

Uczenie maszynowe: *wykład 2*

Paweł Cichosz

- 1 Indukcyjne uczenie się (c.d.)
- 2 PAC-nauczalność
- 3 PAC-uczenie się dla algorytmów spójnych

Estymacja błędu rzeczywistego

- Błąd na zbiorze $e_{S,c}(h)$ jest wiarygodnym estymatorem błędu rzeczywistego $e_{\Omega,c}(h)$, jeśli:
 - S jest wystarczająco duży,
 - S jest wybrany z dziedziny niezależnie od h ,
 - S jest wybrany z dziedziny zgodnie z rozkładem Ω .
- W praktyce: $S \subset D$, $T \subset D$, gdzie $D \subset X$ jest zbiorem przykładów o znanych klasach, $S \cap T = \emptyset$.
- Można użyć zastępczo estymatora $e_{S,c}(h)$ zamiast nieznanego $e_{\Omega,c}(h)$ do wykrywania nadmiernego dopasowania.
- Uproszczone praktyczne kryterium ryzyka nadmiernego dopasowania:
 $e_{S,c}(h) \gg e_{T,c}(h)$.

Estymacja przedziałowa błędu

Przedział ufności: Przedział wokół $e_{S,c}(h)$ który prawdopodobieństwem $1 - \delta$ zawiera $e_{\Omega,c}(h)$ (gdzie δ – poziom ufności).

Przedział Walda: (tylko jeśli błąd $e_{S,c}(h)$ nie jest zbyt bliski 0 ani 1)

$$|e_{\Omega,c}(h) - e_{S,c}(h)| < u_\delta \sqrt{\frac{e_{S,c}(h)(1 - e_{S,c}(h))}{|S|}}$$

z prawdopodobieństwem $1 - \delta$, gdzie dla $U \sim N(0, 1)$:

$$P(|U| < u_\delta) = 1 - \delta$$

Przedział Wilsona: (także jeśli błąd $e_{S,c}(h)$ bliski 0 lub 1)

$$\left| e_{\Omega,c}(h) - \frac{e_{S,c}(h) + \frac{u_\delta^2}{2|S|}}{1 + \frac{u_\delta^2}{|S|}} \right| < \frac{u_\delta}{1 + \frac{u_\delta^2}{|S|}} \sqrt{\frac{e_{S,c}(h)(1 - e_{S,c}(h))}{|S|} + \frac{u_\delta^2}{4|S|^2}}$$

z prawdopodobieństwem $1 - \delta$, gdzie u_δ – jak wyżej.


- 1 Indukcyjne uczenie się (c.d.)
- 2 PAC-nauczalność**
- 3 PAC-uczenie się dla algorytmów spójnych

Probably Approximately Correct

Klasa pojęć \mathbb{C} dla dziedzinie X jest PAC-nauczalna za pomocą przestrzeni modeli \mathbb{H} , jeśli


- istnieje algorytm uczenia się używający \mathbb{H} ,
- którego uruchomienie z dostępem do źródła przykładów $\text{EX}(\Omega, c)$ oraz z parametrami ϵ i δ ,
- daje w wyniku z prawdopodobieństwem co najmniej $1 - \delta$ model $h \in \mathbb{H}$, dla którego $e_{\Omega, c}(h) \leq \epsilon$,
- dla dowolnego pojęcia $c \in \mathbb{C}$, dowolnego rozkładu prawdopodobieństwa Ω na X oraz dowolnych $0 < \epsilon < 1$ i $0 < \delta < 1$.

Przykład: prostokąty




- Algorytm najciaśniejszego dopasowania (model – najmniejszy prostokąt zawierający wszystkie przykłady pozytywne).
- R_c , R_h – prostokąty reprezentujące pojęcie c , model h (oczywiście $R_h \subseteq R_c$).
- Wystarczy rozważyć przypadek c takiego, że $P(R_c) > \epsilon$ (w przeciwnym przypadku błąd nie może przekroczyć ϵ).

Przykład: prostokąty



- Odcinamy z boku R_c margines o prawdopodobieństwie $\frac{\epsilon}{4}$.

Przykład: prostokąty



- Powtarzając to dla każdego boku uzyskujemy „ramkę” o prawdopodobieństwie poniżej ϵ .
- Model ma błąd poniżej ϵ , jeśli w każdym marginesie $\frac{\epsilon}{4}$ znajduje się przykład trenujący (warunek wystarczający).

Przykład: prostokąty

- Model ma błąd poniżej ϵ , jeśli w każdym marginesie $\frac{\epsilon}{4}$ znajduje się przykład trenujący (warunek wystarczający).
- Prawdopodobieństwo sytuacji przeciwnej można ograniczyć przez:

$$4\left(1 - \frac{\epsilon}{4}\right)^m \leq 4e^{-m\frac{\epsilon}{4}} \leq \delta$$

gdzie m jest liczbą przykładów trenujących (w ostatnim kroku wykorzystana nierówność $1 + \alpha \leq e^\alpha$ dla dowolnego α).

- Wystarczy odpowiednio wiele przykładów:

$$m \geq \frac{4}{\epsilon} \left(\ln 4 + \ln \frac{1}{\delta} \right)$$

- Można również określić, jaki poziom błędu rzeczywistego da się zagwarantować przy ustalonej liczbie przykładów:

$$\epsilon \geq \frac{4}{m} \left(\ln 4 + \ln \frac{1}{\delta} \right)$$

- 1 Indukcyjne uczenie się (c.d.)
- 2 PAC-nauczalność
- 3 PAC-uczenie się dla algorytmów spójnych

Spójne uczenie się

Spójny model: zerowy błąd na zbiorze trenującym.

Spójny algorytm uczenia się: zwraca spójny model albo zawodzi, jeśli takiego modelu nie ma w przestrzeni modeli \mathbb{H} .

Niezawodność spójnego uczenia się: można zagwarantować tylko, jeśli $\mathbb{C} \subseteq \mathbb{H}$.

Przestrzeń wersji: zbiór wszystkich spójnych modeli:

$$VS_{\mathbb{H},T}(c) = \{h \in \mathbb{H} \mid e_{T,c}(h) = 0\}$$

Przykładowe algorytmy spójne

Prostokąty: algorytm znajdujący najmniejszy prostokąt zawierający wszystkie przykłady pozytywne.

Koniunkcje boolowskie: algorytm usuwający z początkowej koniunkcji $a_1 \wedge \neg a_1 \wedge a_2 \wedge \neg a_2 \wedge \dots \wedge a_n \wedge \neg a_n$ wszystkie literały, które nie są spełnione dla któregośkolwiek przykładu pozytywnego.

Błąd rzeczywisty spójnych modeli

- 1 Ponieważ algorytm spójny może zwrócić dowolny model spójny, więc potrzebujemy ograniczenia błędu rzeczywistego dowolnego takiego modelu.
- 2 Przestrzeń wersji jest ϵ -wyczerpana jeśli błąd rzeczywisty wszystkich należących do niej modeli nie przekracza ϵ .
- 3 Prawdopodobieństwo, że pewien model o błędzie rzeczywistym powyżej ϵ należy do przestrzeni wersji nie przekracza:

$$(1 - \epsilon)^m \leq e^{-m\epsilon}$$

gdzie m jest liczbą przykładów trenujących.

- 4 Dla skończonej przestrzeni modeli prawdopodobieństwo, że którykolwiek model z tej przestrzeni o błędzie rzeczywistym powyżej ϵ należy do przestrzeni wersji, nie przekracza:

$$|\mathbb{H}|e^{-m\epsilon}$$

Błąd rzeczywisty spójnych modeli

- 1 Zatem dla dowolnego spójnego modelu h :

$$P(e_{\Omega,c}(h) > \epsilon) \leq |\mathbb{H}|e^{-m\epsilon}$$

- 2 Ograniczamy przez δ :

$$|\mathbb{H}|e^{-\epsilon m} \leq \delta$$

$$m \geq \frac{1}{\epsilon}(\ln |\mathbb{H}| + \ln \frac{1}{\delta}) \qquad \epsilon \geq \frac{1}{m}(\ln |\mathbb{H}| + \ln \frac{1}{\delta})$$

- 3 Stąd z prawdopodobieństwem $1 - \delta$:

$$e_{\Omega,c}(h) \leq \frac{1}{m}(\ln |\mathbb{H}| + \ln \frac{1}{\delta})$$

- 4 Algorytmy spójne używające skończonej przestrzeni modeli mogą osiągnąć dowolnie mały błąd, mimo podatności na nadmierne dopasowanie (wystarczy odpowiednio wiele przykładów).
- 5 Dla ustalonej liczby przykładów można określić, jaki poziom błędu rzeczywistego może być probabilistycznie zagwarantowany.

Przykłady wyznaczania $|\mathbb{H}|$

Koniunkcje boolowskie:

- dla każdego atrybutu koniunkcja może zawierać literał pozytywny, negatywny lub nie zawierać go wcale,
- dodatkowo należy uwzględnić koniunkcję „zerową” (stale niespełnioną):

$$|\mathbb{H}| = 3^n + 1$$

Dowolne funkcje boolowskie: wszystkie możliwe sposoby etykietowania wszystkich możliwych 2^n przykładów z dziedziny:

$$|\mathbb{H}| = 2^{2^n}$$