {a priori 0.5}

IF dzis jest slonce {LS=1.6, LN=0.4}

THEN jutro jest slonce {a priori 0.5}

LS (*likelihood of sufficiency*) - współczynnik wystarczalności

Miara przekonania eksperta, że **H** wystąpi, jeśli wystąpiło **E**.



> np. dla reguły 1: >

Przykład 2 - Prognoza pogody

IF dzis jest deszcz {LS=2.5, LN=0.6}

THEN jutro jest deszcz {a priori 0.5}

IF dzis jest slonce {LS=1.6, LN=0.4}

THEN jutro jest slonce {a priori 0.5}

LN (*likelihood of necessity*) – współczynnik konieczności

Miara przekonania eksperta, na ile **E** jest istotny dla wystąpienia **H**.



np. dla reguły 2: > 

Przykład 2 - Prognoza pogody

LS nie może być otrzymany z LN ani LN z LS.

Ekspert musi dostarczyć obie wartości.

Nie jest konieczne szacowanie prawdopodobieństw warunkowych.

LN oraz LS mogą być szacowane bezpośrednio.

Wysokie wartości **LS** (**LS » 1**) wskazuje na to, że reguła mocno wspiera hipotezę **H** jeśli zaobserwowano **E**.

Małe wartości **LN** (**0 < LN < 1**) wskazują na to, że reguła mocno zaprzecza hipotezie **H** w przypadku braku **E**.

Przykład 2 - Prognoza pogody Reguła 1:

IF dzis jest deszcz {LS=2.5, LN=0.6}

THEN jutro jest deszcz {a priori 0.5}

Reguła ta mówi, że jeśli dziś jest deszcz, to jest

duże prawdopodobieństwo, że jutro również będzie

deszcz (**LS=2.5**).

Ale nawet jeśli dziś nie ma deszczu, istnieje pewna

niewielka szansa na to, by jutro był deszcz. (**LN=0.6**)

Przykład 2 - Prognoza pogody Reguła 2:

IF dzis jest slonce {LS=1.6, LN=0.4}

THEN jutro jest slonce {a priori 0.5}

Jeśli dziś jest słońce, jest duże prawdopodobieństwo, że jutro również będzie słońce (**LS=1.6**).

LN=0.4 określa jakie są szanse na to, że jutro będzie słońce jeśli dziś mamy deszcz (E nie jest spełnione)

Zalety szacowania niepewności w oparciu o reguły Bayesa

- Dobrze rozwinięta teoria matematyczna.
- Decyzje oparte na metodzie Bayesa są optymalne (pod warunkiem, że znamy odpowiednie rozkłady prawdopodobieństw).
- Wszystkie inne metody podejmowania decyzji mogą być co najwyżej zbieżne do metody Bayesa.

Wady reguły Bayesa

- Czasami trzeba czynić nieuprawnione założenia upraszczające problem (np. założenie o niezależności bądź warunkowej niezależności między zmiennymi).
- Badania psychologiczne dowodzą, iż ludziom ciężko jest szacować prawdopodobieństwa – często prawd. A priori są niespójne z prawd. warunkowymi.

SIECI BAYESA



Definicja sieci Bayesowskiej

Pod pojęciem sieci Bayesowskiej rozumiemy trójkę: $B = \{N, E, CP\}$,

Gdzie: dwójka $\{N, E\}$ jest zorientowanym grafem acyklicznym zbudowanym na podstawie zadanych

prawdopodobieństw warunkowych zawartych w zbiorze CP.

Inaczej mówiąc:

Sieć Bayesa stanowi numeryczny model związków

przyczynowo-skutkowych zachodzących między elementami

zbioru obserwacji i hipotez. Stosując twierdzenie Bayesa,

można dokonywać zarówno wnioskowania progresywnego

(wnioskowanie w przód), jak i wnioskowania regresywnego (wnioskowanie wstecz).





Przykład syntezy sieci Bayesa

Założmy, że dany jest zbiór pewnych zmiennych identyfikujących obserwacje i hipotezy. Przyjmijmy również, że nie jest dla nas w tym momencie ważne, które elementy tego zbioru są obserwacjami a które hipotezami. 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:

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

Na podstawie tych informacji możemy zbudować następujący graf skierowany, który po uzupełnieniu zbiorem konkretnych wartości prawdopodobieństw warunkowych opisuje sieć Bayesa:

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

co można przedstawić graficznie:

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



**Sieć Bayesa stanowi numeryczny model związków przyczynowo-
> skutkowych zachodzących pomiędzy elementami zbioru obserwacji i
hipotez. Stosując twierdzenie Bayesa, można dokonywać zarówno
wnioskowania progresywnego (wnioskowanie w przód), jak i
wnioskowania regresywnego (wnioskowanie wstecz).**

Przykład sieci Bayesowskiej

W podanym niżej tekście występują pewne zależności przyczynowo skutkowe opisane liczbowo prawdopodobieństwami warunkowymi.

Należy podać zbiór CP takich prawdopodobieństw warunkowych oraz narysować graf przyczynowo-skutkowy. Czy otrzymany graf jest siecią Bayes'a ?

■Jeżeli masz sporo pieniędzy, lubisz szybkie samochody i masz małą rodzinę to stawiam 10 do 100, że kupisz mały, czerwony, sportowy samochód.

■Ale jeśli masz sporo pieniędzy, lubisz szybkie samochody i masz sporo dzieci to kupisz na pewno kombi z mocnym silnikiem.

■Jeżeli jesteś na stanowisku kierowniczym i dbasz o prestiż to na 50 % kupisz mercedesa ze skórzaną tapicerką.

■Jeżeli potrzebujesz jedynie wygodnego , prostego

samochodu to na pewno kupisz auto klasy kompaktowej. ■Jeżeli jest ci wszystko jedno to na 30 % auto średniej klasy

Rozwiązanie

O - obserwacje:

- a - mała rodzina (mało dzieci),
- b - sporo pieniędzy,
- c - lubić szybkie samochody,
- e - spora rodzina (sporo dzieci),
- f - stanowisko kierownicze,
- h - posiadany prestiż,
- j - chęć wygodny i prostoty,
- k - obojętność.

H - hipotezy:

- D - czerwony, sportowy samochód,
- G - kombi,
- I - sedan ze skórzaną tapicerką,
- L - samochód kompaktowy,
- M - auto średniej klasy

CP = {P(D|a, c) = 0.1, P(G|b,e) = 1.0, P(I| f, h) = 0.5, P(L|j) = 1.0, P(M|k) = 0.3}

Reprezentacja graficzna:



Jak widać graf jest skierowany (dokładnie określone są kierunki

wnioskowania), jest on acykliczny (gdyż nie zawiera żadnych cykli), zatem jest on siecią Bayesa.

Podsumowanie

Wadą tej metody jest fakt, że wymaga ona znajomości dokładnych wartości lub rozkładów prawdopodobieństw pojawienia się parametrów zjawiska, czyli problemu będącego przedmiotem rozważań.

Innym problemem jest to, że należy dokonać pewnych nierealistycznych założeń – na przykład w klasyfikacji

bayesowskiej wymagane wyniki, np. rozpoznawania, muszą się wzajemnie wykluczać. Niestety w wielu przypadkach mogą występować liczne podobne wyniki (np. w diagnostyce: pacjent może mieć wiele chorób).

Innym założeniem, co prawda niewymaganym przez

twierdzenie Bayesa, ale wymuszonym przez praktykę, jest statystyczna niezależność cechy problemu .

From:

<https://wiki.ostrowski.net.pl/> - **Kacper's Wiki**

Permanent link:

https://wiki.ostrowski.net.pl/doku.php?id=notatki:ai_niepewnosc&rev=1748004398

Last update: **2025/05/23 14:46**