

Elementy Modelowania Matematycznego

Wykład 5

Drzewa decyzyjne

Romuald Kotowski

Katedra Informatyki Stosowanej

PJWSTK 2009

Spis treści

- 1 Drzewa decyzyjne jako hipotezy
- 2 Zstępujące konstruowanie drzewa

Spis treści

- 1 Drzewa decyzyjne jako hipotezy
- 2 Zstępujące konstruowanie drzewa

Drzewa decyzyjne jako hipotezy

Wstęp

Koncepcja drzew decyzyjnych polega na reprezentowaniu sekwencji warunków wpływających na ostateczną decyzję przez ścieżki łączące korzeń drzewa z jego liśćmi wzdłuż kolejnych węzłów, odpowiadających sprawdzanym warunkom, i gałęzi, odpowiadających wynikom uzyskanym z ich sprawdzenia. Ma ona zastosowanie w różnych dziedzinach, jest stosowana w sposób naturalny i bez obaw o jej intuicyjną oczywistość dla człowieka, który stara się wiedzę reprezentowaną w ten sposób posługiwać.

Drzewa decyzyjne jako hipotezy

Struktura drzewa

Drzewa decyzyjne to struktura:

- węzły, z których wychodzą gałęzie prowadzące do innych węzłów lub liści
- liście, z których nie wychodzą żadne gałęzie

Definicja formalna: drzewo to dowolny spójny skierowany graf acykliczny, przy czym krawędzie takiego grafu są nazywane gałęziami, wierzchołki, z których wychodzi co najmniej jedna krawędź, są nazywane węzłami, a pozostałe wierzchołki - liśćmi.

Drzewa decyzyjne jako hipotezy

Struktura drzewa

Drzewo decyzyjne ma jeszcze dodatkową interpretację:

- węzły – testy przeprowadzane na wartościach atrybutów przykładów
- gałęzie – możliwe wyniki tych testów
- liście – etykiety kategorii
- korzeń – nie ma żadnych węzłów macierzystych

Drzewa decyzyjne jako hipotezy

Definicja rekurencyjna

X – dziedzina, na której są określone atrybuty a_1, a_2, \dots, a_n ,

\mathcal{C} – klasa pojęć o zbiorze kategorii C

- 1 liść zawierający dowolną etykietę kategorii $d \in C$ jest drzewem decyzyjnym
- 2 jeśli $t : X \mapsto R_t$ jest testem przeprowadzonym na wartościach atrybutów przykładów o zbiorze możliwych wyników $R_t = \{r_1, r_2, \dots, r_m\}$ oraz $\mathbb{T}_1, \mathbb{T}_2, \dots, \mathbb{T}_m$ są drzewami decyzyjnymi, to węzeł zawierający test t z którego wychodzi m gałęzi, przy czym dla $i = 1, 2, \dots, m$ gałąź i -ta odpowiada wynikowi r_i , i prowadzi do drzew \mathbb{T}_i , jest drzewem decyzyjnym.

Drzewa decyzyjne jako hipotezy

Notacja dla drzew decyzyjnych

$N_{\mathbb{T}}$ – zbiór węzłów drzewa decyzyjnego \mathbb{T}

$L_{\mathbb{T}}$ – zbiór liści drzewa decyzyjnego \mathbb{T}

- 1 Przykład $x \in X$ odpowiada liściowi (jest związany z liściem) $l \in L_{\mathbb{T}}$ drzewa decyzyjnego \mathbb{T} , jeśli w procesie klasyfikacji przykładu x za pomocą drzewa \mathbb{T} osiągnąony jest ten liść.
- 2 Przykład $x \in X$ odpowiada węzłowi (jest związany z węzłem) $n \in N_{\mathbb{T}}$ drzewa decyzyjnego \mathbb{T} , jeśli węzeł ten znajduje się na ścieżce łączącej korzeń drzewa z liściem odpowiadającym przykładowi x .

Drzewa decyzyjne jako hipotezy

Przykład

Możliwe stany pogody opisane są przez atrybuty:

- aura: słoneczna, pochmurna, deszczowa (atrybut nominalny)
- temperatura: zimna, umiarkowana, ciepła (atrybut porządkowy)
- wilgotność: normalna, duża (atrybut porządkowy)

Drzewa decyzyjne jako hipotezy

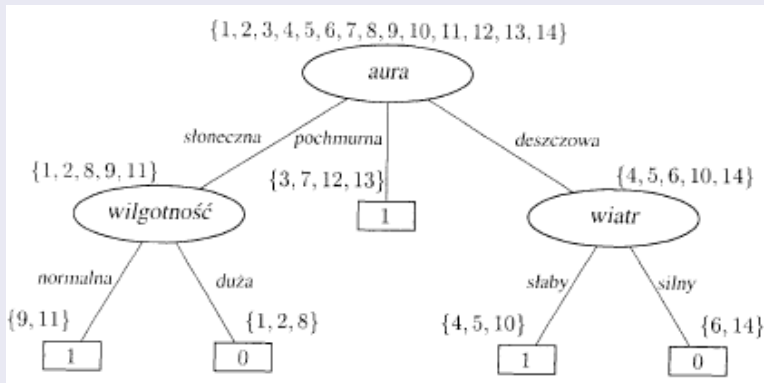
Przykład

x	<i>aura</i>	<i>temperatura</i>	<i>wilgotność</i>	<i>wiatr</i>	$c(x)$
1	<i>słoneczna</i>	<i>ciepła</i>	<i>duża</i>	<i>słaby</i>	0
2	<i>słoneczna</i>	<i>ciepła</i>	<i>duża</i>	<i>silny</i>	0
3	<i>pochmurna</i>	<i>ciepła</i>	<i>duża</i>	<i>słaby</i>	1
4	<i>deszczowa</i>	<i>umiarkowana</i>	<i>duża</i>	<i>słaby</i>	1
5	<i>deszczowa</i>	<i>zimna</i>	<i>normalna</i>	<i>słaby</i>	1
6	<i>deszczowa</i>	<i>zimna</i>	<i>normalna</i>	<i>silny</i>	0
7	<i>pochmurna</i>	<i>zimna</i>	<i>normalna</i>	<i>silny</i>	1
8	<i>słoneczna</i>	<i>umiarkowana</i>	<i>duża</i>	<i>słaby</i>	0
9	<i>słoneczna</i>	<i>zimna</i>	<i>normalna</i>	<i>słaby</i>	1
10	<i>deszczowa</i>	<i>umiarkowana</i>	<i>normalna</i>	<i>słaby</i>	1
11	<i>słoneczna</i>	<i>umiarkowana</i>	<i>normalna</i>	<i>silny</i>	1
12	<i>pochmurna</i>	<i>umiarkowana</i>	<i>duża</i>	<i>silny</i>	1
13	<i>pochmurna</i>	<i>ciepła</i>	<i>normalna</i>	<i>słaby</i>	1
14	<i>deszczowa</i>	<i>umiarkowana</i>	<i>duża</i>	<i>silny</i>	0

Rys. 1: Zbiór trenujący dla stanów pogody; $c(x) = 1$ - pozytywne; $c(x) = 0$ - negatywne

Drzewa decyzyjne jako hipotezy

Przykład



Rys. 2: Drzewo decyzyjne dla stanów pogody

Drzewa decyzyjne jako hipotezy

Przykład

Można to również zapisać w postaci tekstowej:

aura = słoneczna:

wilgotność = normalna: 1

wilgotność = duża: 0

aura = pochmurna: 1

aura = deszczowa:

wiatr = słaby: 1

wiatr = silny: 0

Drzewa decyzyjne jako hipotezy

Drzewo jako reprezentacja zbioru reguł

Reguła:

Jeśli *warunki* To *kategoria*

lub krócej

warunki → *kategoria*

Drzewa decyzyjne jako hipotezy

Przykład dla drzewa klasyfikującego

$aura(x) = słoneczna \wedge wilgotność = duża \rightarrow 0$

$aura(x) = słoneczna \wedge wilgotność = normalna \rightarrow 1$

$aura(x) = pochmurna \rightarrow 1$

$aura(x) = deszczowa \wedge wiatr = silny \rightarrow 0$

$aura(x) = deszczowa \wedge wiatr = słaby \rightarrow 1$

Zstępujące konstruowanie drzewa

funkcja *buduj-drzewo*(P, d, S)

argumenty wejściowe:

- P — zbiór przykładów etykietowanych pojęcia c ,
- d — domyślna etykieta kategorii,
- S — zbiór możliwych testów;

zwraca: drzewo decyzyjne reprezentujące hipotezę przybliżającą c na zbiorze P ;

- 1: **jeśli** *kryterium-stopu*(P, S) **to**
- 2: utwórz liść l ;
- 3: $d_l := \textit{kategoria}(P, d)$;
- 4: **zwróć** l ;
- 5: **koniec jeśli**
- 6: utwórz węzeł n ;
- 7: $t_n := \textit{wybierz-test}(P, S)$;
- 8: $d := \textit{kategoria}(P, d)$;
- 9: **dla wszystkich** $r \in R_{t_n}$ **wykonaj**
- 10: $n[r] := \textit{buduj-drzewo}(P_{t_n r}, d, S - \{t_n\})$;
- 11: **koniec dla**
- 12: **zwróć** n .

Rys. 3: Schemat zstępującego konstruowania drzewa decyzyjnego (TDIDT – Top-Down Induction of Decision Trees)

Zstępujące konstruowanie drzewa

Rodzaje testów

Operacja wyboru testu jest rdzeniem wszystkich algorytmów indukcji drzew decyzyjnych opartych na schemacie zstępującej konstrukcji drzewa i to ona przede wszystkim decyduje o ich właściwościach. Jej zadaniem jest wybranie dla zbioru dostępnych przykładów testu, który jest najbardziej użyteczny do ich dokładnej klasyfikacji.

Testy dla atrybutów nominalnych

Testy równościowe

$$t(x) = \begin{cases} 1 & \text{jeśli } a(x) = v \\ 0 & \text{jeśli } a(x) \neq v \end{cases}$$

Zstępujące konstruowanie drzewa

Testy dla atrybutów nominalnych

Testy przynależnościowe

$$t(x) = \begin{cases} 1 & \text{jeśli } a(x) \in V \\ 0 & \text{jeśli } a(x) \notin V \end{cases}$$

$V \subset A$ – właściwy podzbiór przeciwdziedziny atrybutu a

Zstępujące konstruowanie drzewa

Testy dla atrybutów porządkowych i ciągłych

Testy nierównościowe

$$t(x) = \begin{cases} 1 & \text{jeśli } a(x) \leq \theta \\ 0 & \text{jeśli } a(x) > \theta \end{cases}$$

$\theta \in A$ – pewna wartość progowa przeciwdziedziny atrybutu a

Zstępujące konstruowanie drzewa

Kryterium wyboru testu

Test ma być użyteczny, a drzewo w miarę możliwości proste.

Zstępujące konstruowanie drzewa

Przyrost informacji

Informacja zawarta w zbiorze etykietowanych przykładów P

$$I(P) = \sum_{d \in C} -\frac{|P^d|}{|P|} \log_2 \frac{|P^d|}{|P|}$$

$\log_2(\cdot)$ – gdy chcemy wynik w bitach, może być dowolny byle konsekwentny

Entropia zbioru przykładów P ze względu na wynik r testu t

$$E_{tr}(P) = \sum_{d \in C} -\frac{|P_{tr}^d|}{|P_{tr}|} \log_2 \frac{|P_{tr}^d|}{|P_{tr}|}$$

jest duża, jeśli wśród przykładów ze zbioru P , dla których test t daje wynik r , rozkład na kategorie jest równomierny.

Zstępujące konstruowanie drzewa

Przyrost informacji

Entropia zbioru przykładów P ze względu na test t to średnia ważona entropii dla poszczególnych wyników tego testu

$$E_t(P) = \sum_{r \in R_t} \frac{|P_{tr}|}{|P|} E_{tr}(P)$$

Zstępujące konstruowanie drzewa

Przyrost informacji


W interpretacji entropii pomaga wykres funkcji $E(p) = -p \log_2 p - (1 - p) \log_2(1 - p)$. Dla dwuelementowego zbioru kategorii $C = \{0, 1\}$ przyjmując

- $p = |P_{tr}^0|/|P_{tr}|$ otrzymujemy $I(P) = E(P)$
- $p = |P^0|/|P|$ otrzymujemy $E_{tr}(P) = E(P)$

Maximum zachodzi dla $p = \frac{1}{2}$ – czyli maksymalna entropia jest zawarta w zbiorze przykładów o równomiernym rozkładzie kategorii. Najmniejsze wartości funkcja E przyjmuje dla p bliskich 0 lub 1, co świadczy o tym, że informacja/entropia jest najmniejsza przy wyraźnej przewadze jednej kategorii nad drugą.

Zstępujące konstruowanie drzewa

Przyrost informacji



Rys. 4: Wykres entropii $E(p) = -p \log_2 p - (1 - p) \log_2(1 - p)$

Zstępujące konstruowanie drzewa

Przyrost informacji

Przyrost informacji wynikający z zastosowania testu t do zbioru przykładów etykietowanych P jest określony jako różnica

$$g_t(P) = I(P) - E_t(P)$$

Wybieramy test maksymalizujący przyrost informacji

$$\max_t g_t(P)$$

Ponieważ informacja $I(P)$ ma wartość niezależną od ocenianego testu i właściwą dla zbioru przykładów P , to powyższe kryterium jest równoważne z minimalizacją entropii $E_t(P)$

Zstępujące konstruowanie drzewa

Przyrost informacji

$$\begin{aligned}
 |T^1| &= |\{3, 4, 5, 7, 9, 10, 11, 12, 13\}| = 9, \\
 |T^0| &= |\{1, 2, 6, 8, 14\}| = 5, \\
 |T_{aura, słoneczna}| &= |\{1, 2, 8, 9, 11\}| = 5, \\
 |T_{aura, słoneczna}^1| &= |\{9, 11\}| = 2, \\
 |T_{aura, słoneczna}^0| &= |\{1, 2, 8\}| = 3, \\
 |T_{aura, pochmurna}| &= |\{3, 7, 12, 13\}| = 4, \\
 |T_{aura, pochmurna}^1| &= |\{3, 7, 12, 13\}| = 4, \\
 |T_{aura, pochmurna}^0| &= |\emptyset| = 0, \\
 |T_{aura, deszczowa}| &= |\{4, 5, 6, 10, 14\}| = 5, \\
 |T_{aura, deszczowa}^1| &= |\{4, 5, 10\}| = 3, \\
 |T_{aura, deszczowa}^0| &= |\{6, 14\}| = 2.
 \end{aligned}$$

Rys. 5: Liczności zbiorów potrzebne do wyznaczenia wartości przyrostu informacji dla testu tożsamościowego na wartościach atrybutu *aura*

Zstępujące konstruowanie drzewa

Przyrost informacji

$$E_{\text{aura.skoneczna}}(P) = -\frac{2}{5} \log_2 \frac{2}{5} - \frac{3}{5} \log_2 \frac{3}{5} = 0,971,$$

$$E_{\text{aura.pochybna}}(P) = -\frac{4}{4} \log_2 \frac{4}{4} - \frac{0}{4} \log_2 \frac{0}{4} = 0,$$

$$E_{\text{aura.deszczowa}}(P) = -\frac{3}{5} \log_2 \frac{3}{5} - \frac{2}{5} \log_2 \frac{2}{5} = 0,971.$$

Rys. 6: Entropia liczona ze wzoru $E_{tr}(P) = \sum_{d \in C} -\frac{|P_{tr}^d|}{|P_{tr}|} \log_2 \frac{|P_{tr}^d|}{|P_{tr}|}$

Zstępujące konstruowanie drzewa

Przyrost informacji

Możemy teraz obliczyć entropię ważoną

$$E_{aura} = \frac{5}{14} \cdot 0.971 + \frac{4}{14} \cdot 0 + \frac{5}{14} \cdot 0.971 = 0.694$$

Przyrost informacji dla atrybutu *aura*

$$I(T) = -\frac{9}{14} \log_2 \frac{9}{14} - \frac{5}{14} \log_2 \frac{5}{14} = 0.940$$

Wobec tego

$$g_{aura}(T) = 0.940 - 0.694 = 0.246$$