

Elementy Sztucznej Inteligencji

Wnioskowanie statystyczne i oparte na współczynnikach wiarygodności

Elementy Sztucznej Inteligencji - wykład 8 1

Plan wykładu

- Niepewność
- Wnioskowanie statystyczne:
 - Wprowadzenie teoretyczne
 - Wnioskowanie probabilistyczne
 - Przykłady
- Wnioskowanie ze współczynnikami wiarygodności
 - Wprowadzenie, definicje.
 - Przykład
- Porównanie technik

Elementy Sztucznej Inteligencji - wykład 8 2

Typy niepewności

- **Niepewność wiedzy podstawowej:**
np.. pewne przyczyny chorób są nieznanne i nie są prezentowane w podstawach wiedzy medycznej.
- **Niepewność działań:**
np.. działania można przedstawić jako relatywnie krótką listę warunków początkowych. W rzeczywistości liczba faktów do uwzględnienia jest przytłaczająco duża.
- **Niepewność postrzegania:**
np.. czujniki agenta nie zwracają dokładnej informacji o świecie i agent nigdy nie wie wszystkiego o swoim położeniu (szum).

Elementy Sztucznej Inteligencji - wykład 8 3

Przykład

Przykład niepewności działania:

By rano odjechać samochodem:

- Samochód nie mógł być w nocy ukradziony.
 - Opony nie mogą być dziurawe.
 - Musi być benzyna w baku.
 - Akumulator musi być sprawny.
 - Zapłon musi działać.
 - Kluczyk do stacyjki nie mogły zostać zgubione.
 - Ciężarówka nie może zablokować wyjazdu.
 - Nie można nagle stracić wzroku.
- itd....

Elementy Sztucznej Inteligencji - wykład 8 4

Metody radzenia sobie z wiedzą niepewną

- Wnioskowanie niemonotoniczne
 - np.. Zakładam, że samochód nie ma dziury w oponie
 - problem: jakie założenia są poprawne, jak radzić sobie ze sprzecznościami powstałymi w wyniku wprowadzenia nowego założenia.
- Zastosowanie współczynników wiarygodności
 - np. reguły: zraszacz → mokra trawa (cf = 0.99)
 - problemy: problemy ze składaniem i śledzeniem zależności.
- Prawdopodobieństwo
 - wykorzystuje stopień przekonania (degree of belief)
 - działa dla systemów z dostępnymi dowodami
- Logika rozmyta – opisuje stopień prawdziwości a nie niepewności

Elementy Sztucznej Inteligencji - wykład 8 5

Prawdopodobieństwo

- Prawdopodobieństwo jest subiektywne:
 - prawdopodobieństwa określają proporcje wynikające z indywidualnej oceny agenta.
 - np.. $P(\text{dojadę na dworzec}_{15\text{min}} | \text{nie stwierdzono wypadku}) = 0,06$
- Nie formułuje twierdzeń o świecie (prawdopodobnych tendencji), jednak może się uczyć z własnych doświadczeń o podobnych sytuacjach.
- Przedstawione prawdopodobieństwa nie określają stopnia prawdziwości reguły (która może być albo prawdziwa, albo fałszywa), ale stopień wiary (oczekiwana częstość) w jej wystąpieniu.
- Prawdopodobieństwa hipotez (wniosków) zmieniają się wraz nowymi dowodami
 - np.. $P(\text{dojadę na dworzec}_{15\text{min}} | \text{nie stwierdzono wypadku, 17:00}) = 0,16$

Elementy Sztucznej Inteligencji - wykład 8 6

Podjęmowanie decyzji w niepewności

- Zakładamy, że jesteśmy przekonani o
 - $P(A_{25} \text{ gets me there on time} \mid \dots) = 0.04$
 - $P(A_{90} \text{ gets me there on time} \mid \dots) = 0.70$
 - $P(A_{120} \text{ gets me there on time} \mid \dots) = 0.95$
 - $P(A_{1440} \text{ gets me there on time} \mid \dots) = 0.9999$
- Jaką akcję podjąć?
- Należy rozważyć czy chcemy się spóźnić i jak długo chcemy czekać.
- Teoria użyteczności jest stosowana do określenia preferowanych wniosków
- Teoria decyzji = teoria użyteczności + teoria prawdopodobieństwa.

Elementy Sztucznej Inteligencji - wykład 8 7

Podstawy teorii prawdopodobieństwa

- Prawdopodobieństwo wystąpienia zdarzenia jest odsetkiem jego wystąpień.
- Miara prawdopodobieństwa określana jest wartościami z zakresu 0 (zdarzenie niemożliwe) do 1 (zdarzenie pewne).
- Dla każdego zdarzenia można podać dwie miary:
 - prawdopodobieństwo powodzenia:
 $P(\text{powodzenie}) =$
 $= \text{liczba powodzeń} / \text{liczba możliwych wyników (prób)}$
 - prawdopodobieństwo porażki:
 $P(\text{porażka}) =$
 $= \text{liczba porażek} / \text{liczba możliwych wyników (prób)}$
 - $P(\text{powodzenie}) + P(\text{porażka}) = 1$
- Zdarzenie A jest dowolnym podzbiorem Ω (przestrzeń prób)
 $P(A) = \sum_{\omega \in A} P(\omega)$
 - $P(\text{rzut kością} < 4) = P(1) + P(2) + P(3) = 1/6 + 1/6 + 1/6 = 1/2$

Elementy Sztucznej Inteligencji - wykład 8 8

Zmienne losowe

- Zmienna losowa jest funkcją z próbki w pewien zakres np.. liczb rzeczywistych czy binarnych,
 - np.. $\text{Odd}(1)=\text{true}$.
- P określa rozkład prawdopodobieństwa dla każdej zmiennej losowej X :
 - $P(X = x_i) = \sum_{\omega: X(\omega) = x_i} P(\omega)$
 - np., $P(\text{Odd}=\text{true}) = P(1) + P(3) + P(5) = 1/6 + 1/6 + 1/6 = 1/2$

Elementy Sztucznej Inteligencji - wykład 8 9

Składnia

- Boolowska zmienne losowe
 - np, cavity (Czy mam ubytek?)
 - $\text{cavity} = \text{true}$ jest zdarzeniem, zapisana również cavity
- Dyskretne zmienne losowe
 - np., Weather może być jedną a $\{\text{sunny}; \text{rain}; \text{cloudy}; \text{snow}\}$
 - $\text{Weather} = \text{rain}$ jest zdarzeniem
- Wartości muszą być wyczerpujące i wzajemnie wykluczające się.
- Ciągła zmienna losowa (ograniczona i nieograniczona)
 - np, $\text{Temp}=21,6$; możliwe inne przedstawienie np., $\text{Temp} < 22,00$.

Elementy Sztucznej Inteligencji - wykład 8 10

Zdarzenia niezależne i zależne

→ Zdarzenie **niezależne** - zdarzenie wzajemnie wykluczające się, tj. nie mogą wystąpić równoległe np.. wyrzucenie 1 i 6 w jednym rzucie kostką są niezależne

→ Zdarzenia **zależne**:

- wydarzenia występujące równoległe,
- takie zdarzenia wpływają wzajemnie na prawdopodobieństwa wystąpienia,
- np.. jeżeli wiemy, że przy rzucie kostką na pewno nie wystąpi 1 to uzyskanie 6 przy pojedynczym rzucie:

$$p = \frac{s}{s+f} = \frac{1}{1+(5-1)} = 0.2$$

Elementy Sztucznej Inteligencji - wykład 8 11

Składnia

→ Zdarzenie **elementarne**: Pełna specyfikacja stanu świata niepewnego

- np, jeżeli „świat” zawiera tylko boolowskie zmienne losowe *cavity* i *toothache*, to istnieją 4 odrębne zdarzenia elementarne:

cavity = *false* ∧ *toothache* = *false*

cavity = *false* ∧ *toothache* = *true*

cavity = *true* ∧ *toothache* = *false*

cavity = *true* ∧ *toothache* = *true*


→ Zdarzenia elementarne są wzajemnie wykluczające się i wyczerpujące.

Elementy Sztucznej Inteligencji - wykład 8 12

Aksjomaty prawdopodobieństwa

→ Dla dowolnych zdarzeń A, B

- $0 \leq P(A) \leq 1$
- $P(\text{true}) = 1$ i $P(\text{false}) = 0$
- $P(A \vee B) = P(A) + P(B) - P(A \wedge B)$



Elementy Sztucznej Inteligencji - wykład 8 13

Prawdopodobieństwo a priori

→ Prawdopodobieństwo a priori zdarzeń

np, $P(\text{cavity} = \text{true}) = 0.2$ and $P(\text{Weather} = \text{sunny}) = 0.72$
 odnosi się do miary przekonania a priori bez pojawienia się nowych zdarzeń (dowodów). Żadne obserwacje mogące mieć wpływ na p nie zostały uwzględnione.

→ Rozkład prawdopodobieństwa daje wartości dla wszystkich możliwych zdarzeń:

$P(\text{Weather}) = \langle 0.72, 0.1, 0.08, 0.1 \rangle$ (znormalizowane, tj., P sumuje się do 1)

→ Łączny rozkład prawdopodobieństwa dla zbioru zmiennych losowych określa prawdopodobieństwa każdego zdarzenia elementarnego.

$P(\text{Weather}, \text{Cavity}) =$ macierz 4×2 :

| | | | | |
|--------------------------------|-------|-------|--------|------|
| $\text{Weather} =$ | sunny | rainy | cloudy | snow |
| $\text{Cavity} = \text{true}$ | 0.144 | 0.02 | 0.016 | 0.02 |
| $\text{Cavity} = \text{false}$ | 0.576 | 0.08 | 0.064 | 0.08 |

→ Na każde zapytanie z dziedziny można uzyskać odpowiedź na podstawie łącznego rozkładu prawdopodobieństwa dlatego, że każde zdarzenie jest sumą zdarzeń elementarnych

np. $P(\text{Cavity}) = 0.144 + 0.02 + 0.016 + 0.02 = 0.2$

Elementy Sztucznej Inteligencji - wykład 8 14

Prawdopodobieństwo warunkowe

- Prawdopodobieństwo warunkowe lub a posteriori
np., $P(\text{Cavity} | \text{Toothache}) = 0.8$
tj., Wszystko o czym wiem to *toothache*
- Notacja rozkładu warunkowego:
 - $\mathbf{P}(\text{Cavity} | \text{Toothache})$ dwuelementowy wektor dwuelementowych wektorów
- Jeżeli wiemy więcej, np., dane jest *cavity*, to mamy
 $P(\text{cavity} | \text{toothache}, \text{cavity}) = 1$
- Nowy dowód może być nieznaczący, zezwala na uproszczenia,
np,
 $P(\text{cavity} | \text{toothache}, \text{sunny}) = P(\text{cavity} | \text{toothache}) = 0.8$
- Takie wnioskowanie poparte jest przez teorię prawdopodobieństwa.

Elementy Sztucznej Inteligencji - wykład 8 15

Prawdopodobieństwo warunkowe

- Prawdopodobieństwo warunkowe (wzór 1.1):

$$p(a|b) = \frac{p(a \wedge b)}{p(b)}, p(b) > 0$$

- odpowiednio (1.2):

$$p(b|a) = \frac{p(b \wedge a)}{p(a)}, p(a) > 0$$

Elementy Sztucznej Inteligencji - wykład 8 16

Prawdopodobieństwo łączne

→ Ze wzoru (1.2) prawdopodobieństwo **łączne** (1.3):

$$p(b \wedge a) = p(b|a) p(a)$$

→ Główna wersja zachowana dla całego rozkładu, np.,
 $\mathbf{P}(\text{Weather}, \text{Cavity}) = \mathbf{P}(\text{Weather} | \text{Cavity}) \mathbf{P}(\text{Cavity})$

→ Prawdopodobieństwo łączne jest przechodnie (1.4):

$$p(b \wedge a) = p(a \wedge b)$$

Elementy Sztucznej Inteligencji - wykład 8 17

Wyprowadzenie reguły Bayes'a

→ Dany jest wzór na prawdopodobieństwo warunkowe:

$$p(a|b) = \frac{p(a \wedge b)}{p(b)}, p(b) > 0$$

→ Podstawiając ze wzoru (1.3) prawdopodobieństwo łączne i korzystając z własności (1.4) uzyskujemy (1.5):

$$p(a|b) = \frac{p(b|a)p(a)}{p(b)}$$

Elementy Sztucznej Inteligencji - wykład 8 18

Rozpatrywanie wielu zdarzeń

→ a zależy od zdarzeń b_1, \dots, b_n niezależnych, stąd (1.6):


$$\sum_{i=1}^n p(a \wedge b_i) = \sum_{i=1}^n p(a|b_i)p(b_i)$$

→ Jeżeli n jest pełną listą zdarzeń warunkowych, to (1.7):

$$\sum_{i=1}^n p(a \wedge b_i) = p(a)$$

→ stąd, z (1.6) i z (1.7) wynika (1.8):

$$p(a) = \sum_{i=1}^n p(a|b_i)p(b_i)$$



Elementy Sztucznej Inteligencji - wykład 8 19

Reguła Bayesa dla dwóch zdarzeń

→ Jeżeli badamy wystąpienie zdarzenia b zależnego od zmiennej losowej boolowskiej a , która może mieć dwie wartości to wzór (1.8) przybiera formę (1.9):

$$p(b) = p(b|a)p(a) + p(b|\neg a)p(\neg a),$$

→ Korzystając z (1.9) reguła Bayesa ma postać (1.10):

$$p(a|b) = \frac{p(b|a)p(a)}{p(b|a)p(a) + p(b|\neg a)p(\neg a)},$$

Elementy Sztucznej Inteligencji - wykład 8 20

Wnioskowanie z zastosowaniem reguły Bayesa

- Reguły reprezentowane są w formie:
IF D(owód) jest TRUE
THEN H(ipoteza) jest TRUE (z prawdopodobieństwem p)
- D to dowód na wystąpienie zdarzenia H, zatem reguła Bayes'a (z 1.10):

$$p(H | D) = \frac{p(D|H)p(H)}{p(D|H)p(H) + p(D|\neg H)p(\neg H)},$$

- gdzie:

- $p(H)$ - dane prawdopodobieństwo, że hipoteza H jest TRUE,
- $p(D|H)$ - hipoteza H jest TRUE pod wpływem dowodu D,
- $p(\neg H)$ - prawdopodobieństwo, gdy hipoteza H jest FALSE,
- $p(D|\neg H)$ - prawdopodobieństwo znalezienia dowodu D, gdy hipoteza H jest FALSE.

Elementy Sztucznej Inteligencji - wykład 8 21

Jakie dane trzeba znać?

- $p(H)$ musi być dane zanim jakkolwiek dowód D zostanie przedstawiony.
- Ponadto dane musi być:
 - prawdopodobieństwo, że hipoteza jest TRUE to zaobserwowano dowód D, czyli: $p(D|H)$;
 - oraz prawdopodobieństwo wystąpienia D, gdy hipoteza była FALSE: $p(D|\neg H)$.
- Dane dostarczane są przez ekspertów, lub wynikają ze zgromadzonych danych i obliczeń statystycznych.

Elementy Sztucznej Inteligencji - wykład 8 22

Wiele hipotez dla jednego dowodu

→ Hipotezy H_1, \dots, H_m muszą być wzajemnie wykluczające się, wówczas (1.11):

$$p(H_i|D) = \frac{p(D|H_i)p(H_i)}{\sum_{k=1}^m p(D|H_k)p(H_k)},$$

Elementy Sztucznej Inteligencji - wykład 8 23

Wiele hipotez i wiele dowodów

→ Hipotezy H_1, \dots, H_m jak i dowody D_1, \dots, D_n muszą być wzajemnie wykluczające się (niezależne). Wówczas (1.12):

$$p(H_i|D_1 D_2 \dots D_n) = \frac{p(D_1 D_2 \dots D_n|H_i)p(H_i)}{\sum_{k=1}^m p(D_1 D_2 \dots D_n|H_k)p(H_k)},$$

→ Upraszczając, ze względu na niemożliwą do uzyskania informację o prawdopodobieństwie kombinacji wszystkich dowodów dla danej hipotezy uzyskuje się zależność (1.13):

$$p(H_i|D_1 D_2 \dots D_n) = \frac{p(D_1|H_i)p(D_2|H_i)\dots p(D_n|H_i)p(H_i)}{\sum_{k=1}^m p(D_1|H_k)p(D_2|H_k)\dots p(D_n|H_k)p(H_k)},$$

Elementy Sztucznej Inteligencji - wykład 8 24

Prosty przykład oceny degree of belief

- Dane są przez eksperta następujące wartości prawdopodobieństw np.. (H1=grypa, H2= alergja, H3=przeziębienie) (D1 = katar, D2 = gorączka, D3 = ból głowy)

| prawdopodobieństwo | Hipotezy | | |
|--------------------|----------|------|------|
| | i=1 | i=2 | i=3 |
| p(Hi) | 0,4 | 0,35 | 0,25 |
| p(D1 Hi) | 0,3 | 0,8 | 0,5 |
| p(D2 Hi) | 0,9 | 0 | 0,7 |
| p(D3 Hi) | 0,6 | 0,7 | 0,9 |

Elementy Sztucznej Inteligencji - wykład 8 25

Został zaobserwowany dowód D3

- Jak długo nie ma żadnych dodatkowych informacji wiemy, że H1 może pojawić się z prawdopodobieństwem 0.4, H2 z 0.35, a H3 z 0.25.
- Pojawia się jednak dowód D3, co dzieje się z przekonaniem o hipotezach H1, H2 i H3?
- Korzystając z zależności wiele hipotez 1 dowód (1.11) obliczamy:

Elementy Sztucznej Inteligencji - wykład 8 26

Jak zmienia się H1, H2 i H3

$$p(H_1|D_3) = \frac{0,6 \times 0,4}{0,6 \times 0,4 + 0,7 \times 0,35 + 0,9 \times 0,25} = 0,34$$

$$p(H_2|D_3) = \frac{0,7 \times 0,35}{0,6 \times 0,4 + 0,7 \times 0,35 + 0,9 \times 0,25} = 0,35$$

$$p(H_3|D_3) = \frac{0,9 \times 0,25}{0,6 \times 0,4 + 0,7 \times 0,35 + 0,9 \times 0,25} = 0,32$$

Elementy Sztucznej Inteligencji - wykład 8 27

Wnioski

- Poprzez przedstawienie dowodu D3
- przekonanie o hipotezie H1 zmalało (0.4 do 0.34),
 - przekonanie o H2 prawie zrównało się z H1 (0.35), ale się nie zmieniło
 - przekonanie o H3 wzrosło (0.25 do 0.32).

Elementy Sztucznej Inteligencji - wykład 8 28

Został zaobserwowany dowód D1

- Po zaobserwowaniu dowodu D3 zaobserwowano kolejny dowód D1.
- Należy zatem uwzględnić sytuację, gdy operujemy na wielu hipotezach i wielu dowodach.
- Do wyznaczania nowego przekonania o hipotezach skorzystamy ze wzoru (1. 13).

Elementy Sztucznej Inteligencji - wykład 8 29

Jak zmienia się H1, H2 i H3

$$p(H_1|D_1D_3) = \frac{0,3 \times 0,6 \times 0,4}{0,3 \times 0,6 \times 0,4 + 0,8 \times 0,7 \times 0,35 + 0,5 \times 0,9 \times 0,25} = 0,19$$

$$p(H_2|D_1D_3) = \frac{0,8 \times 0,7 \times 0,35}{0,3 \times 0,6 \times 0,4 + 0,8 \times 0,7 \times 0,35 + 0,5 \times 0,9 \times 0,25} = 0,52$$

$$p(H_3|D_1D_3) = \frac{0,5 \times 0,9 \times 0,25}{0,3 \times 0,6 \times 0,4 + 0,8 \times 0,7 \times 0,35 + 0,5 \times 0,9 \times 0,25} = 0,30$$

Elementy Sztucznej Inteligencji - wykład 8 30

Wnioski

→ Poprzez przedstawienie dowodu D1 i D3

- przekonanie o hipotezie H1 poważnie zmalało (0.34 do 0.19),
- dla H2 prawdopodobieństwo wzrosło (0.35 do 0.52),
- a H3 obniżyło się (0.32 do 0.30).

Elementy Sztucznej Inteligencji - wykład 8 31

Został zaobserwowany dowód D2

→ Analogicznie do sytuacji poprzednich przedstawiono kolejny dowód D2.

→ Będzie on miał wpływ na zmianę przekonania o wystąpieniu hipotez H1, H2 i H3.

$$p(H_1|D_1D_2D_3) = \frac{0,3 \times 0,9 \times 0,6 \times 0,4}{0,3 \times 0,9 \times 0,6 \times 0,4 + 0,8 \times 0 \times 0,7 \times 0,35 + 0,5 \times 0,7 \times 0,9 \times 0,25} = 0,45$$

$$p(H_2|D_1D_2D_3) = \frac{0,8 \times 0 \times 0,7 \times 0,35}{0,3 \times 0,9 \times 0,6 \times 0,4 + 0,8 \times 0 \times 0,7 \times 0,35 + 0,5 \times 0,7 \times 0,9 \times 0,25} = 0$$

$$p(H_3|D_1D_2D_3) = \frac{0,5 \times 0,7 \times 0,9 \times 0,25}{0,3 \times 0,9 \times 0,6 \times 0,4 + 0,8 \times 0 \times 0,7 \times 0,35 + 0,5 \times 0,7 \times 0,9 \times 0,25} = 0,55$$

Elementy Sztucznej Inteligencji - wykład 8 32

Wnioski

- Poprzez przedstawienie dowodu D2 sytuacja diametralnie się zmienia:
 - przekonanie o hipotezie H1 wzrasta (0.19 do 0.45),
 - hipoteza H2 jest nieprawdopodobna (0),
 - a H3 znacznie wzrosło (0.30 do 0.55).
- Zatem dla dowodów D1, D2, D3 najbardziej prawdopodobna jest hipoteza H3.

Elementy Sztucznej Inteligencji - wykład 8 33

L i O

- W niektórych zastosowaniach przekształca się wzór Bayes'a (1.11) stosując dwa współczynniki:
 - L (likelihood ratio) – wskaźnik wiarygodności,
 - O (odds ratio) – iloraz szans.
- Dzieląc wzór (1.11) przez odpowiednią formę dla hipotezy komplementarnej uzyskujemy (1.14):

$$\frac{p(H|D)}{p(\neg H|D)} = \frac{p(D|H) \times p(H)}{p(D|\neg H) \times p(\neg H)}$$

Elementy Sztucznej Inteligencji - wykład 8 34

Przekonanie o hipotezie H w nowym ujęciu

→ Iloraz szans to (1.15): $O(H) = \frac{p(H)}{p(\neg H)} = \frac{p(H)}{1 - p(H)}$

→ a wskaźnik wiarygodności (1.16): $L(D|H) = \frac{p(D|H)}{p(D|\neg H)}$

→ Zatem (1.17): $O(H|D) = \frac{p(H|D)}{p(\neg H|D)}$

→ A z (1.14) podstawiając (1.15), (1.16) i (1.17) wynika (1.18):

$$O(H|D) = L(D|H)O(H)$$

Elementy Sztucznej Inteligencji - wykład 8 35

Przykład

- W środku nocy budzi nas alarm informujący o włamaniu.
- Jaki jest stopień przekonania o włamaniu?
- Istnieje 95% szansy, że włamanie włączy alarm: $p(\text{alarm}|\text{włamanie})=0.95$.
- W oparciu o wcześniejsze fałszywe alarmy obliczono, że jest niewielka szansa (1%), że alarm włączył się bez przyczyny: $p(\text{alarm}|\text{nie włamanie})=0,01$.
- W oparciu o dane o przestępczości jest szansa 1 na 1000, że danej nocy do danego domu nastąpi włamanie: $p(\text{włamanie}) = 10^{-4}$

Elementy Sztucznej Inteligencji - wykład 8 36

Czy jest włamanie?

→ Korzystając z wzoru (1.18) uzyskujemy:

$$O(\text{włamanie} \mid \text{alarm}) = L(\text{alarm} \mid \text{włamanie})O(\text{włamanie}) = \frac{0.95 \cdot 10^{-4}}{0.01 \cdot 1 - 10^{-4}} = 0.0095$$

→ Z zależności (1.19) wyprowadzonej z (1.15):

$$p(A) = \frac{O(A)}{1 + O(A)}$$

→ uzyskujemy:

$$p(\text{włamanie} \mid \text{alarm}) = \frac{0.0095}{1 + 0.0095} = 0.00941$$

Elementy Sztucznej Inteligencji - wykład 8 37

Wnioski

→ Retrospektywne wsparcie dla hipotezy o włamaniu dawane przez dowód w postaci włączonego alarmu zostało wzmocnione ponad stukrotnie (0.0001 do 0.0094).

Elementy Sztucznej Inteligencji - wykład 8 38

Prognozowanie pogody

- **Zadanie**: określić czy będzie, lub czy nie będzie padał deszcz następnego dnia.
- Z biura prognozowania zebrane są dane:
 - minimalna temperatura w ciągu dnia,
 - maksymalna temperatura w ciągu dnia,
 - opady w mm,
 - liczba godzin słonecznych,
 - aktualny stan: pada lub nie pada.
- System prognozowania poda z jakim prawdopodobieństwem będzie padało lub nie będzie padało dnia następnego.

Elementy Sztucznej Inteligencji - wykład 8 39

Reguły główne

- Główne reguły z prawdopodobieństwem i wskaźnikami:
 1. IF dziś pada [LS=2,5 LN=0,6]
THEN jutro pada {p=0,5}
 2. IF dziś nie pada [LS=1,6 LN=0,4]
THEN jutro nie pada {p=0,5}

Elementy Sztucznej Inteligencji - wykład 8 40

Podział L na LS i LN

- Wprowadzamy podział wskaźnika wiarygodności L na LS i LN, gdzie (1.19) i (1.20):

$$LS(D|H) = \frac{p(D|H)}{p(D|\neg H)} \quad LN(D|H) = \frac{p(\neg D|H)}{p(\neg D|\neg H)}$$

- Współczynnik LS jest miarą ufności w hipotezę H, jeżeli przedstawiony został dowód D.
- $LS = p(\text{dziś pada} | \text{jutro pada}) / p(\text{dziś pada} | \text{jutro nie pada})$
- Współczynnik LN jest miarą pomniejszenia przekonania o hipotezie H, gdy brak dowodu D
- $LN = p(\text{dziś nie pada} | \text{jutro pada}) / p(\text{dziś nie pada} | \text{jutro nie pada})$
- LN nie może być wyprowadzony z LS i wartości te podawane są przez ekspertów lub z danych.

Elementy Sztucznej Inteligencji - wykład 8 41

Określanie wartości LN i LS

- Aby je określić **nie trzeba** opierać się na prawdopodobieństwie warunkowym.
- Wartości podawane są niezależnie:
- duże LS ($\gg 1$) silnie potwierdza hipotezę,
 - a niskie LN ($0 < LN < 1$) oznacza, że reguła silnie osłabia hipotezę, gdy nie ma dowodu D.
- Z LN i LS łatwo wyprowadzić prawdopodobieństwa warunkowe i zastosować regułę Bayes'a.
- W przykładzie:
- $LS=2,5$ oznacza, że jeżeli dziś pada, to z dużym prawdopodobieństwem będzie padać jutro,
 - $LN=0,6$ oznacza, że istnieje szansa, że pomimo, że dziś nie pada to jutro będzie padać.

Elementy Sztucznej Inteligencji - wykład 8 42

Iloraz szans dla LN i LS

- Rewidując wzór (1.18) z zastosowaniem (1.19) i (1.20) uzyskujemy:

$$O(H|D) = LS \times O(H),$$

$$O(H|\neg D) = LN \times O(H)$$

- Poszukiwane prawdopodobieństwa oblicza się zatem:

$$p(H|D) = \frac{O(H|D)}{1 + O(H|D)},$$

$$p(H|\neg D) = \frac{O(H|\neg D)}{1 + O(H|\neg D)}$$

Elementy Sztucznej Inteligencji - wykład 8 43

Przykład: odpalenie reguły 1

- Dowód D: Dziś pada.
→ Reguła 1 jest odpalana i prawdopodobieństwa są użyte do obliczenia szansy wystąpienia deszczu:

$$O(\text{jutro pada}) = \frac{0,5}{1 - 0,5} = 1$$

- Dowód D zwiększa szansę na opad przez wskaźnik wiarygodności $LS=2,5$

$$O(\text{jutro pada} | \text{dziś pada}) = 2,5 \times 1 = 2,5$$

$$p(\text{jutro pada} | \text{dziś pada}) = \frac{2,5}{1 + 2,5} = 0,71$$

- Wniosek: Prawdopodobieństwo jutrzejszego opadu wzrasta z 0,5 do 0,71 poprzez przedstawienie dowodu D.

Elementy Sztucznej Inteligencji - wykład 8 44

Przykład: odpalenie reguły 2

- Dowód D: Dziś pada.
- Reguła 2 jest odpalana i prawdopodobieństwa są użyte do obliczenia szansy, że jutro nie będzie padać:

$$O(\text{jutro nie pada}) = \frac{0,5}{1-0,5} = 1$$

- Dowód D wpływa hipotezę, że jutro nie będzie padało ze współczynnikiem $LN=0,4$

$$O(\text{jutro nie pada} | \text{dziś pada}) = 0,4 \times 1 = 0,4$$

$$p(\text{jutro nie pada} | \text{dziś pada}) = \frac{0,4}{1+0,4} = 0,29$$

- Wniosek: prawdopodobieństwo, że jutro nie będzie padać, gdy dziś pada jest 0,29, czyli zmniejszyło się z powodu zaistnienia D.

Elementy Sztucznej Inteligencji - wykład 8 45

Przykład: D = Dziś nie pada.

- W analogiczny sposób oblicza się prawdopodobieństwa, że jutro nie będzie padać, lub będzie deszczowo, gdy dowód D mówi, że dziś nie pada.
- Wyniki dla obu reguł to:
 - 62% szans, że nie będzie padać, gdy dziś nie pada.
 - 38% szans, że będzie padało, gdy dziś nie padało.

Elementy Sztucznej Inteligencji - wykład 8 46

Dodajemy kolejne reguły

- Powiększamy naszą bazę wiedzy na temat prognozowania pogody o inne parametry.
- Wskaźniki są uzyskiwane poprzez analizę danych zbieranych z lat poprzednich. Pewne zależności są widoczne i można je ująć w reguły, które uszczegółowią analizę i sprawią, że wnioskowanie będzie bardziej wiarygodne.

Elementy Sztucznej Inteligencji - wykład 8 47

Zestaw reguł

1. IF dziś pada [LS=2,5 LN=0,6]
THEN jutro pada {p=0,5}
2. IF dziś nie pada [LS=1,6 LN=0,4]
THEN jutro nie pada {p=0,5}
3. IF dziś pada
AND wilgotność jest niska [LS=10 LN=1]
THEN jutro nie pada {p=0,5}

Elementy Sztucznej Inteligencji - wykład 8 48

Zestaw reguł cd.

4. IF dziś pada
AND wilgotność jest niska
AND temperatura jest niska [LS=1,5 LN=1]
THEN jutro nie pada {p=0,5}
5. IF dziś nie pada
AND temperatura jest wysoka [LS=2 LN=0,9]
THEN jutro pada {p=0,5}
6. IF dziś nie pada
AND temperatura jest wysoka
AND niebo jest pochmurne [LS=5 LN=1]
THEN jutro pada {p=0,5}

Elementy Sztucznej Inteligencji - wykład 8 49

Działanie systemu wnioskowania – dialog

→ Jaka jest dziś pogoda?

→ Odp: **PADA**

→ **Obliczenia** (przedstawione na slajdach (41-42)):

- na podstawie reguły 1:
 - $p(\text{jutro pada} \mid \text{dziś pada})=0,71$
- na podstawie reguły 2:
 - $p(\text{jutro nie pada} \mid \text{dziś pada})=0,29$

→ **Wniosek**: jutro: pada [0,71], nie pada [0,29]

Elementy Sztucznej Inteligencji - wykład 8 50

Działanie systemu wnioskowania – dialog cd.

→ Jaka jest dziś wilgotność?

→ Odp: **NISKA**

→ Obliczenia:

- na podstawie reguły 3 (prawdopodobieństwo opadu pobrane z poprzedniego kroku (0,29)):

$$O(\text{jutro nie pada}) = \frac{0,29}{1-0,29} = 0,41$$

$$O(\text{jutro nie pada} | \text{dzis pada} \cap \text{niska wilgotnosc}) = 10 \cdot 0,41 = 4,1$$

$$p(\text{jutro nie pada} | \text{dzis pada} \cap \text{niska wilgotnosc}) = \frac{4,1}{1+4,1} = 0,81$$

→ Wniosek: jutro: pada [0,71], nie pada [0,81]

Elementy Sztucznej Inteligencji - wykład 8 51

Działanie systemu wnioskowania – dialog cd.

→ Jaka jest dziś temperatura?

→ Odp: **NISKA**

→ Obliczenia:

- na podstawie reguły 4 (LS): $O(\text{jutro nie pada}) = \frac{0,81}{1-0,81} = 4,26$

$$O(\text{jutro nie pada} | \text{dzis pada} \cap \text{niska wilgotnosc} \cap \text{niskatemp}) = 1,5 \cdot 4,26 = 6,4$$

$$p(\text{jutro nie pada} | \text{dzis pada} \cap \text{niska wilgotnosc} \cap \text{niskatemp}) = \frac{6,4}{1+6,4} = 0,86$$

- na podstawie reguły 5 (LN): $O(\text{jutro pada}) = \frac{0,71}{1-0,71} = 2,45$

$$O(\text{jutro pada} | \text{dzis pada} \cap \text{niskatemp}) = 0,9 \cdot 2,45 = 2,2$$

$$p(\text{jutro pada} | \text{dzis pada} \cap \text{niskatemp}) = \frac{2,2}{1+2,2} = 0,69$$

→ Wniosek: jutro: pada [0,69], nie pada [0,86]

Elementy Sztucznej Inteligencji - wykład 8 52

Działanie systemu wnioskowania – dialog cd.

→ Jakie jest niebo?

→ Odp: **NIEZACHMURZONE**

→ Obliczenia:

na podstawie reguły 6 (LN): $O(\text{jutro pada}) = \frac{0,69}{1-0,69} = 2,23$

$O(\text{jutro pada} | \text{dzis pada} \cap \text{niska wilgotnosc} \cap \text{niska temp} \cap \text{niebo pochmurne}) = 2,23 \times 1 = 2,23$

$p(\text{jutro pada} | \text{dzis pada} \cap \text{niska wilgotnosc} \cap \text{niska temp} \cap \text{niebo pochmurne}) = \frac{2,23}{1+2,23} = 0,69$

→ Wniosek: jutro: pada [0,69], nie pada [0,86]

Elementy Sztucznej Inteligencji - wykład 8 53

Zastosowanie (Mozilla)

→ Autor Paul Graham – filtr do spamu.

→ Filtr oparty jest na wnioskowaniu Bayes'a.

→ Użytkownik wskazuje wiadomości typu spam i normalne (dwie klasy) i na ich podstawie tworzone są wagi dla słów oparte na prawdopodobieństwie.

→ Skuteczność jest niezwykle wysoka:

- program przepuścił 5 na 1000 wiadomości typu spam,
- nie odrzucił żadnej z dobrych wiadomości.

Elementy Sztucznej Inteligencji - wykład 8 54

Jak to działa?

- Podział wiadomości na dwie klasy:
 1. dobre
 2. spam.
- Skanowanie całego tekstu (cała wiadomość z nagłówkami, osadzony html i javascript) i wyluskiwanie tokenów, odrzucane:
 - separatory,
 - wartości całkowite liczbowe,
 - komentarze z html'a.
- Zliczenie wystąpień każdego tokena i obliczenie prawdopodobieństwa jego wystąpienia:
 - liczba dobrych tokenów jest podwajana, by nie wpadały przez przypadek jako spam,
 - rozważane są słowa, które pojawiły się więcej niż 5 razy,
 - prawdopodobieństwo a priori pojawienia się słowa w jednym bloku, ale nie w drugim jest 0,01 i 0,99.

Elementy Sztucznej Inteligencji - wykład 8 55

Jak to działa?

- Jeżeli pojawi się nowa wiadomość, to jest skanowana. Pobieranych jest 15 najbardziej interesujących tokenów, przy czym interesujący znaczy daleki od neutralnej wartości (spam czy nie spam), czyli 0.5.
- Oblicza się łączne prawdopodobieństwo 15 tokenów i otrzymuje odpowiedź.
- Słowa, które nigdy się nie pojawiły mają przypisane prawdopodobieństwo 0.4 (czyli zakładamy, że jest niewinny i nie pochodzi ze spamu.)
- Mail traktowany jest jako spam, gdy prawdopodobieństwo, że jest podejrzan jest większe od 0.9

Elementy Sztucznej Inteligencji - wykład 8 56

Zalety

- Nie trzeba czytać dużej liczby spamu, by określić filtry.
- Metoda bierze pod uwagę wszystkie dowody za i przeciw.
- Dla każdego użytkownika można policzyć prawdopodobieństwo występowania tokenów dla jego indywidualnych i wybranych wiadomości.
- Nie musi być łączony z białą listą (listą adresów, z których akceptujemy wiadomości).
- Ewoluuje wraz ze spamem. Zmiany w mailach powodują zmiany w statystykach.

Elementy Sztucznej Inteligencji - wykład 8 57

Przykład

- madam 0.99
- promotion 0.99
- republic 0.99
- shortest 0.047225013
- mandatory 0.047225013
- standardization 0.07347802
- sorry 0.08221981
- supported 0.09019077
- people's 0.09019077
- enter 0.9075001
- quality 0.8921298
- organization 0.12454646
- investment 0.8568143
- very 0.14758544
- valuable 0.82347786

Słówka "madam" czy "promotion" przyczyniają się do oceny na korzyść spamu a słówko „shortest” wręcz przeciwnie.

Jednak przewaga jest słów z prawdopodobieństwem wskazującym na spam.

Reguła Bayes'a dała temu mailowi miarę 0.9027, czyli **spam**

Elementy Sztucznej Inteligencji - wykład 8 58

Metody oparte na współczynniku wiarygodności

- Alternatywa dla wnioskowania Bayes'a.
- **MYCIN** – system, w którym wprowadzono współczynniki wiarygodności – jest to medyczny system ekspertowy określający siłę przekonania o wiarygodności hipotezy nie oparty na logicznych i matematycznych zależnościach między danymi. Jego przeznaczeniem było stawianie diagnozy i wyznaczanie terapii przy chorobach krwi.
- Zastosowanie, gdy brak spójnych danych statystycznych.
- Naśladują procesy myślowe przy wnioskowaniu prowadzonym przez eksperta - człowieka.

Elementy Sztucznej Inteligencji - wykład 8 59

Współczynnik wiarygodności

- Współczynnik wiarygodności – **cf** – jest miarą przekonań eksperta.
- Ma wartość z przedziału **-1 (fałsz)** do **1 (prawda)**.
- Wartości >0 są miarą przekonania o hipotezie.
- Wartości <0 są miarą braku przekonania o hipotezie.

Elementy Sztucznej Inteligencji - wykład 8 60

Reguły w systemie dowodzenia

- Reguły mają postać:
IF D <dowód>
THEN H <hipoteza> {cf}
- cf jest miarą ufności w hipotezę H, gdy dany jest dowód D.

Elementy Sztucznej Inteligencji - wykład 8 61

MB (measure of belief)

- Wykorzystuje się dwie funkcje oceny (mają wartości od 0 do 1):

- miara przekonania o hipotezie H oparta o prawdopodobieństwo: MB(H,D):

$$MB(H, D) = \begin{cases} 1 & \text{if } p(H) = 1 \\ \frac{p(H|D) - p(H)}{1 - p(H)} & \text{otherwise} \end{cases}$$

- Ekspert ocenia jak bardzo przedstawiony dowód D redukuje jego wątpliwości w wypadku braku dowodu ($1 - p(H)$).
- Jeżeli dowód jest słaby, to $p(H|D) - p(H)$ jest bliskie 0 i jego wątpliwości nie ulegną zmianie.

Elementy Sztucznej Inteligencji - wykład 8 62

MD (measure of disbelief)

- miara braku przekonania w hipotezę H w oparciu o prawdopodobieństwo: $MD(H,D)$:

$$MD(H, D) = \begin{cases} 1 & \text{if } p(H) = 0 \\ \frac{p(H) - p(H|D)}{p(H)} & \text{otherwise} \end{cases}$$

- Ekspert ocenia jak bardzo przedstawiony dowód D redukuje jego przekonanie o hipotezie $p(H)$.
- $p(H)$ prawdopodobieństwo a priori, że H jest TRUE,

Elementy Sztucznej Inteligencji - wykład 8 63

Całkowity współczynnik

→ W oparciu o MB i MD wyznaczamy cf :

$$cf = \frac{MB(H, D) - MD(H, D)}{1 - \min[MB(H, D), MD(H, D)]}$$

→ stąd cf ma wartości z zakresu -1 do 1 , które oznacza całkowite przekonanie o hipotezie H.

Elementy Sztucznej Inteligencji - wykład 8 64

Jak działa MYCIN?

- Najczęściej reguły są złożone, tzn. że zaobserwowanie pewnej wartości może pociągać różne wyniki:
IF A jest X
THEN B jest Y {cf 0,7}
 B jest Z {cf 0,2}
- Oznacza, to że w 10% wypadków nie wiemy jaka jest odpowiedź – jest to wartość (odpowiedź), której dotychczas nie zaobserwowano.

Elementy Sztucznej Inteligencji - wykład 8 65

Obliczanie *cf* – pojedynczy dowód

- $cf(H,D)$ dla reguły z jednym dowodem oblicza się jako mnożenie $cf(D)$ dowodu i cf reguły:

$$cf(H, D) = cf(D) \times cf$$

- Przykład:
IF niebo czyste
THEN prognozujemy słońce {cf 0.8}
 $cf(D)$ dla czyste niebo to 0.5
zatem $cf(H,D)=0.5*0.8=0.4$
co czytamy, że „może być słonecznie”.

Elementy Sztucznej Inteligencji - wykład 8 66

Obliczanie *cf* przy koniunkcji wielu dowodów

→ Zasady:

IF <dowód D1>
AND <dowód D2> ...
AND <dowód Dn>
THEN <hipoteza> {*cf*}

→ to:

$$cf(H, D_1 \cap D_2 \cap \dots \cap D_n) = \min[cf(D_1), cf(D_2), \dots, cf(D_n)] \times cf$$

→ Przykład:

IF niebo czyste
AND prognozujemy słońce
THEN noś okulary {*cf* 0.8},
gdzie: $cf(D1)=0,9$ i $cf(D2)=0,7$

$$cf(H, D_1 \cap D_2) = \min[0,9,0,7] \times 0,8 = 0,56$$

Elementy Sztucznej Inteligencji - wykład 8 67

Obliczanie *cf* przy dysjunkcji wielu dowodów

→ Zasady:

IF <dowód D1>
OR <dowód D2>...
OR <dowód Dn>
THEN <hipoteza> {*cf*}

→ to:

$$cf(H, D_1 \cup D_2 \cup \dots \cup D_n) = \max[cf(D_1), cf(D_2), \dots, cf(D_n)] \times cf$$

→ Przykład:

IF niebo zachmurzone
OR prognozujemy deszcz
THEN weź parasol {*cf* 0.9},
gdzie: $cf(D1)=0,6$ $cf(D2)=0,8$

$$cf(H, D_1 \cup D_2) = \max[0,6,0,8] \times 0,9 = 0,72$$

Elementy Sztucznej Inteligencji - wykład 8 68

Obliczanie cf , gdy wiele zdarzeń wpływa na tą sam hipotezę

→ Zasady:

IF A jest X
THEN B jest Y { cf_1 }
IF C jest Z
THEN B jest Y { cf_2 }

→ to:

$$cf(cf_1, cf_2) = \begin{cases} cf_1 + cf_2 \times (1 - cf_1) & \text{if } cf_1 > 0 \text{ and } cf_2 > 0 \\ \frac{cf_1 + cf_2}{1 - \min[|cf_1|, |cf_2|]} & \text{if } cf_1 > 0 \text{ or } cf_2 > 0 \\ cf_1 + cf_2 \times (1 + cf_1) & \text{if } cf_1 < 0 \text{ and } cf_2 < 0 \end{cases}$$

→ Przykład: $cf(D1) = cf(D2) = 1.0$

$$cf_1(H, D1) = 1 * 0.8 = 0.8$$

$$cf_2(H, D2) = 1 * 0.6 = 0.6$$

$$cf(cf_1, cf_2) = cf_1 + cf_2 * [1 - cf_1] = 0.92$$

Elementy Sztucznej Inteligencji - wykład 8 69

Analiza wzoru

→ Jeżeli wiele zdarzeń wpływa na tą samą hipotezę, to:

- jeżeli oba zdarzenia wzmacniają przekonanie o hipotezie przekonanie wzrasta przy złożeniu obu warunków,
- jeżeli jedno zdarzenie wzmacnia, a drugie osłabia przekonanie o hipotezie to całkowity współczynnik wiarygodności zmniejszy się,
- jeżeli oba zdarzenia osłabiają hipotezę to ich złożenie da jeszcze bardziej osłabiający współczynnik wiarygodności.

Elementy Sztucznej Inteligencji - wykład 8 70

Przykład dla prognozowania pogody- reguły

1. IF dziś pada
THEN jutro pada { $cf=0,5$ }
2. IF dziś nie pada
THEN jutro nie pada { $cf=0,5$ }
3. IF dziś pada
AND wilgotność jest niska
THEN jutro nie pada { $cf=0,6$ }

Elementy Sztucznej Inteligencji - wykład 8 71

Przykład dla prognozowania pogody- reguły

4. IF dziś pada
AND wilgotność jest niska
AND temperatura jest niska
THEN jutro nie pada { $cf=0,7$ }
5. IF dziś nie pada
AND temperatura jest wysoka
THEN jutro pada { $cf=0,65$ }
6. IF dziś nie pada
AND temperatura jest wysoka
AND niebo jest pochmurne
THEN jutro pada { $cf=0,55$ }

Elementy Sztucznej Inteligencji - wykład 8 72

Działanie systemu wnioskowania – dialog

- Jaka jest dziś pogoda?
- Odp: **PADA**
- Obliczenia:
 - na podstawie reguły 1:
 - $cf(\text{jutro pada}, \text{dziś pada}) = 1 * 0,5 = 0,5$
- Wnioski:
 - jutro: pada [0,5]

Elementy Sztucznej Inteligencji - wykład 8 73

Działanie systemu wnioskowania – dialog cd.

- Jaka jest dziś wilgotność?
- Odp: **NISKA**
- Jaka jest stopień wilgotności podaj współczynnik od 0 do 1?
- Odp: **0.8**
- Odpowiedzi:
 - na podstawie reguły 3:
$$cf(\text{jutro nie pada}, \text{dzis pada} \cap \text{niska wilgotnosc}) =$$
$$= \min[cf(\text{dzis pada}), cf(\text{niska wilgotnosc})] \times cf =$$
$$= \min[1, 0.8] \times 0.6 = 0.48$$
- Wniosek: jutro: pada [0,5], nie pada [0,48]

Elementy Sztucznej Inteligencji - wykład 8 74

Działanie systemu wnioskowania – dialog cd.

- Jaka jest dziś temperatura?
- Odp: **NISKA**
- Jaka jest stopień wiarygodności stwierdzenia, że temperatura jest niska?
- Odp: **0.9**
- Obliczenia:
 - na podstawie reguły 4:
 $cf(\text{jutro nie pada, dzis pada} \cap \text{niska wilgotnosc} \cap \text{niska temp}) =$
 $= \min[cf(\text{dzis pada}), cf(\text{niska wilgotnosc}), cf(\text{niska temp})] \times cf =$
 $= \min[1, 0.8, 0.9] \times 0.7 = 0.56$
- **Wniosek:** jutro: pada [0,50], nie pada [0,56]

Elementy Sztucznej Inteligencji - wykład 8 75

Działanie systemu wnioskowania – dialog cd.

- Złożenie reguł 3 i 4 w ocenie hipotezy nie pada:

$$\begin{aligned} cf(cf_{regula3}, cf_{regula4}) &= cf_{regula3} + cf_{regula4} \times (1 - cf_{regula3}) \\ &= 0.48 + 0.56 \times (1 - 0.48) = 0.77 \end{aligned}$$

- **Wniosek:** jutro: pada [0,50], nie pada [0,77]

Elementy Sztucznej Inteligencji - wykład 8 76

Porównanie wnioskowanie Bayes'a i współczynnik wiarygodności

- Zastosowanie: planowanie, prognozowanie, tam gdzie dostępne są dane statystyczne.
- Przykład działającego systemu: PROSPECTOR – geologia.
- Matematycznie poprawny (teoria prawdopodobieństwa).
- Zastosowanie: planowanie, prognozowanie, tam gdzie brak danych statystycznych.
- Przykład działającego systemu: MYCIN – medycyna.
- Brak matematycznej poprawności. Dane pochodzą z ocen ekspertów z dziedziny.

Elementy Sztucznej Inteligencji - wykład 8 77

Cechy wspólne

- Propagowanie przekonań wzrasta wykładniczo, dlatego nie nadaje się dla bardzo dużych baz wiedzy.
- Problemem jest znalezienie właściwej metody określania prawdopodobieństw i współczynników, ponieważ ludzie są tendencyjni w ocenach.

Elementy Sztucznej Inteligencji - wykład 8 78