

COLT - OBLICZENIOWA TEORIA UCZENIA SIĘ

Hung Son Nguyen

Institute of Mathematics, Warsaw University
son@mimuw.edu.pl

2007

SPIS TREŚCI

- 1 WPROWADZENIE DO TEORII UCZENIA SIĘ
- 2 MODEL PAC (PROBABLY APPROXIMATELY CORRECT)
- 3 WYUCZALNOŚĆ KLASY POJEŃ
- 4 WYMIAR VAPNIKA CHERVONENKISA (VC DIMENSION)
- 5 PODSTAWOWE TWIERDZENIA TEORII UCZENIA SIĘ

SPIS TREŚCI

- 1 WPROWADZENIE DO TEORII UCZENIA SIĘ
- 2 MODEL PAC (PROBABLY APPROXIMATELY CORRECT)
- 3 WYUCZALNOŚĆ KLASY POJEŃ
- 4 WYMIAR VAPNIKA CHERVONENKISA (VC DIMENSION)
- 5 PODSTAWOWE TWIERDZENIA TEORII UCZENIA SIĘ

SPIS TREŚCI

- 1 WPROWADZENIE DO TEORII UCZENIA SIĘ
- 2 MODEL PAC (PROBABLY APPROXIMATELY CORRECT)
- 3 WYUCZALNOŚĆ KLASY POJEŃ
- 4 WYMIAR VAPNIKA CHERVONENKISA (VC DIMENSION)
- 5 PODSTAWOWE TWIERDZENIA TEORII UCZENIA SIĘ

SPIS TREŚCI

- 1 WPROWADZENIE DO TEORII UCZENIA SIĘ
- 2 MODEL PAC (PROBABLY APPROXIMATELY CORRECT)
- 3 WYUCZALNOŚĆ KLASY POJEŃ
- 4 WYMIAR VAPNIKA CHERVONENKISA (VC DIMENSION)
- 5 PODSTAWOWE TWIERDZENIA TEORII UCZENIA SIĘ

- 1 WPROWADZENIE DO TEORII UCZENIA SIĘ
- 2 MODEL PAC (PROBABLY APPROXIMATELY CORRECT)
- 3 WYUCZALNOŚĆ KLASY POJEŃ
- 4 WYMIAR VAPNIKA CHERVONENKISA (VC DIMENSION)
- 5 PODSTAWOWE TWIERDZENIA TEORII UCZENIA SIĘ

SPIS TREŚCI

- 1 WPROWADZENIE DO TEORII UCZENIA SIĘ
- 2 MODEL PAC (PROBABLY APPROXIMATELY CORRECT)
- 3 WYUCZALNOŚĆ KLASY POJEŃ
- 4 WYMIAR VAPNIKA CHERVONENKISA (VC DIMENSION)
- 5 PODSTAWOWE TWIERDZENIA TEORII UCZENIA SIĘ

ŹRÓDŁO INFORMACJI:

Uczeń może pozyskać informacje o dziedzinie poprzez:

- 1 **Przykłady:** Uczeń dostaje pozytywne i/lub negatywne przykłady. Przykłady mogą być zdobywane w sposób:
 - 1 losowy: według pewnego znanego lub nieznanego rozkładu;
 - 2 arbitralny;
 - 3 złośliwy: (np. przez kontrolera, który chciałby poznać najgorsze zachowanie algorytmu uczenia się);
 - 4 specjalny przez życzliwego nauczyciela: (np., aby ułatwić proces uczenia się)
- 2 **Zapytania:** uczeń zdobywa informacje o dziedzinie przez zadawanie zapytań do nauczyciela.
- 3 **Eksperymentowanie:** aktywne uczenie się.

TEORIA UCZENIA SIĘ

- **Podejście indukcyjne:** wnioskowanie na podstawie skończonego zbioru obserwacji;
- Np. Pokazać, że dla każdego $n \in \mathbb{N}$

$$1^2 + 2^2 + \dots + n^2 = \frac{n(n+1)(2n+1)}{6}$$

- Jakie prawa rządzą w podejściu uczenia indukcyjnego?

Szukamy teorii dotyczącej:

- Prawdopodobieństwa udanego uczenia się;
- Liczby przykładów treningowych;
- Złożoności przestrzeni hipotez;
- Skuteczności aproksymacji;
- Sposób reprezentacji danych treningowych;

TEORIA UCZENIA SIĘ

- **Podejście indukcyjne:** wnioskowanie na podstawie skończonego zbioru obserwacji;
- Np. Pokazać, że dla każdego $n \in \mathbb{N}$

$$1^2 + 2^2 + \dots + n^2 = \frac{n(n+1)(2n+1)}{6}$$

- Jakie prawa rządzą w podejściu uczenia indukcyjnego?

Szukamy teorii dotyczącej:

- Prawdopodobieństwa udanego uczenia się;
- Liczby przykładów treningowych;
- Złożoności przestrzeni hipotez;
- Skuteczności aproksymacji;
- Sposób reprezentacji danych treningowych;

TEORIA UCZENIA SIĘ

- **Podejście indukcyjne:** wnioskowanie na podstawie skończonego zbioru obserwacji;
- Np. Pokazać, że dla każdego $n \in \mathbb{N}$

$$1^2 + 2^2 + \dots + n^2 = \frac{n(n+1)(2n+1)}{6}$$

- Jakie prawa rządzą w podejściu uczenia indukcyjnego?

Szukamy teorii dotyczącej:

- Prawdopodobieństwa udanego uczenia się;
- Liczby przykładów treningowych;
- Złożoności przestrzeni hipotez;
- Skuteczności aproksymacji;
- Sposób reprezentacji danych treningowych;

KRYTERIA OCENY JAKOŚCI:

Skąd wiemy, czy uczeń się nauczył lub jak dobrze się nauczył?

- Miary off-line (batch) vs. on-line (interactive).
- Jakość opisu vs. jakość predykcji
- Skuteczność: obliczona na podstawie błędu klasyfikacji, dokładności opisu ...
- Efektywność uczenia: wymagana jest wielomianowa złożoność obliczeniowa.

PRZYKŁAD

- Załóżmy, że chcemy nauczyć się pojęcia "człowieka o średniej budowie ciała". Dane – czyli osoby – są reprezentowane przez punkty $(wzrost(cm), waga(Kg))$ i są etykietowane przez $+$ dla pozytywnych przykładów i $-$ dla negatywnych.
- Dodatkowa wiedza: szukane pojęcie można wyrazić za pomocą PROSTOKĄTA
- Na przykład dany jest etykietowany zbiór:
 $((84, 184), +)$, $((70, 170), +)$, $((75, 163), -)$, $((80, 180), +)$,
 $((81, 195), -)$, $((63, 191), -)$, $((77, 187), -)$, $((68, 168), +)$
- Znajdź etykietę $((79, 183, ?))$

PROBLEM UCZENIA SIĘ PROSTOKĄTA

Możemy definiować problem jak następująco:

- **Cel:** Znaleźć w \mathbb{R}^2 prostokąt R o bokach równoległych do osi.
- **Wejście:** Zbiór zawierający przykłady w postaci punktów $((x, y), +/−)$. Te punkty zostały wygenerowane losowo.
- **Wyjście:** hipotetyczny prostokąt R' będący "dobrą aproksymacją" R .
- **Dodatkowe wymagania:** Algorytm powinien być efektywny (czasowo) używając do uczenia najmniejszej liczby przykładów.

PROBLEM UCZENIA SIĘ PROSTOKĄTA

Możemy definiować problem jak następująco:

- **Cel:** Znaleźć w \mathbb{R}^2 prostokąt R o bokach równoległych do osi.
- **Wejście:** Zbiór zawierający przykłady w postaci punktów $((x, y), +/−)$. Te punkty zostały wygenerowane losowo.
- **Wyjście:** hipotetyczny prostokąt R' będący "dobrą aproksymacją" R .
- **Dodatkowe wymagania:** Algorytm powinien być efektywny (czasowo) używając do uczenia najmniejszej liczby przykładów.

PROBLEM UCZENIA SIĘ PROSTOKĄTA

Możemy definiować problem jak następująco:

- **Cel:** Znaleźć w \mathbb{R}^2 prostokąt R o bokach równoległych do osi.
- **Wejście:** Zbiór zawierający przykłady w postaci punktów $((x, y), +/−)$. Te punkty zostały wygenerowane losowo.
- **Wyjście:** hipotetyczny prostokąt R' będący "dobrą aproksymacją" R .
- **Dodatkowe wymagania:** Algorytm powinien być efektywny (czasowo) używając do uczenia najmniejszej liczby przykładów.

PROBLEM UCZENIA SIĘ PROSTOKĄTA

Możemy definiować problem jak następująco:

- **Cel:** Znaleźć w \mathbb{R}^2 prostokąt R o bokach równoległych do osi.
- **Wejście:** Zbiór zawierający przykłady w postaci punktów $((x, y), +/−)$. Te punkty zostały wygenerowane losowo.
- **Wyjście:** hipotetyczny prostokąt R' będący "dobrą aproksymacją" R .
- **Dodatkowe wymagania:** Algorytm powinien być efektywny (czasowo) używając do uczenia najmniejszej liczby przykładów.

OGÓLNY MODEL UCZENIA SIĘ

• Dane są

- zbiór wszystkich obiektów X (skończony lub nie);
- pojęcie $c \in \mathbb{C}$ (funkcja celu);
- skończona próbka D obiektów $x_1, \dots, x_m \in X$ wraz z wartością funkcji c na tych obiektach;
- przestrzeń hipotez \mathbb{H} ;

• Szukane

- hipoteza $h \in \mathbb{H}$ będąca dobrą aproksymacją pojęcia c .

• Wymagane

- dobra jakość aproksymacji
- szybki czas działania.

OGÓLNY MODEL UCZENIA SIĘ

- **Dane są**
 - zbiór wszystkich obiektów X (skończony lub nie);
 - pojęcie $c \in \mathbb{C}$ (funkcja celu);
 - skończona próbka D obiektów $x_1, \dots, x_m \in X$ wraz z wartością funkcji c na tych obiektach;
 - przestrzeń hipotez \mathbb{H} ;
- **Szukane**
 - hipoteza $h \in \mathbb{H}$ będąca dobrą aproksymacją pojęcia c .
- **Wymagane**
 - dobra jakość aproksymacji
 - szybki czas działania.

OGÓLNY MODEL UCZENIA SIĘ

- **Dane są**
 - zbiór wszystkich obiektów X (skończony lub nie);
 - pojęcie $c \in \mathbb{C}$ (funkcja celu);
 - skończona próbka D obiektów $x_1, \dots, x_m \in X$ wraz z wartością funkcji c na tych obiektach;
 - przestrzeń hipotez \mathbb{H} ;
- **Szukane**
 - hipoteza $h \in \mathbb{H}$ będąca dobrą aproksymacją pojęcia c .
- **Wymagane**
 - dobra jakość aproksymacji
 - szybki czas działania.

INNE PRZYKŁADY

- **Uczenie półosi (lub dyskretyzacji):**

$$X = \mathfrak{R}; \quad \mathbb{C} = \mathbb{H} = \{[\lambda, \infty) : \alpha \in \mathfrak{R}\}$$

- **Uczenie hiperpłaszczyzny:**

$$X = \mathfrak{R}^n; \quad \mathbb{H} = \{f_{w_0, w_1, \dots, w_n} : \mathfrak{R}^n \rightarrow \{0, 1\}\}$$

gdzie $f_{w_0, \dots, w_n}(x_1, \dots, x_n) = \text{sgn}(w_0 + w_1x_1 + \dots + w_nx_n)$.

- **Uczenie jednomianów Boolowskich:**

$$X = \{0, 1\}^n; \quad c : \{0, 1\}^n \rightarrow \{0, 1\};$$

$\mathbb{H} = M_n =$ zbiór jednomianów Boolowskich o n zmiennych.

BŁĄD HIPOTEZY

Niech

- X – zbiór wszystkich obiektów.
- $\Omega = (X, \mu)$ – przestrzeń probabilistyczna określona na X .

Błąd hipotezy $h \in \mathbb{H}$ względem pojęcia c (funkcji docelowej):

$$er_{\Omega}(h, c) = er_{\Omega}^c(h) = \mu\{x \in X | h(x) \neq c(x)\}$$

Z prawdopodobieństwem $(1 - \varepsilon)$ możemy oszacować er_{Ω}^c :

$$|er_{\Omega}^c - er_D^c| \leq s_{\frac{\varepsilon}{2}} \sqrt{\frac{er_D^c(1 - er_D^c)}{|D|}}$$

THE NO FREE LUNCH THEOREM

- Algorytm \mathcal{L} dobrze się uczy pojęcia c jeśli er_{Ω}^c jest mały.
- Niech $\mathbb{P}(X) = \{c : X \rightarrow \{0, 1\}\}$.
Czy można stwierdzić wiedzieć, że \mathcal{L}_1 uczy się wszystkich pojęć z $\mathbb{P}(X)$ lepiej od \mathcal{L}_2 ?
- "No Free Lunch theorem" (Wolpert, Schaffer) w wersji problemów uczenia się głosi, że:
 - Żaden algorytm nie może być najlepszy w uczeniu wszystkich pojęć.
 - Każdy algorytm jest najlepszy dla takiej samej liczby pojęć
 - Ale interesuje nas tylko pewna klasa problemów czyli klasa pojęć $\mathbb{C} \subset \mathbb{P}(X)$
 - Wniosek: Należy znaleźć odp. algorytm do każdego problemu.

SPIS TREŚCI

- 1 WPROWADZENIE DO TEORII UCZENIA SIĘ
- 2 MODEL PAC (PROBABLY APPROXIMATELY CORRECT)
- 3 WYUCZALNOŚĆ KLASY POJEŃ
- 4 WYMIAR VAPNIKA CHERVONENKISA (VC DIMENSION)
- 5 PODSTAWOWE TWIERDZENIA TEORII UCZENIA SIĘ

MODEL UCZENIA SIĘ PAC

- **Dane:** dziedzina X , klasa pojęć \mathbb{C} i przestrzeń hipotez ucznia \mathbb{H} .
- Uczeń uczy się pojęcia $c \in \mathbb{C}$ na podstawie przykładów wygenerowanych przez zm.l. $EX(\Omega, c)$ (zwaną *wyrocznią*).

rodzina wszystkich zbiorów zawierających m przykładów

$$D = \{\langle x_1, c(x_1) \rangle, \dots, \langle x_m, c(x_m) \rangle\} \in \mathcal{S}(m, c)$$

- Kolejne przykłady zbioru trenującego generuje zm. losowa $EX(c, \Omega)$ (*wyrocznia*) zwracająca przykład $\langle x, c(x) \rangle$, gdzie $x \in X$ jest wylosowane zgodnie z Ω .
- Celem ucznia jest znalezienie hipotezy minimalizującej błąd rzeczywisty względem c dla rozkładu Ω , czyli er_{Ω}^c .
- Zasadnicza idea modelu PAC: określenie warunków, pod jakimi uczeń (lub algorytm uczenia się) znajdzie "dobrą hipotezę" z "dużym prawdopodobieństwem".
(o ograniczonym błędzie rzeczywistym powyżej określonego progu)

MODEL UCZENIA SIĘ PAC

- **Dane:** dziedzina X , klasa pojęć \mathbb{C} i przestrzeń hipotez ucznia \mathbb{H} .
- Uczeń uczy się pojęcia $c \in \mathbb{C}$ na podstawie przykładów wygenerowanych przez zm.l. $EX(\Omega, c)$ (zwaną *wyrocznią*).

rodzina wszystkich zbiorów zawierających m przykładów

$$D = \{\langle x_1, c(x_1) \rangle, \dots, \langle x_m, c(x_m) \rangle\} \in \mathcal{S}(m, c)$$

- Kolejne przykłady zbioru trenującego generuje zm. losowa $EX(c, \Omega)$ (*wyrocznia*) zwracająca przykład $\langle x, c(x) \rangle$, gdzie $x \in X$ jest wylosowane zgodnie z Ω .
- Celem ucznia jest znalezienie hipotezy minimalizującej błąd rzeczywisty względem c dla rozkładu Ω , czyli er_{Ω}^c .
- Zasadnicza idea modelu PAC: określenie warunków, pod jakimi uczeń (lub algorytm uczenia się) znajdzie “dobrą hipotezę” z “dużym prawdopodobieństwem”.
(o ograniczonym błędzie rzeczywistym powyżej określonego progu)

MODEL UCZENIA SIĘ PAC

- **Dane:** dziedzina X , klasa pojęć \mathbb{C} i przestrzeń hipotez ucznia \mathbb{H} .
- Uczeń uczy się pojęcia $c \in \mathbb{C}$ na podstawie przykładów wygenerowanych przez zm.l. $EX(\Omega, c)$ (zwaną *wyrocznią*).

rodzina wszystkich zbiorów zawierających m przykładów

$$D = \{\langle x_1, c(x_1) \rangle, \dots, \langle x_m, c(x_m) \rangle\} \in \mathcal{S}(m, c)$$

- Kolejne przykłady zbioru trenującego generuje zm. losowa $EX(c, \Omega)$ (*wyrocznia*) zwracająca przykład $\langle x, c(x) \rangle$, gdzie $x \in X$ jest wylosowane zgodnie z Ω .
- Celem ucznia jest znalezienie hipotezy minimalizującej błąd rzeczywisty względem c dla rozkładu Ω , czyli er_{Ω}^c .
- **Zasadnicza idea modelu PAC:** określenie warunków, pod jakimi uczeń (lub algorytm uczenia się) znajdzie “dobrą hipotezę” z “dużym prawdopodobieństwem”.
(o ograniczonym błędzie rzeczywistym powyżej określonego progu)

MODEL UCZENIA SIĘ PAC

- **Dane:** dziedzina X , klasa pojęć \mathbb{C} i przestrzeń hipotez ucznia \mathbb{H} .
- Uczeń uczy się pojęcia $c \in \mathbb{C}$ na podstawie przykładów wygenerowanych przez zm.l. $EX(\Omega, c)$ (zwaną *wyrocznią*).

rodzina wszystkich zbiorów zawierających m przykładów

$$D = \{\langle x_1, c(x_1) \rangle, \dots, \langle x_m, c(x_m) \rangle\} \in \mathcal{S}(m, c)$$

- Kolejne przykłady zbioru trenującego generuje zm. losowa $EX(c, \Omega)$ (*wyrocznia*) zwracająca przykład $\langle x, c(x) \rangle$, gdzie $x \in X$ jest wylosowane zgodnie z Ω .
- Celem ucznia jest znalezienie hipotezy minimalizującej błąd rzeczywisty względem c dla rozkładu Ω , czyli er_{Ω}^c .
- **Zasadnicza idea modelu PAC:** określenie warunków, pod jakimi uczeń (lub algorytm uczenia się) znajdzie “dobrą hipotezę” z “dużym prawdopodobieństwem”.
(o ograniczonym błędzie rzeczywistym powyżej określonego progu)

MODEL UCZENIA SIĘ PAC

- **Dane:** dziedzina X , klasa pojęć \mathbb{C} i przestrzeń hipotez ucznia \mathbb{H} .
- Uczeń uczy się pojęcia $c \in \mathbb{C}$ na podstawie przykładów wygenerowanych przez zm.l. $EX(\Omega, c)$ (zwaną *wyrocznią*).

rodzina wszystkich zbiorów zawierających m przykładów

$$D = \{\langle x_1, c(x_1) \rangle, \dots, \langle x_m, c(x_m) \rangle\} \in \mathcal{S}(m, c)$$

- Kolejne przykłady zbioru trenującego generuje zm. losowa $EX(c, \Omega)$ (*wyrocznia*) zwracająca przykład $\langle x, c(x) \rangle$, gdzie $x \in X$ jest wylosowane zgodnie z Ω .
- Celem ucznia jest znalezienie hipotezy minimalizującej błąd rzeczywisty względem c dla rozkładu Ω , czyli er_{Ω}^c .
- **Zasadnicza idea modelu PAC:** określenie warunków, pod jakimi uczeń (lub algorytm uczenia się) znajdzie “dobrą hipotezę” z “dużym prawdopodobieństwem”.
(o ograniczonym błędzie rzeczywistym powyżej określonego progu)

PAC-OWY UCZEŃ

DEFINITION (PAC)

Algorytm \mathcal{L} nazywamy “*prawdopodobnie aproksymacyjnie poprawnym*” wtedy i tylko wtedy, gdy

dla każdych $0 < \varepsilon, \delta < 1$, istnieje liczba $m_0 = m_0(\varepsilon, \delta)$ taka, że dla dowolnego pojęcia $c \in \mathbb{C}$ i dla dowolnego rozkładu Ω na X mamy


$$\mu^m \{D \in \mathcal{S}(m, c) \mid \text{er}_\Omega(\mathcal{L}(D)) < \varepsilon\} > 1 - \delta$$

o ile $m > m_0$.

Wówczas mówimy w skrócie, że \mathcal{L} *jest PAC* (*Probably Approximately Correct*).

- ε – dopuszczalny poziom błędu
- $(1 - \delta)$ – poziom zaufania

PRZYKŁAD PROBLEMU DYSKRETYZACJI



- $X = \mathbb{R}$; $\mathbb{H} = \mathbb{C} = \{f_\lambda : \mathbb{R} \rightarrow \{0, 1\} \mid f_\lambda(x) = 1 \Leftrightarrow x \geq \lambda\}$
- $c = f_{\lambda_0}$
- znaleźć λ_0 na podstawie losowo wygenerowanych przykładów $D = \{\langle x_1, f_{\lambda_0}(x_1) \rangle, \dots, \langle x_m, f_{\lambda_0}(x_m) \rangle\}$

Algorytm:

- 1 Set $\lambda^* := \min_{i \in \{1, \dots, m\}} \{x_i : f_{\lambda_0}(x_i) = 1\}$;
- 2 $L(D) := f_{\lambda^*}$;

PRZYKŁAD (C.D.)

Twierdzenie:

Powyższy algorytm jest PAC

Dowód

- $er_{\Omega}^{\epsilon} = \mu([\lambda_0, \lambda^*])$
- Niech $\beta_0 = \sup\{\beta | \mu([\lambda_0, \beta]) < \epsilon\}$. Wówczas $er_{\Omega}^{\epsilon}(f_{\lambda^*}) \leq \epsilon$
 $\Leftrightarrow \lambda^* \leq \beta_0 \Leftrightarrow$ jeden z przykładów x_i znajduje się w przedziale $[\lambda_0, \beta_0]$;
- Prawdopodobieństwo tego, że żaden pośród m przykładów nie należy do $[\lambda_0, \beta_0]$ jest $\leq (1 - \epsilon)^m$. Stąd

$$\mu^m\{D \in \mathcal{S}(m, f_{\lambda_0}) | er_{\Omega}(L(D)) \leq \epsilon\} \geq 1 - (1 - \epsilon)^m$$

- Aby to prawdopodobieństwo było $> 1 - \delta$, wystarczy wybrać

$$m \geq m_0 = \left\lceil \frac{1}{\epsilon} \ln \frac{1}{\delta} \right\rceil$$

DOKŁADNE UCZENIE SIĘ

- Niech Ω będzie rozkładem dyskretnym zdefiniowanym przez $\mu_1 = \mu(x_1), \dots, \mu_n = \mu(x_n)$ – dla pewnych $x_1, \dots, x_n \in X$ – takich, że $\mu_1 + \dots + \mu_n = 1$. Niech $\varepsilon_{\min} = \min_i \mu_i$.
- Jeśli \mathfrak{L} jest PAC, i jeśli $\varepsilon \leq \varepsilon_{\min}$ to warunek $er_{\Omega}^c(L(D)) < \varepsilon$ jest równoważny z $er_{\Omega}^c(L(D)) = 0$. Stąd dla każdego δ , istnieje $m_0 = m_0(\varepsilon_{\min}, \delta)$ taka, że dla dowolnego $c \in \mathbb{C}$ i Ω

$$m > m_0 \Rightarrow \mu^m \{D \in \mathcal{S}(m, t) \mid er_{\Omega}(L(D)) = 0\} > 1 - \delta$$

- Wówczas mówimy, że prawdopodobnie \mathfrak{L} jest dokładnym algorytmem (*jest PEC – probably exactly correct*)

SPIS TREŚCI

- 1 WPROWADZENIE DO TEORII UCZENIA SIĘ
- 2 MODEL PAC (PROBABLY APPROXIMATELY CORRECT)
- 3 WYUCZALNOŚĆ KLASY POJĘĆ
- 4 WYMIAR VAPNIKA CHERVONENKISA (VC DIMENSION)
- 5 PODSTAWOWE TWIERDZENIA TEORII UCZENIA SIĘ

POTENCJALNA WYUCZALNOŚĆ

- Algorytm \mathfrak{L} nazywamy **niesprzecznym** jeśli dla każdego pojęcia c i każdego zbioru D mamy $er_D^c(L(D)) = 0$
(tzn. $\mathfrak{L}(D)(x_i) = c(x_i)$ dla dowolnego przykładu $(x_i, c(x_i)) \in D$).
- $\mathbb{H}^c(D) = \{h \in \mathbb{H} | h(x_i) = c(x_i) (i = 1, \dots, m)\}$.
 \mathfrak{L} jest niespreczny jeśli $\mathfrak{L}(D) \in \mathbb{H}^c(D)$ dla każdego D .
- $\mathbb{B}_\varepsilon^c = \{h \in \mathbb{H} | er_\Omega(h) \geq \varepsilon\}$ – zbiór słabych hipotez

DEFINITION

Mówimy, że \mathbb{C} jest potencjalnie wyuczalne za pomocą \mathbb{H} , jeśli dla każdego rozkładu Ω na X i dowolnego pojęcia $c \in \mathbb{C}$ oraz dla dowolnych $0 < \varepsilon, \delta < 1$ istnieje $m_0 = m_0(\varepsilon, \delta)$ takie, że

$$m \geq m_0 \Rightarrow \mu^m \{D \in \mathcal{S}(m, c) | \mathbb{H}^c(D) \cap \mathbb{B}_\varepsilon^c = \emptyset\} > 1 - \delta$$

POTENCJALNA WYUCZALNOŚĆ

- Algorytm \mathfrak{L} nazywamy **niesprzecznym** jeśli dla każdego pojęcia c i każdego zbioru D mamy $er_D^c(L(D)) = 0$
(tzn. $\mathfrak{L}(D)(x_i) = c(x_i)$ dla dowolnego przykładu $(x_i, c(x_i)) \in D$).
- $\mathbb{H}^c(D) = \{h \in \mathbb{H} | h(x_i) = c(x_i) (i = 1, \dots, m)\}$.
 \mathfrak{L} jest niespreczny jeśli $\mathfrak{L}(D) \in \mathbb{H}^c(D)$ dla każdego D .
- $\mathbb{B}_\varepsilon^c = \{h \in \mathbb{H} | er_\Omega(h) \geq \varepsilon\}$ – zbiór słabych hipotez

DEFINITION

Mówimy, że \mathbb{C} jest potencjalnie wyuczalne za pomocą \mathbb{H} , jeśli dla każdego rozkładu Ω na X i dowolnego pojęcia $c \in \mathbb{C}$ oraz dla dowolnych $0 < \varepsilon, \delta < 1$ istnieje $m_0 = m_0(\varepsilon, \delta)$ takie, że

$$m \geq m_0 \Rightarrow \mu^m \{D \in \mathcal{S}(m, c) | \mathbb{H}^c(D) \cap \mathbb{B}_\varepsilon^c = \emptyset\} > 1 - \delta$$

POTENCJALNA WYUCZALNOŚĆ

- Algorytm \mathfrak{L} nazywamy **niesprzecznym** jeśli dla każdego pojęcia c i każdego zbioru D mamy $er_D^c(L(D)) = 0$
(tzn. $\mathfrak{L}(D)(x_i) = c(x_i)$ dla dowolnego przykładu $(x_i, c(x_i)) \in D$).
- $\mathbb{H}^c(D) = \{h \in \mathbb{H} | h(x_i) = c(x_i) (i = 1, \dots, m)\}$.
 \mathfrak{L} jest niespreczny jeśli $\mathfrak{L}(D) \in \mathbb{H}^c(D)$ dla każdego D .
- $\mathbb{B}_\varepsilon^c = \{h \in \mathbb{H} | er_\Omega(h) \geq \varepsilon\}$ – zbiór słabych hipotez

DEFINITION

Mówimy, że \mathbb{C} jest potencjalnie wyuczalne za pomocą \mathbb{H} , jeśli dla każdego rozkładu Ω na X i dowolnego pojęcia $c \in \mathbb{C}$ oraz dla dowolnych $0 < \varepsilon, \delta < 1$ istnieje $m_0 = m_0(\varepsilon, \delta)$ takie, że

$$m \geq m_0 \Rightarrow \mu^m \{D \in \mathcal{S}(m, c) | \mathbb{H}^c(D) \cap \mathbb{B}_\varepsilon^c = \emptyset\} > 1 - \delta$$

POTENCJALNA WYUCZALNOŚĆ

- Algorytm \mathfrak{L} nazywamy **niesprzecznym** jeśli dla każdego pojęcia c i każdego zbioru D mamy $er_D^c(L(D)) = 0$
(tzn. $\mathfrak{L}(D)(x_i) = c(x_i)$ dla dowolnego przykładu $(x_i, c(x_i)) \in D$).
- $\mathbb{H}^c(D) = \{h \in \mathbb{H} | h(x_i) = c(x_i) (i = 1, \dots, m)\}$.
 \mathfrak{L} jest niespreczny jeśli $\mathfrak{L}(D) \in \mathbb{H}^c(D)$ dla każdego D .
- $\mathbb{B}_\varepsilon^c = \{h \in \mathbb{H} | er_\Omega(h) \geq \varepsilon\}$ – zbiór słabych hipotez

DEFINITION

Mówimy, że \mathbb{C} jest potencjalnie wyuczalne za pomocą \mathbb{H} , jeśli dla każdego rozkładu Ω na X i dowolnego pojęcia $c \in \mathbb{C}$ oraz dla dowolnych $0 < \varepsilon, \delta < 1$ istnieje $m_0 = m_0(\varepsilon, \delta)$ takie, że

$$m \geq m_0 \Rightarrow \mu^m \{D \in \mathcal{S}(m, c) | \mathbb{H}^c(D) \cap \mathbb{B}_\varepsilon^c = \emptyset\} > 1 - \delta$$

POTENCJALNA WYUCZALNOŚĆ

THEOREM

Jeśli

- 1 \mathbb{C} jest potencjalnie wyuczalne za pomocą \mathbb{H}
- 2 \mathcal{L} jest algorytmem niesprzecznym dla \mathbb{C}

Wówczas \mathcal{L} jest PAC

THEOREM (HAUSSLER, 1988)

Jeśli $\mathbb{C} = \mathbb{H}$ i $|\mathbb{C}| < \infty$, to \mathbb{C} jest potencjalnie wyuczalne.Dowód: Niech $h \in \mathbb{B}_\varepsilon$ (tzn. $er_\Omega(h) \geq \varepsilon$). Wówczas

$$\begin{aligned} \mu^m \{D \in \mathcal{S}(m, c) \mid er_D(h) = 0\} &\leq (1 - \varepsilon)^m \\ \Rightarrow \mu^m \{D : \mathbb{H}[D] \cap \mathbb{B}_\varepsilon \neq \emptyset\} &\leq |\mathbb{B}_\varepsilon| (1 - \varepsilon)^m \leq |\mathbb{H}| (1 - \varepsilon)^m \end{aligned}$$

Aby $|\mathbb{H}| (1 - \varepsilon)^m < \delta$ wystarczy wybrać $m \geq m_0 = \left\lceil \frac{1}{\varepsilon} \ln \frac{|\mathbb{H}|}{\delta} \right\rceil$

SPIS TREŚCI

- 1 WPROWADZENIE DO TEORII UCZENIA SIĘ
- 2 MODEL PAC (PROBABLY APPROXIMATELY CORRECT)
- 3 WYUCZALNOŚĆ KLASY POJEŃ
- 4 WYMIAR VAPNIKA CHERVONENKISA (VC DIMENSION)
- 5 PODSTAWOWE TWIERDZENIA TEORII UCZENIA SIĘ

WYMIAR VAPNIKA-CHEVONENKISA

- Niech $\mathbf{x} = \{x_1, x_2, \dots, x_m\} \subset X$. Oznaczmy przez $\Pi_{\mathbb{H}}(\mathbf{x})$ liczbę podziałów zbioru \mathbf{x} dokonanych przez \mathbb{H} , t.j. liczbę różnych wektorów postaci

$$(h(x_1), \dots, h(x_m)) \in \{0, 1\}^m$$

po wszystkich $h \in H$.

- $\Pi_{\mathbb{H}}(\mathbf{x}) \leq 2^m$. Jeśli zachodzi równość, mówimy, że \mathbb{H} rozbija \mathbf{x} .
- Niech $\Pi_{\mathbb{H}}(m) = \max_{\mathbf{x} \in X^m} \Pi_{\mathbb{H}}(\mathbf{x})$
- Na przykład: W przypadku przestrzeni półosi postaci $[\alpha, \infty)$ mamy $\Pi_{\mathbb{H}}(m) = m + 1$.
- Na ogół trudno znaleźć wzór na $\Pi_{\mathbb{H}}(m)$!!!

WYMIAR VAPNIKA-CHERVONENKISA

- Niech $\mathbf{x} = \{x_1, x_2, \dots, x_m\} \subset X$. Oznaczmy przez $\Pi_{\mathbb{H}}(\mathbf{x})$ liczbę podziałów zbioru \mathbf{x} dokonanych przez \mathbb{H} , t.j. liczbę różnych wektorów postaci

$$(h(x_1), \dots, h(x_m)) \in \{0, 1\}^m$$

po wszystkich $h \in H$.

- $\Pi_{\mathbb{H}}(\mathbf{x}) \leq 2^m$. Jeśli zachodzi równość, mówimy, że \mathbb{H} **rozbija** \mathbf{x} .
- Niech $\Pi_{\mathbb{H}}(m) = \max_{\mathbf{x} \in X^m} \Pi_{\mathbb{H}}(\mathbf{x})$
- Na przykład: W przypadku przestrzeni półosi postaci $[\alpha, \infty)$ mamy $\Pi_{\mathbb{H}}(m) = m + 1$.
- Na ogół trudno znaleźć wzór na $\Pi_{\mathbb{H}}(m)$!!!

WYMIAR VAPNIKA-CHERVONENKISA

- Niech $\mathbf{x} = \{x_1, x_2, \dots, x_m\} \subset X$. Oznaczmy przez $\Pi_{\mathbb{H}}(\mathbf{x})$ liczbę podziałów zbioru \mathbf{x} dokonanych przez \mathbb{H} , t.j. liczbę różnych wektorów postaci

$$(h(x_1), \dots, h(x_m)) \in \{0, 1\}^m$$

po wszystkich $h \in H$.

- $\Pi_{\mathbb{H}}(\mathbf{x}) \leq 2^m$. Jeśli zachodzi równość, mówimy, że \mathbb{H} **rozbija** \mathbf{x} .
- Niech $\Pi_{\mathbb{H}}(m) = \max_{\mathbf{x} \in X^m} \Pi_{\mathbb{H}}(\mathbf{x})$
- Na przykład: W przypadku przestrzeni półosi postaci $[\alpha, \infty)$ mamy $\Pi_{\mathbb{H}}(m) = m + 1$.
- Na ogół trudno znaleźć wzór na $\Pi_{\mathbb{H}}(m)$!!!

WYMIAR VAPNIKA-CHERVONENKISA

- Niech $\mathbf{x} = \{x_1, x_2, \dots, x_m\} \subset X$. Oznaczmy przez $\Pi_{\mathbb{H}}(\mathbf{x})$ liczbę podziałów zbioru \mathbf{x} dokonanych przez \mathbb{H} , t.j. liczbę różnych wektorów postaci

$$(h(x_1), \dots, h(x_m)) \in \{0, 1\}^m$$

po wszystkich $h \in H$.

- $\Pi_{\mathbb{H}}(\mathbf{x}) \leq 2^m$. Jeśli zachodzi równość, mówimy, że \mathbb{H} **rozbija** \mathbf{x} .
- Niech $\Pi_{\mathbb{H}}(m) = \max_{\mathbf{x} \in X^m} \Pi_{\mathbb{H}}(\mathbf{x})$
- Na przykład:** W przypadku przestrzeni półosi postaci $[\alpha, \infty)$ mamy $\Pi_{\mathbb{H}}(m) = m + 1$.
- Na ogół trudno znaleźć wzór na $\Pi_{\mathbb{H}}(m)$!!!

WYMIAR VAPNIKA-CHERVONENKISA

- Niech $\mathbf{x} = \{x_1, x_2, \dots, x_m\} \subset X$. Oznaczmy przez $\Pi_{\mathbb{H}}(\mathbf{x})$ liczbę podziałów zbioru \mathbf{x} dokonanych przez \mathbb{H} , t.j. liczbę różnych wektorów postaci

$$(h(x_1), \dots, h(x_m)) \in \{0, 1\}^m$$

po wszystkich $h \in H$.

- $\Pi_{\mathbb{H}}(\mathbf{x}) \leq 2^m$. Jeśli zachodzi równość, mówimy, że \mathbb{H} **rozbija** \mathbf{x} .
- Niech $\Pi_{\mathbb{H}}(m) = \max_{\mathbf{x} \in X^m} \Pi_{\mathbb{H}}(\mathbf{x})$
- Na przykład:** W przypadku przestrzeni półosi postaci $[\alpha, \infty)$ mamy $\Pi_{\mathbb{H}}(m) = m + 1$.
- Na ogół trudno znaleźć wzór na $\Pi_{\mathbb{H}}(m)$!!!

WYMIAR VAPNIKA-CHERVONENKISA (C.D.)

Uwagi:

- Jeśli $\Pi_{\mathbb{H}}(m) = 2^m$, to \mathbb{H} rozbija prawie każdy zbiór o mocy m (prawie zawsze można znaleźć niesprzeczną hipotezę).
- Maksymalna wartość m , dla której $\Pi_{\mathbb{H}}(m) = 2^m$ można uważać za moc wyrażania przestrzeni \mathbb{H}

DEFINITION (VC DIMENSION)

Wymiarem Vapnika-Chervonenkisa przestrzeni hipotez \mathbb{H} nazywamy liczbę

$$VCdim(\mathbb{H}) = \max\{m : \Pi_{\mathbb{H}}(m) = 2^m\}$$

gdzie maksimum wynosi ∞ jeśli ten zbiór jest nieograniczony.

WYMIAR VAPNIKA-CHERVONENKISA (C.D.)

Uwagi:

- Jeśli $\Pi_{\mathbb{H}}(m) = 2^m$, to \mathbb{H} rozbija prawie każdy zbiór o mocy m (prawie zawsze można znaleźć niesprzeczną hipotezę).
- Maksymalna wartość m , dla której $\Pi_{\mathbb{H}}(m) = 2^m$ można uważać za moc wyrażania przestrzeni \mathbb{H}

DEFINITION (VC DIMENSION)

Wymiarem Vapnika-Chervonenkisa przestrzeni hipotez \mathbb{H} nazywamy liczbę

$$VCdim(\mathbb{H}) = \max\{m : \Pi_{\mathbb{H}}(m) = 2^m\}$$

gdzie maksimum wynosi ∞ jeśli ten zbiór jest nieograniczony.

WYMIAR VAPNIKA-CHERVONENKISA (C.D.)

Uwagi:

- Jeśli $\Pi_{\mathbb{H}}(m) = 2^m$, to \mathbb{H} rozbija prawie każdy zbiór o mocy m (prawie zawsze można znaleźć niesprzeczną hipotezę).
- Maksymalna wartość m , dla której $\Pi_{\mathbb{H}}(m) = 2^m$ można uważać za moc wyrażania przestrzeni \mathbb{H}

DEFINITION (VC DIMENSION)

Wymiarem Vapnika-Chervonenkisa przestrzeni hipotez \mathbb{H} nazywamy liczbę


$$VCdim(\mathbb{H}) = \max\{m : \Pi_{\mathbb{H}}(m) = 2^m\}$$

gdzie maksimum wynosi ∞ jeśli ten zbiór jest nieograniczony.

Przykłady wymiaru VC-Dim

- $H = \{\text{okręgi ...}\} \implies VC(H) = 3$
- $H = \{\text{prostokąty ...}\} \implies VC(H) = 4$
- $H = \{\text{funkcje progowe ...}\} \implies$
 $VC(H) = 1$ jeśli "+" są zawsze po prawej stronie;
 $VC(H) = 2$ jeśli "+" mogą być po obu stronach
- $H = \{\text{przedziały ...}\} \implies$
 $VC(H) = 2$ jeśli "+" są zawsze w środku
 $VC(H) = 3$ jeśli w środku mogą być zarówno "+" i "-"
- $H = \{\text{półpłaszczyzny w } \mathbb{R}^2 \text{ ...}\} \implies VC(H) = 3$
- czy istnieje H dla której $VC(H) = \infty$?
- Tw.: Jeśli $|\mathbb{H}| < \infty$ to $VCdim(\mathbb{H}) \leq \log |\mathbb{H}|$
- Niech $M_n =$ zbiór jednomianów boolowskich na n zmiennych. Ponieważ, $|M_n| = 3^n$ mamy


$$VCdim(M_n) \leq n \log 3$$



Przykłady wymiaru VC-Dim

- $H = \{\text{okręgi ...}\} \implies VC(H) = 3$
- $H = \{\text{prostokąty ...}\} \implies VC(H) = 4$
- $H = \{\text{funkcje progowe ...}\} \implies$
 $VC(H) = 1$ jeśli "+" są zawsze po prawej stronie;
 $VC(H) = 2$ jeśli "+" mogą być po obu stronach
- $H = \{\text{przedziały ...}\} \implies$
 $VC(H) = 2$ jeśli "+" są zawsze w środku
 $VC(H) = 3$ jeśli w środku mogą być zarówno "+" i "-"
- $H = \{\text{półpłaszczyzny w } \mathbb{R}^2 \text{ ...}\} \implies VC(H) = 3$
- czy istnieje H dla której $VC(H) = \infty$?
- Tw.: Jeśli $|\mathbb{H}| < \infty$ to $VCdim(\mathbb{H}) \leq \log |\mathbb{H}|$
- Niech $M_n =$ zbiór jednomianów boolowskich na n zmiennych. Ponieważ, $|M_n| = 3^n$ mamy


$$VCdim(M_n) \leq n \log 3$$



Przykłady wymiaru VC-Dim

- $H = \{\text{okręgi ...}\} \implies VC(H) = 3$
- $H = \{\text{prostokąty ...}\} \implies VC(H) = 4$
- $H = \{\text{funkcje progowe ...}\} \implies$
 $VC(H) = 1$ jeśli "+" są zawsze po prawej stronie;
 $VC(H) = 2$ jeśli "+" mogą być po obu stronach
- $H = \{\text{przedziały ...}\} \implies$
 $VC(H) = 2$ jeśli "+" są zawsze w środku
 $VC(H) = 3$ jeśli w środku mogą być zarówno "+" i "-"
- $H = \{\text{półpłaszczyzny w } \mathbb{R}^2 \text{ ...}\} \implies VC(H) = 3$
- czy istnieje H dla której $VC(H) = \infty$?
- Tw.: Jeśli $|\mathbb{H}| < \infty$ to $VCdim(\mathbb{H}) \leq \log |\mathbb{H}|$
- Niech $M_n =$ zbiór jednomianów boolowskich na n zmiennych. Ponieważ, $|M_n| = 3^n$ mamy


$$VCdim(M_n) \leq n \log 3$$



Przykłady wymiaru VC-Dim

- $H = \{\text{okręgi ...}\} \implies VC(H) = 3$
- $H = \{\text{prostokąty ...}\} \implies VC(H) = 4$
- $H = \{\text{funkcje progowe ...}\} \implies$
 $VC(H) = 1$ jeśli "+" są zawsze po prawej stronie;
 $VC(H) = 2$ jeśli "+" mogą być po obu stronach
- $H = \{\text{przedziały ...}\} \implies$
 $VC(H) = 2$ jeśli "+" są zawsze w środku
 $VC(H) = 3$ jeśli w środku mogą być zarówno "+" i "-"
- $H = \{\text{półpłaszczyzny w } \mathbb{R}^2 \text{ ...}\} \implies VC(H) = 3$
- czy istnieje H dla której $VC(H) = \infty$?
- Tw.: Jeśli $|\mathbb{H}| < \infty$ to $VCdim(\mathbb{H}) \leq \log |\mathbb{H}|$
- Niech $\mathcal{M}_n =$ zbiór jednomianów boolowskich na n zmiennych. Ponieważ, $|\mathcal{M}_n| = 3^n$ mamy


$$VCdim(\mathcal{M}_n) \leq n \log 3$$



Przykłady wymiaru VC-Dim

- $H = \{\text{okręgi ...}\} \implies VC(H) = 3$
- $H = \{\text{prostokąty ...}\} \implies VC(H) = 4$
- $H = \{\text{funkcje progowe ...}\} \implies$
 $VC(H) = 1$ jeśli "+" są zawsze po prawej stronie;
 $VC(H) = 2$ jeśli "+" mogą być po obu stronach
- $H = \{\text{przedziały ...}\} \implies$
 $VC(H) = 2$ jeśli "+" są zawsze w środku
 $VC(H) = 3$ jeśli w środku mogą być zarówno "+" i "-"
- $H = \{\text{półpłaszczyzny w } \mathbb{R}^2 \text{ ...}\} \implies VC(H) = 3$
- czy istnieje H dla której $VC(H) = \infty$?
- Tw.: Jeśli $|\mathbb{H}| < \infty$ to $VCdim(\mathbb{H}) \leq \log |\mathbb{H}|$
- Niech $M_n =$ zbiór jednomianów boolowskich na n zmiennych. Ponieważ, $|M_n| = 3^n$ mamy


$$VCdim(M_n) \leq n \log 3$$



Przykłady wymiaru VC-Dim

- $H = \{\text{okręgi ...}\} \implies VC(H) = 3$
- $H = \{\text{prostokąty ...}\} \implies VC(H) = 4$
- $H = \{\text{funkcje progowe ...}\} \implies$
 $VC(H) = 1$ jeśli “+” są zawsze po prawej stronie;
 $VC(H) = 2$ jeśli “+” mogą być po obu stronach
- $H = \{\text{przedziały ...}\} \implies$
 $VC(H) = 2$ jeśli “+” są zawsze w środku
 $VC(H) = 3$ jeśli w środku mogą być zarówno “+” i “-”
- $H = \{\text{półpłaszczyzny w } \mathbb{R}^2 \text{ ...}\} \implies VC(H) = 3$
- czy istnieje H dla której $VC(H) = \infty$?
- Tw.: Jeśli $|\mathbb{H}| < \infty$ to $VCdim(\mathbb{H}) \leq \log |\mathbb{H}|$
- Niech $M_n =$ zbiór jednomianów boolowskich na n zmiennych. Ponieważ, $|M_n| = 3^n$ mamy


$$VCdim(M_n) \leq n \log 3$$



Przykłady wymiaru VC-Dim

- $H = \{\text{okręgi ...}\} \implies VC(H) = 3$
- $H = \{\text{prostokąty ...}\} \implies VC(H) = 4$
- $H = \{\text{funkcje progowe ...}\} \implies$
 $VC(H) = 1$ jeśli “+” są zawsze po prawej stronie;
 $VC(H) = 2$ jeśli “+” mogą być po obu stronach
- $H = \{\text{przedziały ...}\} \implies$
 $VC(H) = 2$ jeśli “+” są zawsze w środku
 $VC(H) = 3$ jeśli w środku mogą być zarówno “+” i “-”
- $H = \{\text{półpłaszczyzny w } \mathbb{R}^2 \text{ ...}\} \implies VC(H) = 3$
- czy istnieje H dla której $VC(H) = \infty$?
- **Tw.:** Jeśli $|\mathbb{H}| < \infty$ to $VCdim(\mathbb{H}) \leq \log |\mathbb{H}|$
- Niech $M_n =$ zbiór jednomianów boolowskich na n zmiennych. Ponieważ, $|M_n| = 3^n$ mamy


$$VCdim(M_n) \leq n \log 3$$



Przykłady wymiaru VC-Dim

- $H = \{\text{okręgi ...}\} \implies VC(H) = 3$
- $H = \{\text{prostokąty ...}\} \implies VC(H) = 4$
- $H = \{\text{funkcje progowe ...}\} \implies$
 $VC(H) = 1$ jeśli “+” są zawsze po prawej stronie;
 $VC(H) = 2$ jeśli “+” mogą być po obu stronach
- $H = \{\text{przedziały ...}\} \implies$
 $VC(H) = 2$ jeśli “+” są zawsze w środku
 $VC(H) = 3$ jeśli w środku mogą być zarówno “+” i “-”
- $H = \{\text{półpłaszczyzny w } \mathbb{R}^2 \text{ ...}\} \implies VC(H) = 3$
- czy istnieje H dla której $VC(H) = \infty$?
- **Tw.:** Jeśli $|\mathbb{H}| < \infty$ to $VCdim(\mathbb{H}) \leq \log |\mathbb{H}|$
- Niech $M_n =$ zbiór jednomianów boolowskich na n zmiennych. Ponieważ, $|M_n| = 3^n$ mamy

$$VCdim(M_n) \leq n \log 3$$



WYMIAR VC DLA PERCEPTRONU

TWIERDZENIE

Dla każdej liczby naturalnej n , niech P_n będzie perceptronem o n wejściach rzeczywistych. Wówczas

$$VCdim(P_n) = n + 1$$

Dowód:

- $VCdim(P_n) \leq n + 1$:

Wynika z Twierdzenia Radona: Dla dowolnego zbioru E zawierającego $n + 2$ punktów w przestrzeni \mathbb{R}^n istnieje niepusty podzbiór $S \subset E$ taki, że

$$\text{conv}(S) \cap \text{conv}(E \setminus S) \neq \emptyset$$

- $VCdim(P_n) \geq n + 1$: Wystarczy wybrać $\mathbf{x} = \{0, e_1, \dots, e_n\}$ i pokazać, że każdy jego podzbiór jest definiowany przez jakiś perceptron.

LEMAT SAUER'A

THEOREM (LEMAT SAUER'A))

Jeśli $VCdim(\mathbb{H}) = d \geq 0$ i $m \geq 1$, to

$$\Pi_{\mathbb{H}}(m) \leq 1 + \underbrace{\binom{m}{1} + \binom{m}{2} + \dots + \binom{m}{d}}_{\Phi(d,m)}$$

Wnioski

$$\Phi(d, m) \leq \left(\frac{em}{d}\right)^d \Rightarrow \Pi_{\mathbb{H}}(m) \leq \left(\frac{em}{d}\right)^d$$

$$VCdim(\mathbb{H}) > \frac{\ln|\mathbb{H}|}{1 + \ln|X|}$$

SPIS TREŚCI

- 1 WPROWADZENIE DO TEORII UCZENIA SIĘ
- 2 MODEL PAC (PROBABLY APPROXIMATELY CORRECT)
- 3 WYUCZALNOŚĆ KLASY POJEŃ
- 4 WYMIAR VAPNIKA CHERVONENKISA (VC DIMENSION)
- 5 PODSTAWOWE TWIERDZENIA TEORII UCZENIA SIĘ

FUNDAMENTALNE TWIERDZENIA

THEOREM (WARUNEK KONIECZNY)

Każda przestrzeń hipotez o nieskończonym wymiarze VC nie jest potencjalnie wyuczalna.

THEOREM (FUNDAMENTALNE TWIERDZENIE)

Jeśli przestrzeń hipotez ma skończony wymiar VC , to jest ona potencjalnie wyuczalna.

FUNDAMENTALNE TWIERDZENIA

THEOREM (WARUNEK KONIECZNY)

Każda przestrzeń hipotez o nieskończonym wymiarze VC nie jest potencjalnie wyuczalna.

THEOREM (FUNDAMENTALNE TWIERDZENIE)

Jeśli przestrzeń hipotez ma skończony wymiar VC , to jest ona potencjalnie wyuczalna.

DOWÓD

- Definiujemy

$$Q_m^\varepsilon = \{\mathbf{x} \in X^m \mid H[\mathbf{x}, t] \cap B_\varepsilon \neq \emptyset\}$$

- Szukamy górnego ograniczenia $f(m, \varepsilon)$ dla $\mu^m(Q_m^\varepsilon)$, które powinno
 - być niezależne od t (target concept) i μ (rozkład prawdopodobieństwa).
 - dążyć do 0 przy $m \rightarrow \infty$
- Twierdzenie Niech \mathbb{H} będzie przestrzenią hipotez określonych na X . Dla dowolnych c, μ, ε (ale ustalonych) mamy

$$\mu^m(Q_m^\varepsilon) < 2\Pi_{\mathbb{H}}(2m)2^{-\varepsilon m/2}$$

o ile $m \geq 8/\varepsilon$.

- Możemy użyć lematu Sauer'a, aby pokazać, że $\mu^m(Q_m^\varepsilon) < \delta$ dla dostatecznie dużych m .

DOWÓD

- Definiujemy

$$Q_m^\varepsilon = \{\mathbf{x} \in X^m \mid H[\mathbf{x}, t] \cap B_\varepsilon \neq \emptyset\}$$

- Szukamy górnego ograniczenia $f(m, \varepsilon)$ dla $\mu^m(Q_m^\varepsilon)$, które powinno
 - być niezależne od t (target concept) i μ (rozkład prawdopodobieństwa).
 - dążyć do 0 przy $m \rightarrow \infty$
- Twierdzenie Niech \mathbb{H} będzie przestrzenią hipotez określonych na X . Dla dowolnych c, μ, ε (ale ustalonych) mamy

$$\mu^m(Q_m^\varepsilon) < 2\Pi_{\mathbb{H}}(2m)2^{-\varepsilon m/2}$$

o ile $m \geq 8/\varepsilon$.

- Możemy użyć lematu Sauer'a, aby pokazać, że $\mu^m(Q_m^\varepsilon) < \delta$ dla dostatecznie dużych m .

DOWÓD

- Definiujemy

$$Q_m^\varepsilon = \{\mathbf{x} \in X^m \mid H[\mathbf{x}, t] \cap B_\varepsilon \neq \emptyset\}$$

- Szukamy górnego ograniczenia $f(m, \varepsilon)$ dla $\mu^m(Q_m^\varepsilon)$, które powinno
 - być niezależne od t (target concept) i μ (rozkład prawdopodobieństwa).
 - dążyć do 0 przy $m \rightarrow \infty$
- Twierdzenie** Niech \mathbb{H} będzie przestrzenią hipotez określonych na X . Dla dowolnych c, μ, ε (ale ustalonych) mamy

$$\mu^m(Q_m^\varepsilon) < 2\Pi_{\mathbb{H}}(2m)2^{-\varepsilon m/2}$$

o ile $m \geq 8/\varepsilon$.

- Możemy użyć lematu Sauer'a, aby pokazać, że $\mu^m(Q_m^\varepsilon) < \delta$ dla dostatecznie dużych m .

DOWÓD

- Definiujemy

$$Q_m^\varepsilon = \{\mathbf{x} \in X^m \mid H[\mathbf{x}, t] \cap B_\varepsilon \neq \emptyset\}$$

- Szukamy górnego ograniczenia $f(m, \varepsilon)$ dla $\mu^m(Q_m^\varepsilon)$, które powinno
 - być niezależne od t (target concept) i μ (rozkład prawdopodobieństwa).
 - dążyć do 0 przy $m \rightarrow \infty$
- Twierdzenie** Niech \mathbb{H} będzie przestrzenią hipotez określonych na X . Dla dowolnych c, μ, ε (ale ustalonych) mamy

$$\mu^m(Q_m^\varepsilon) < 2\Pi_{\mathbb{H}}(2m)2^{-\varepsilon m/2}$$

o ile $m \geq 8/\varepsilon$.

- Mozemy użyć lematu Sauer'a, aby pokazać, że $\mu^m(Q_m^\varepsilon) < \delta$ dla dostatecznie dużych m .

ZŁOŻONOŚĆ ZBIORU TRENINGOWEGO

- Z Fundamentalnego Twierdzenia wynika, że jeśli $VCdim(\mathbb{H}) < \infty$, to dla danych δ i ε , istnieje $m_0 = m_0(\mathbb{H}, \delta, \varepsilon)$ takie, że

$$m \geq m_0 \Rightarrow \mu^m \{D \in \mathcal{S}(m, c) : \mathbb{H}[D] \cap \mathbb{B}_\varepsilon = \emptyset\} > 1 - \delta$$

- Wówczas każdy niesprzeczny algorytm \mathcal{L} jest PAC oraz wymagana liczba przykładów $m_L(\mathbb{H}, \delta, \varepsilon)$ dla \mathcal{L} jest ograniczona z góry przez $m_0(\mathbb{H}, \delta, \varepsilon)$.
- Dla skończonych przestrzeni hipotez \mathbb{H} mamy

$$m_L(\mathbb{H}, \delta, \varepsilon) \leq \left\lceil \frac{1}{\varepsilon} \ln \frac{|\mathbb{H}|}{\delta} \right\rceil = \left\lceil \frac{1}{\varepsilon} (\ln |\mathbb{H}| + \ln(1/\delta)) \right\rceil$$

ZŁOŻONOŚĆ ZBIORU TRENINGOWEGO (C.D.)

- **Twierdzenie** Niech $V\text{Cdim}(\mathbb{H}) = d \geq 1$. Wówczas każdy algorytm niesprzeczny \mathcal{L} jest PAC oraz wymagana liczba przykładów dla \mathcal{L} wynosi

$$m_L(\mathbb{H}, \delta, \varepsilon) \leq \left\lceil \frac{4}{\varepsilon} \left(d \log \frac{12}{\varepsilon} + \log \frac{2}{\delta} \right) \right\rceil$$

- Dolne ograniczenia:

- $m_L(\mathbb{H}, \delta, \varepsilon) \geq d(1 - \varepsilon)$
- Jeśli $\delta \leq 1/100$ i $\varepsilon \leq 1/8$, to $m_L(\mathbb{H}, \delta, \varepsilon) > \frac{d-1}{32\varepsilon}$
- $m_L(\mathbb{H}, \delta, \varepsilon) > \frac{1-\varepsilon}{\varepsilon} \ln \frac{1}{\delta}$