Uczenie maszynowe

Jest konieczne w nieznanym środowisku, tj. gdy projektant systemu nie posiada wszechwiedzy

Jest przydatne jako metoda konstrukcji systemu, tj. konfrontuje agenta z rzeczywistością zamiast próby napisania jego programu

Modyfikuje mechanizm decyzyjny agenta, aby poprawić wydajność

Wszystkie typy uczenia mogą byc rozważane jako uczenie reprezentacji funkcji.

Uczenie indukcyjne

Element uczący otrzymuje poprawną wartość funkcji dla poszczególnych danych wejściowych i na tej podstawie modyfikuje reprezentację funkcji tak, aby pasowała do dostarczonej informacji.

Formalnie:
Obiekty: dane opisujące stan lub obiekt; tworzą przestrzeń obiektów X.

Decyzja: Funkcja $dec : X \to V_{dec}$ przypisująca obiektom ze zbioru X wartość decyzji z ustalonego zbioru V_{dec}.

Zbiór przykładów: Ustalony zbiór obiektów z X z przypisanymi wartościami decyzji: tj. zbiór par $(x_i, dec(x_i))$ dla $i = 1, \ldots, n$.

Zadanie: Z danego zbioru przykładów nauczyć się funkcji (hipotezy) $h : X \to V_{dec}$ aproksymującej decyzję dec tak, aby możliwie *najbardziej poprawnie* przypisywała ją obiektom z przestrzeni X, dla których nieznana jest wartość decyzji dec.

Przykład – kółko i krzyżyk

Uczenie funkcji z przykładów (*tabula rasa)*

f *jest* funkcją docelową

Przykład to para $(x, f(x))$, *tj.*, $\begin{array}{|c|c|c|}\hline O & O & X \\ \hline & X & \\ \hline X & & \\ \hline\end{array}$, $+1$

Problem: znaleźć hipotezę h
taką że $h \approx f$
dla danego zbioru przykładów

Hipoteza h *jest* spójna *na zbiorze* $\{(x_1, dec(x_1)), \ldots, (x_n, dec(x_n))\}$ *jeśli*

$h(x_i) = dec(x_i)$ *dla każdego* $1 \leq i \leq n$

Rodzaje decyzji

Decyzja może przyjmować wartości:

- rzeczywiste
- dyskretne
- binarne (TRUE, fALSE)

Przestrzeń hipotez

W ogólności może być wiele hipotez dla tego samego zbioru przykładów.

Ile jest różnych hipotez (funkcji) binarnych dla n atrybutów binarnych?

= liczba funkcji binarnych dla dziedziny z 2^n obiektami = 2^{2^n}

Przestrzeń hipotez można ograniczyć do ustalonej klasy hipotez.

Z drugiej strony zwiększanie przestrzeni hipotez:

- zwiększa szansę, że funkcja docelowa może być wyrażona
- zwiększa liczbę hipotez zgodnych ze zbiorem przykładów

Empiryczna miara jakości hipotezy

Sposób postępowania:

- Dane X dzielimy na dwa podzbiory – *zbiór treningowy* Z_{trn} i *zbiór testowy* Z_{tst}.
- Hipoteza $h : X \to V_{dec}$ jest indukowana na podstawie zbioru treningowego Z_{trn}.
- *Skuteczność* hipotezy $Acc(h)$ jest mierzona proporcją poprawnie sklasyfikowanych obiektów ze zbioru testowego do rozmiaru zbioru testowego, tj.

$$Acc(h) = \frac{\mid \{x \in Z_{tst} : h(x) = dec(x)\} \mid}{\mid Z_{tst} \mid}$$

Stosowane podejścia

Zależą od reprezentacji modułu decyzyjnego agenta:

1. drzewa decyzyjne
2. wnioskowanie oparte na podobieństwie - k najbliższych sąsiadów
3. sieci neuronowe
4. sieci bayessowskie
5. systemy regułowe

Drzewa decyzyjne

Wejście: obiekt lub stan opisany przez zbiór własności (atrybutów).

Wyjście: decyzja tak/nie (wartości wyjściowych może być więcej).

Opisują funkcje boolowskie.

Reprezentacja:

Węzły wewnętrzne: Każdy związany z jednym atrybutem - reprezentuje test wartości tego atrybutu.

Gałęzie: Każda związana z wartością lub podzbiorem wartości atrybutu węzła, z którego wychodzi - odpowiada obiektom danych z pasującymi wartościami atrybutu.

Liście: Każdy związany z decyzją lub rozkładem decyzji - odpowiada obiektom danych pasującym do ścieżki prowadzącej do danego liścia.

Przykład

Example	Attributes											Target
	Alt	*Bar*	*Fri*	*Hun*	*Pat*	*Price*	*Rain*	*Res*	*Type*	*Est*	*WillWait*
X_1	*T*	*F*	*F*	*T*	*Some*	\$\$\$	*F*	*T*	*French*	*0–10*	*T*
X_2	*T*	*F*	*F*	*T*	*Full*	\$	*F*	*F*	*Thai*	*30–60*	*F*
X_3	*F*	*T*	*F*	*F*	*Some*	\$	*F*	*F*	*Burger*	*0–10*	*T*
X_4	*T*	*F*	*T*	*T*	*Full*	\$	*F*	*F*	*Thai*	*10–30*	*T*
X_5	*T*	*F*	*T*	*F*	*Full*	\$\$\$	*F*	*T*	*French*	*>60*	*F*
X_6	*F*	*T*	*F*	*T*	*Some*	\$\$	*T*	*T*	*Italian*	*0–10*	*T*
X_7	*F*	*T*	*F*	*F*	*None*	\$	*T*	*F*	*Burger*	*0–10*	*F*
X_8	*F*	*F*	*F*	*T*	*Some*	\$\$	*T*	*T*	*Thai*	*0–10*	*T*
X_9	*F*	*T*	*T*	*F*	*Full*	\$	*T*	*F*	*Burger*	*>60*	*F*
X_{10}	*T*	*T*	*T*	*T*	*Full*	\$\$\$	*F*	*T*	*Italian*	*10–30*	*F*
X_{11}	*F*	*F*	*F*	*F*	*None*	\$	*F*	*F*	*Thai*	*0–10*	*F*
X_{12}	*T*	*T*	*T*	*T*	*Full*	\$	*F*	*F*	*Burger*	*30–60*	*T*

Drzewo decyzyjne

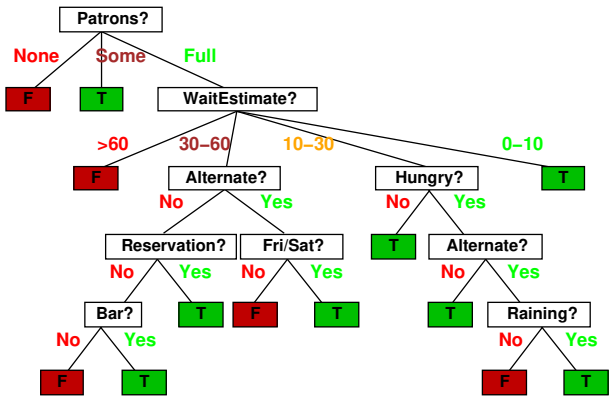

Drzewa decyzyjne– moc wyrażania

Dla każdego zbioru przykładów istnieje spójne drzewo decyzyjne – jedna ścieżka do liścia dla każdego przykładu (chyba, że f jest niedeterministyczna).

A	B	A xor B
F	F	F
F	T	T
T	F	T
T	T	F

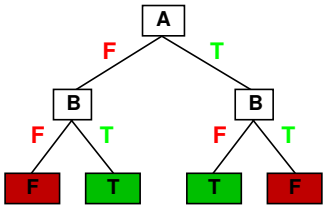

Zadanie:
Szukanie bardziej zwartego drzewa decyzyjnego.

Uczenie drzewa decyzyjnego

Cel: znalezienie małego drzewa zgodnego ze zbiorem treningowym.

Pomysł: rekurencyjne wybieranie najbardziej znaczącego atrybutu jako korzenia poddrzewa.

function DECISION-TREE-LEARNING(*examples*, *attributes*, *default*) **returns** a decision tree
  inputs: *examples*, set of examples
    attributes, set of attributes
    default, default value for the goal predicate

  if *examples* is empty **then return** *default*
  else if all *examples* have the same classification **then return** the classification
  else if *attributes* is empty **then return** MAJORITY-VALUE(*examples*)
  else
    best ← CHOOSE-ATTRIBUTE(*attributes*, *examples*)
    tree ← a new decision tree with root test *best*
    for each value v_i of *best* **do**
      $examples_i$ ← {elements of *examples* with $best = v_i$}
      subtree ← DECISION-TREE-LEARNING($examples_i$, *attributes* − *best*,
                MAJORITY-VALUE(*examples*))
      add a branch to *tree* with label v_i and subtree *subtree*
    end
    return *tree*

$Patrons?$ jest lepszym wyborem – daje **informację** o klasyfikacji.

Informacja

Rozwiązaniem jest informacja.

Im większa ignorancja w kwestii odpowiedzi na początku, tym więcej informacji zawiera odpowiedź.

Skala: 1bit = odpowiedź na pytanie boolowskie z prawdopodobieństwem $\langle 0.5, 0.5 \rangle$

Wybór atrybutu

Idea: dobry atrybut rozdziela przykłady na podzbiory, których elementy są wszystkie "pozytywne" lub wszystkie "negatywne".

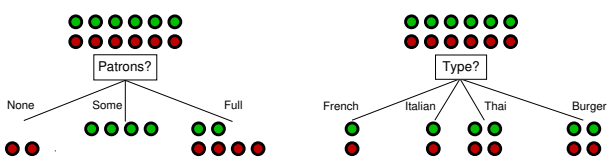

Entropia

Dany jest rozkład prawdopodobieństwa

$$\langle P_1, \ldots, P_n \rangle.$$

Miara informacji (*entropia prawdopodobieństwa*) wyznacza ile informacji niesie ten rozkład

$$H(\langle P_1, \ldots, P_n \rangle) = \Sigma_{i=1}^{n} - P_i \log_2 P_i$$

S –zbiór danych
S_d –zbiór obiektów z decyzją d

$$H(S) = \Sigma_{d \in V_{dec}} - \frac{\mid S_d \mid}{\mid S \mid} log_2 \frac{\mid S_d \mid}{\mid S \mid}$$

Entropia = średnia liczba bitów potrzebna do zakodowania decyzji d dla losowo wybranego obiektu ze zbioru S. Optymalne kodowanie przydziela $-log_2 p$ bitów do decyzji występującej z prawdopodobieństwem p.

Entropia: przypadek 2 decyzji

Dane są dwie decyzje: pozytywna (+) i negatywna (-)

$p_+ = \frac{|S_+|}{|S|}$ – częstość obiektów z decyzją pozytywną w S

$p_- = \frac{|S_-|}{|S|}$ – częstość obiektów z decyzją negatywną w S

$$H(S) = -p_+ log_2 p_+ - p_- log_2 p_-$$

Zysk informacji

Zysk informacji $G(S, a)$=
redukcja entropii przy podziale zbioru względem atrybutu a.

S_v – zbiór obiektów w S z wartością atrybutu $a = v$

$$G(S, a) = H(S) - \Sigma_{v \in Value(a)} \frac{\mid S_v \mid}{\mid S \mid} H(S_v)$$

Przykład cd.

Drzewo decyzyjne wyuczone z 12 przykładów

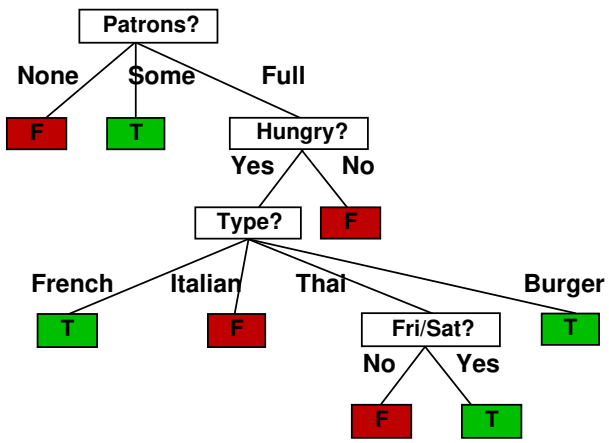

Miara efektywności.

Skąd wiadomo, że $h \approx f$

1) Teoria obliczeń/ statystyka
2) Testowanie funkcji h na nowym zbiorze testowym

Krzywa uczenia = % poprawności na zbiorze testowym jako funkcja jego rozmiaru

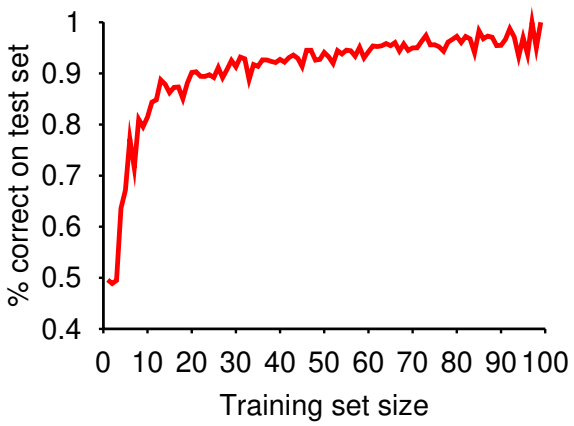

Miara efektywności cd.

Krzywa uczenia zależy od

- realizowalności (wyrażalność funkcji docelowej) vs. nierealizowalności (spowodowanej np. brakiem atrybutu lub nadmiernych ograniczeniem klasy hipotez)
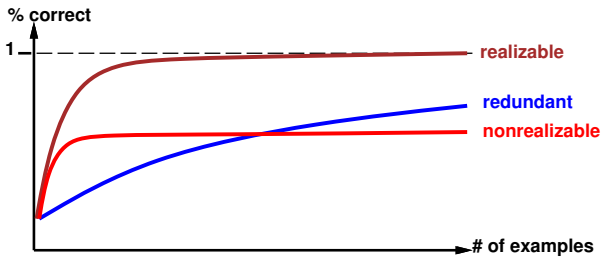
- redundancji w wyrażalności (np. nierelewantne atrybuty)