


Ada Boost



Dane: (x_i, y_i) , $i=1, \dots, N$, $y_i \in \{-1, 1\}$

$$\cdot C_0(x) = 0$$

$$\cdot C_m(x_i) = C_{m-1}(x_i) + \alpha_m k_m(x_i)$$

Jak dobierać α_m , klasyfikator $k_m : X \rightarrow \{-1, 1\}$? Tak, żeby zminimalizować funkcję kosztu:

$$E = \sum_{i=1}^N e^{-y_i C_m(x_i)} = \sum_{i=1}^N \underbrace{e^{-y_i C_{m-1}(x_i)}}_{w_i^{(m)}} e^{-y_i \alpha_m k_m(x_i)} = \\ = \sum_{i: y_i = k_m(x_i)} w_i^{(m)} e^{-\alpha_m} + \sum_{i: y_i \neq k_m(x_i)} w_i^{(m)} e^{\alpha_m} = \sum_{i=1}^N w_i^{(m)} e^{-\alpha_m} + \sum_{i: y_i \neq k_m(x_i)} w_i^{(m)} (e^{\alpha_m} - e^{-\alpha_m})$$

Dopasowujemy k_m tak, aby zminimalizować $\sum_{i: y_i \neq k_m(x_i)} w_i^{(m)}$. Mając ostateczne k_m , dobieramy α_m taki, aby zminimalizować E .

$$\alpha_m = \frac{1}{2} \ln \left[\left(\sum_{i: y_i = k_m(x_i)} w_i^{(m)} \right) / \left(\sum_{i: y_i \neq k_m(x_i)} w_i^{(m)} \right) \right]. \quad \begin{cases} \text{Otrzymujemy } C_m, \text{ ostateczna} \\ \text{klasyfikacja: } \text{sgn}(C_m(x)) \end{cases}$$

Tabela pomyłek (confusion matrix)

		należąca klasa	
predykcja klasa	-	+	
	-	a_{00}	a_{01}
+	a_{10}	a_{11}	

lubiąc obserwować

		należąca klasa	
pred.	-	+	
	-	TN	FN
+	FP	TP	

pojęcie, i.e. $TP = \text{true } +$

tego typu błędów
chętnie uniknąć

Mając wstępnie funkcję klasz: C

	$C(0,1)$
	$C(1,0)$

np.


	3
1	

$$\hat{P}^* = \frac{C(1,0)}{C(1,0) + C(0,1)}$$


$$\text{np. } \hat{P}^* = \frac{1}{1+9} = \frac{1}{10}$$

Jeli: $P(\neg x) \geq \hat{P}^*$, to klaszifikujemy x jako „-“

↑
estymowane prawdopodobieństwo tego, i.e.
x jest w klasie -




Kwadra ROC (receiver operator characteristics)



Pole pod krywą ROC jest pierw. miarą jakości klasyfikatora

klasyfikator, który bierze pod uwagę przynależność do jednej z klas: 2+: +
1-2: -



	$(1-\beta)N$	βN
-	$(1-\alpha)(1-\beta)N$	$(1-\alpha)\beta N$
+	$\alpha(1-\beta)N$	$\alpha\beta N$

Klasyfikator bayesowski

najbardziej prawdopodobny
przyporządkowywany obserwacji do klasy, tzn. rozszerzamy

$$\hat{y}_0 = \underset{k}{\operatorname{argmax}} P(Y=k | X=x_0)$$

(x_0, y_0) - obserwacja
+ jaka klasa

y_0 - przypisana klasa


Mocna struktura, ziekt, że błąd $E\left(\sum \frac{1}{N} \mathbb{1}(y_0 \neq \hat{y}_0)\right)$ jest największym możliwym dla klasyfikatora bayesowskiego

W praktyce nie znamy $P(Y=k | X=x_0)$, więc nie możemy użyć tego klasyfikatora.

↓
J. (x_0, y_0) mamy generować antypojęcie:

$$P(y_0=1) = \frac{1}{2}, \quad P(y_0=-1) = \frac{1}{2} \quad (\text{wysoki rozstęp})$$

Jest $y_0 = -1$, to $x_0 = u_0 + n$, $u_0 \sim U(-1, 0) \times (0, 1)$
 $n \sim N(0, \sigma^2 I)$ $u_0 \perp n$
 $y_0 = 1$, to $x_0 = u_1 + n$, $u_1 \sim U(0, 1) \times (0, 1)$ $u_1 \perp n$



LDA

(Linear Discriminant Analysis)

 $X \in \mathbb{R}^P$

Model

$$P(Y=k | X=x) = \frac{\pi_k \cdot f_k(x)}{\sum_{l=1}^L \pi_l f_l(x)},$$

$$\left| \begin{array}{l} P(A|B) = \\ \text{II} \\ \frac{P(A \cap B)}{P(B)} \end{array} \right. \quad \frac{P(B|A) P(A)}{P(B)}$$

gде $\pi_k = P(Y=k)$ — частота вхождения $f_k(x) = P(X=x | Y=k)$ функция густоты

$$P(X \in A | Y=k) = \int_A f_k(x) dx$$

Чтобы построить f_k , требуется, чтобы f_k имела конкретную форму

$$\underline{P=1} \quad f_k(x) = \frac{1}{\sqrt{2\pi} \sigma_k} \exp\left(-\frac{1}{2\sigma_k^2} (x - \mu_k)^2\right), \quad \mu_k, \sigma_k^2 — \text{быть мат. ожидание и дисперсия для } k\text{-го класса}$$

$$\underline{\text{LDA}}: \sigma_1^2 = \sigma_2^2 = \dots = \sigma_p^2 = \sigma^2 \quad \underline{(\text{QDA: как LDA, но без этого ограничения})}$$

Wtedy

$$P(Y=k|X=x) = \frac{\pi_k \cdot \frac{1}{\sqrt{2\pi}\sigma} \exp\left(-\frac{1}{2\sigma^2}(x-\mu_k)^2\right)}{\sum_{\ell=1}^K \pi_\ell \frac{1}{\sqrt{2\pi}\sigma} \exp\left(-\frac{1}{2\sigma^2}(x-\mu_\ell)^2\right)}$$

Przypomnijmy x klasę k, dla której powyższe wyrażenie jest największe

Mianowicie są takie same dla klas k, $k=1, \dots, K$, w których wystąpiły największe liczniki, lub jego logarytmy:

$$\log \pi_k + \underbrace{\log \frac{1}{\sqrt{2\pi}\sigma}}_{\text{stale}} - \frac{1}{2\sigma^2}(x-\mu_k)^2 = \log \pi_k + \log \frac{1}{\sqrt{2\pi}\sigma} - \frac{1}{2\sigma^2}x^2 + \frac{1}{\sigma^2}x\mu_k - \frac{1}{2\sigma^2}\mu_k^2$$

Czy $K=2$:

$$\log \pi_1 + \frac{1}{\sigma^2} x\mu_1 - \frac{1}{2\sigma^2} \mu_1^2 > \log \pi_2 + \frac{1}{\sigma^2} x\mu_2 - \frac{1}{2\sigma^2} \mu_2^2 \quad | \cdot \sigma^2$$

$\pi_1 = \pi_2$:

$$(x\mu_1 - x\mu_2) > \frac{1}{2}(\mu_2^2 - \mu_1^2) = \frac{1}{2}(\mu_1 - \mu_2)(\mu_1 + \mu_2)$$

jeśli $x < \frac{1}{2}(\mu_1 + \mu_2)$ to x jest klasyfikowany do klasy 1

