

SCHOOL
OF ENERGY
& POWER ENGINEERING

Обучение классификаторов

Сергей Владимирович Аксёнов,

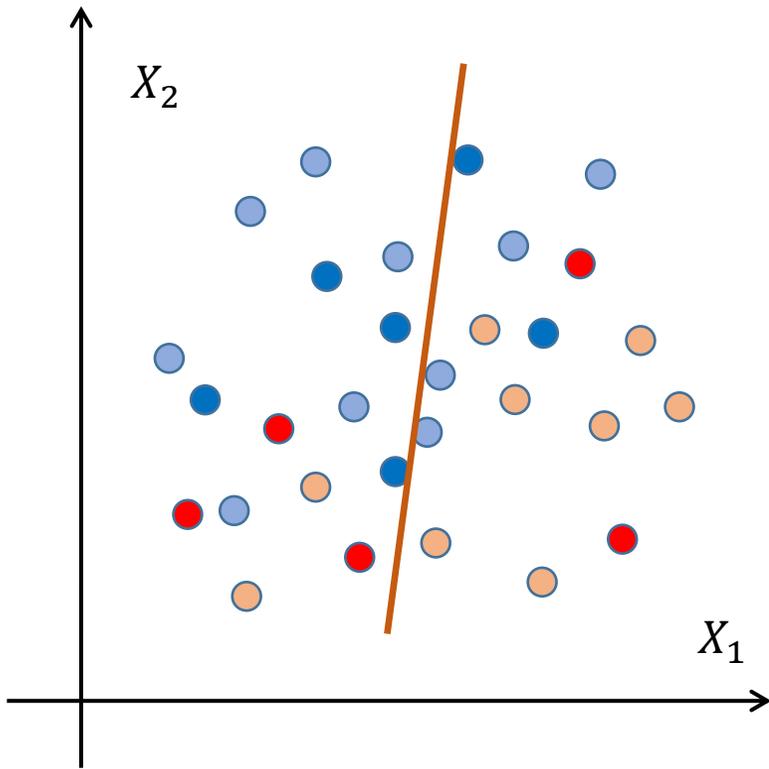
Доцент отделения информационных технологий ИШИТР,

Томский политехнический университет

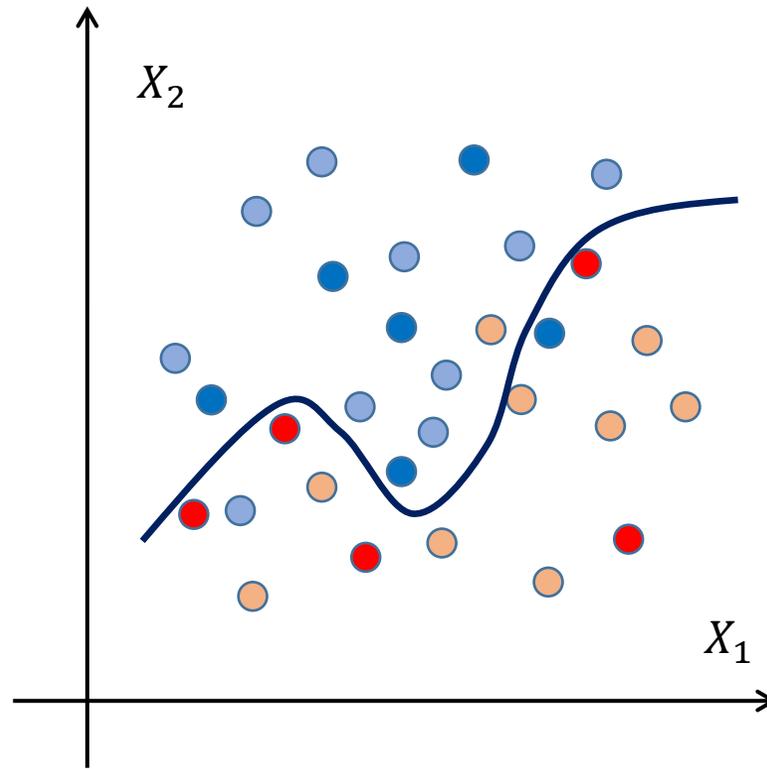
Томск-2023

Плохое и хорошее обучение

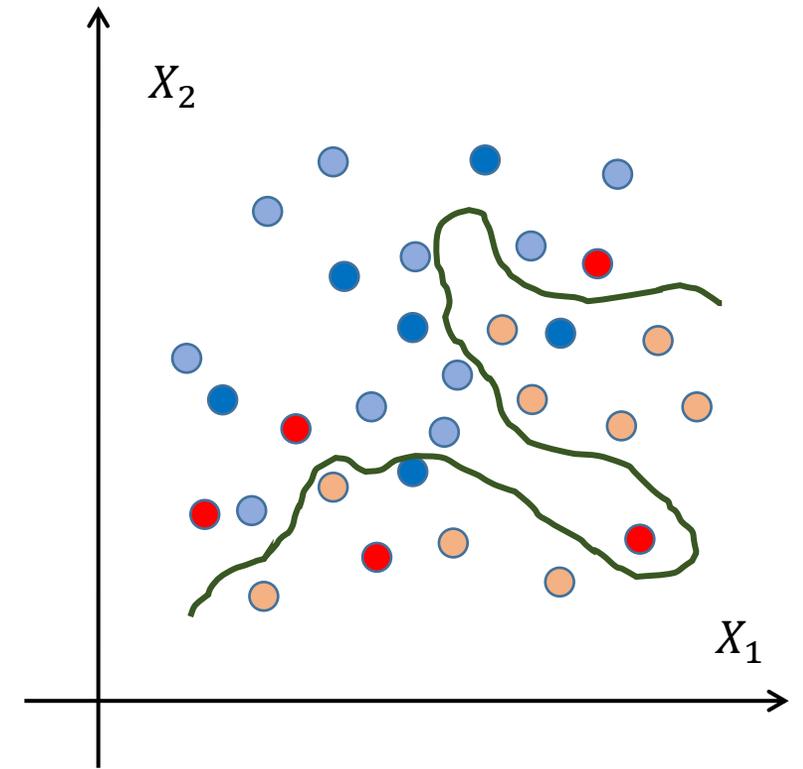
- Класс А (обучение)
- Класс В (обучение)
- Класс А (тест)
- Класс В (тест)



Недообучение



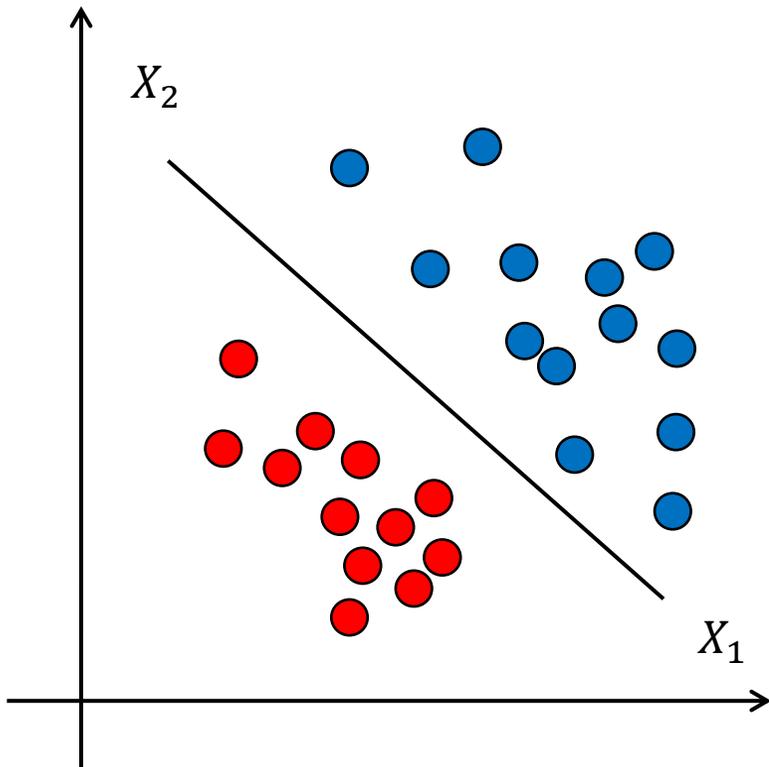
Хорошее обучение



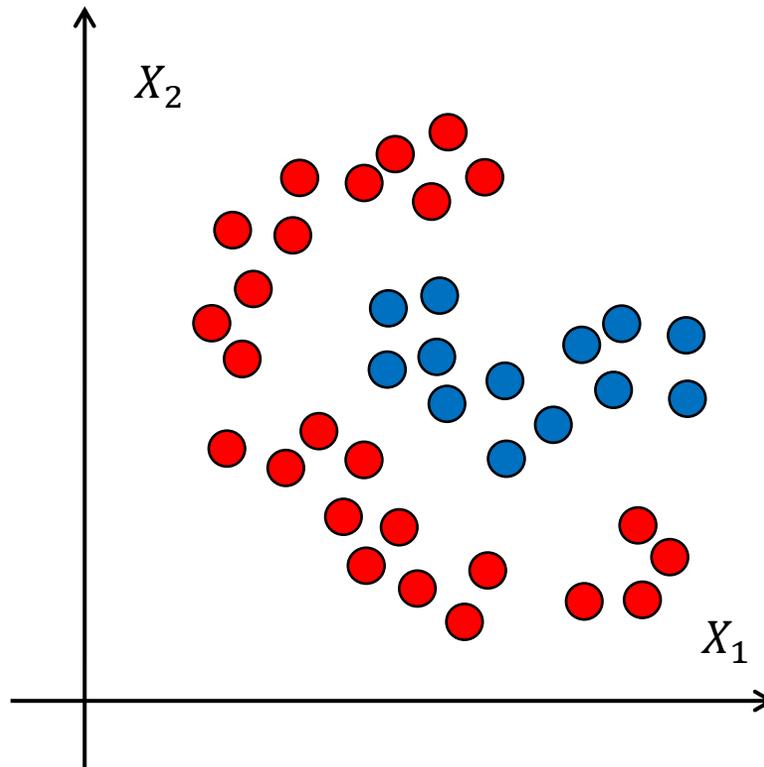
Переобучение

Линейно разделимые и линейно неразделимые классы

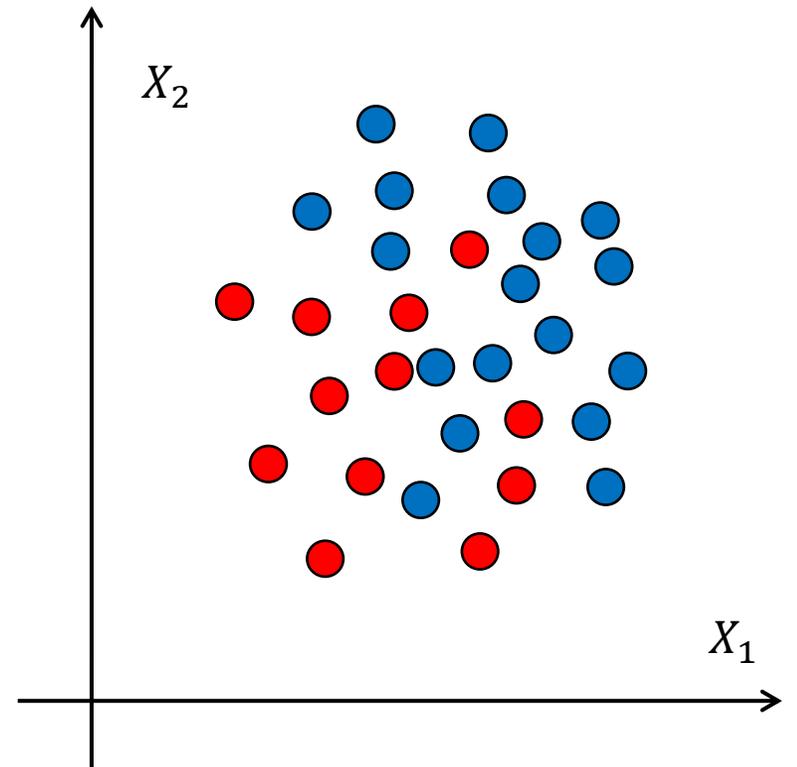
● Класс А ● Класс В



Линейно разделимые
классы



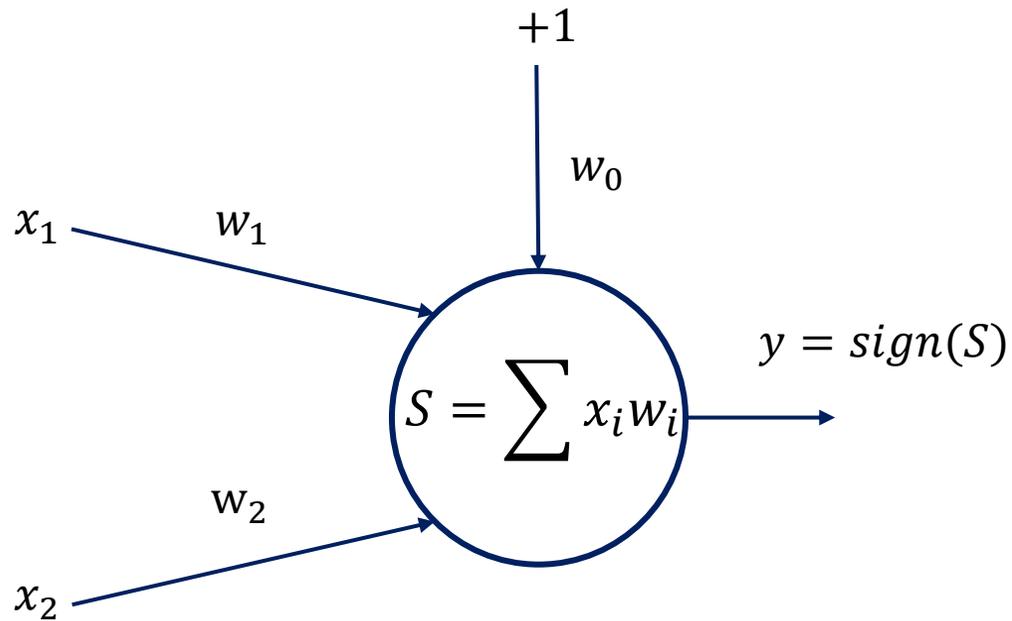
Линейно неразделимые
классы



Линейно неразделимые
классы

Бинарный линейный классификатор-1

Вектор признаков: $x = (x_1, x_2, x_3, \dots, x_N)$



Положительный класс
($\hat{y} = +1$)

Отрицательный класс
($\hat{y} = -1$)

Выход модели: $\hat{y} = \hat{y}(x, w) = \text{sign}\left(w_0 + \sum_i^N w_i x_i\right) = \text{sign}(w^T x)$

Бинарный линейный классификатор-2

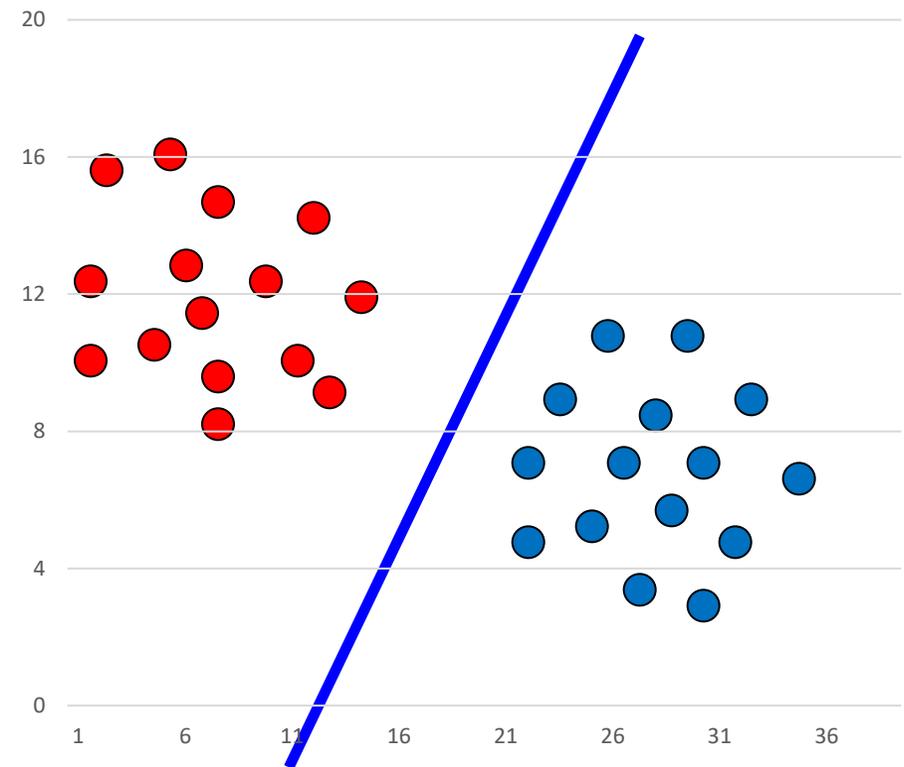
Результат обучения: входной вектор относится либо к положительному ($\hat{y}=+1$), либо отрицательному ($\hat{y}=-1$) классу

Вектор признаков:

$$x = (x_1, x_2, x_3, \dots, x_N)$$

Выход модели:

$$\hat{y} = \hat{y}(x, w) = \text{sign} \left(w_0 + \sum_i^N w_i x_i \right) = \text{sign}(w^T x)$$



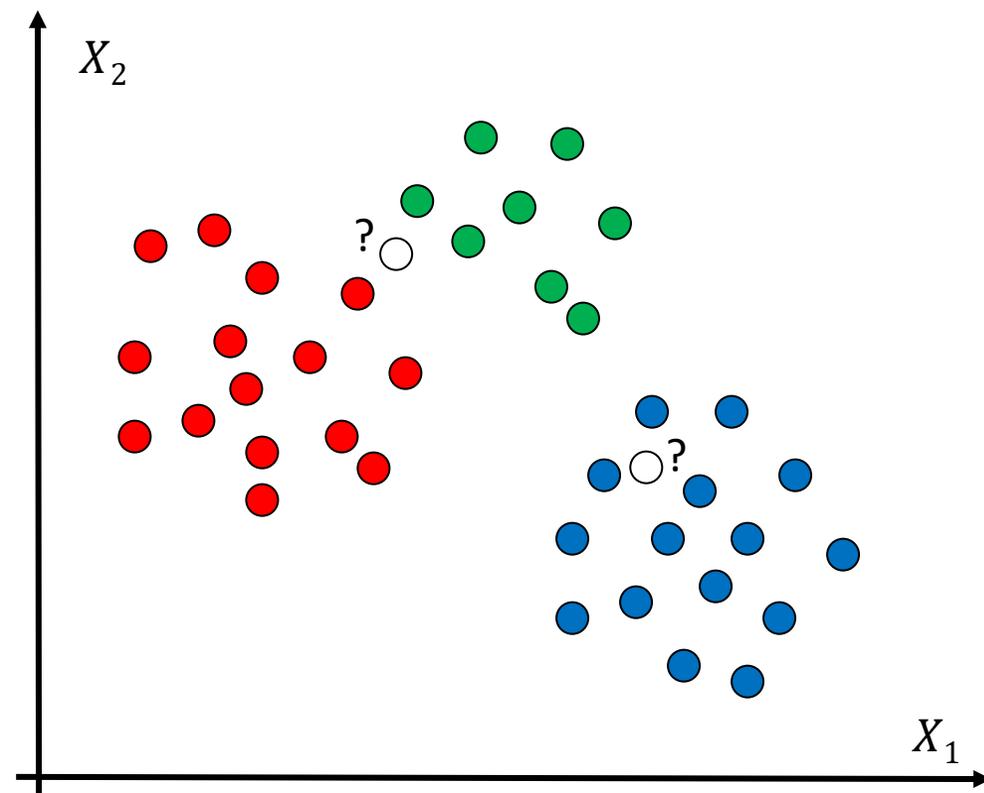
K-ближайших соседей

Нахождение набора объектов, чьи признаки близки к тестирующему примеру.

K – число соседей = 1, 3, 5

Приведение признаков к одинаковой шкале.

Требование по хранению всей выборки.



Расстояния

$$D = \sqrt{\sum_{i=1}^n (Q_i - P_i)^2}$$

Эвклидово расстояние

$$D = \sum_{i=1}^n \frac{|Q_i - P_i|}{|Q_i| + |P_i|}$$

Расстояние Канберры

$$D = \sum_{i=1}^n |Q_i - P_i|$$

Расстояние Манхэттена

$$D = \frac{1}{n} \sum_{i=1}^n (Q_i - P_i)^2$$

MSE Расстояние

Метод опорных векторов (Support Vector Machine)

Результат обучения: максимизация зазора (расстояния между разделяющей гиперплоскостью и самыми близкими к этой плоскости тренировочными образцами)

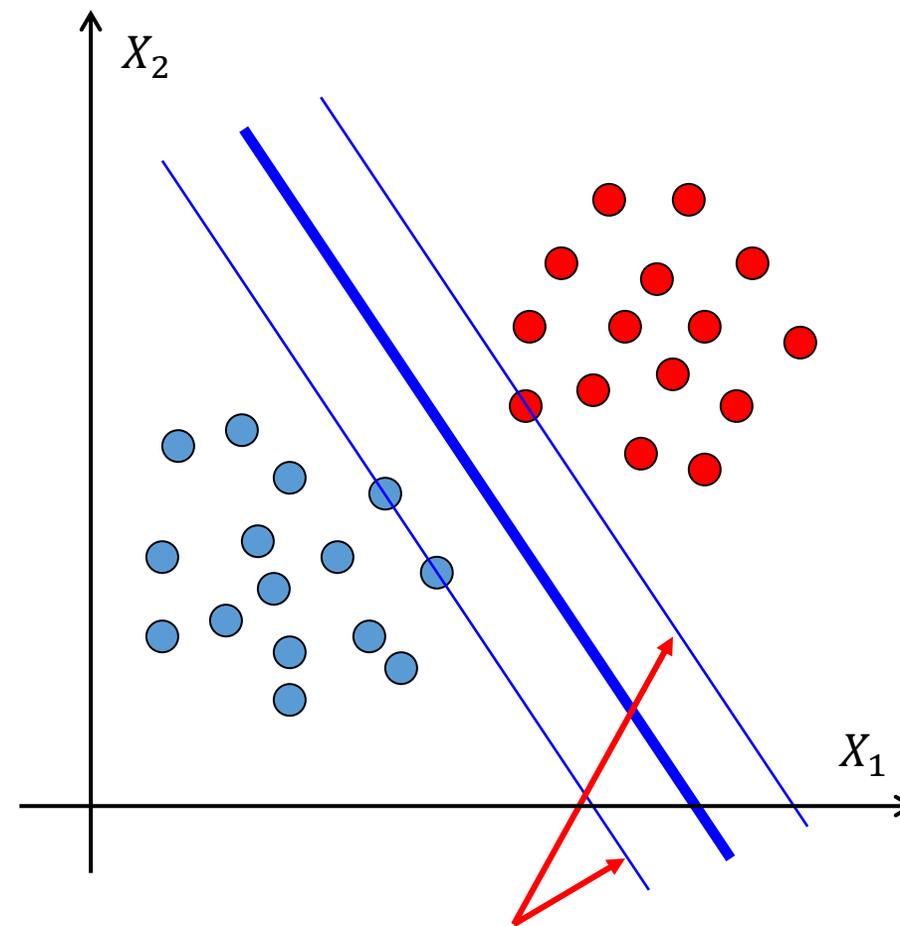
«Положительная» гиперплоскость: $w^T x = +1$

«Отрицательная» гиперплоскость: $w^T x = -1$

Граница решения: $w^T x = 0$

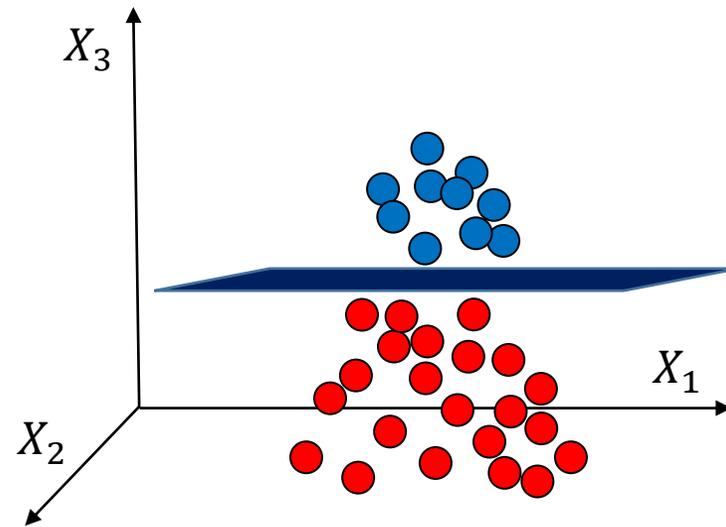
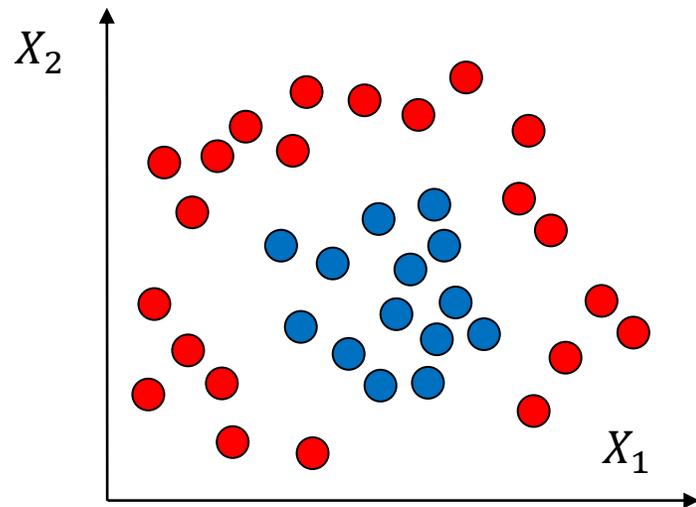
Целевая функция SVM: $\frac{2}{\|w\|} \rightarrow \max$

При ограничениях: $w_0 + w^T x^i \geq +1$, если $y^i = 1$
 $w_0 + w^T x^i < -1$, если $y^i = -1$

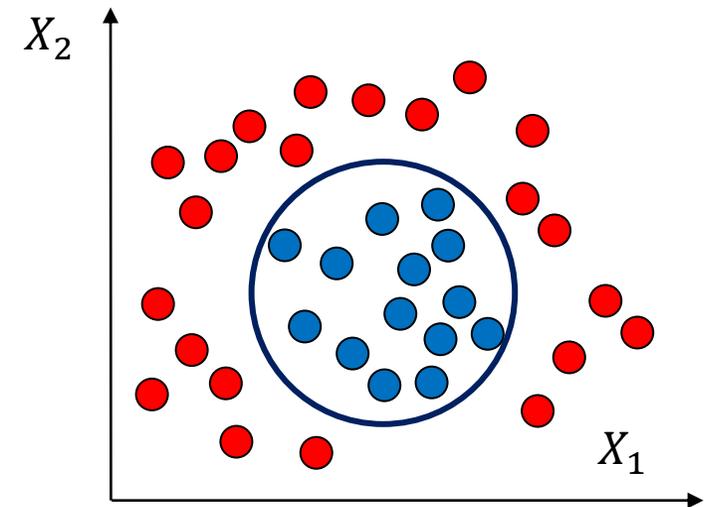


Опорные вектора

Ядерный трюк SVM



$$X_3 = \phi(X_1, X_2)$$



Наиболее популярные ядра

Radial-basis function (RBF) kernel: $k(x_i, x_j) = \exp\left(-\frac{d(x_i, x_j)^2}{2\sigma^2}\right)$ $d(x_i, x_j) = \|x_i - x_j\|$

Matérn kernel: $k(x_i, x_j) = \frac{1}{\Gamma(\nu)2^{\nu-1}} \left(\frac{\sqrt{2\nu}}{\sigma} d(x_i, x_j)\right)^\nu K_\nu\left(\frac{\sqrt{2\nu}}{\sigma} d(x_i, x_j)\right)$

Rational quadratic kernel: $k(x_i, x_j) = \left(1 + \frac{d(x_i, x_j)^2}{2\alpha\sigma^2}\right)^{-\alpha}$

Exp-Sine-Squared kernel: $k(x_i, x_j) = \exp\left(-\frac{2\sin^2(\pi d(x_i, x_j)/p)}{\sigma^2}\right)$

Dot-Product kernel: $k(x_i, x_j) = \sigma_0^2 + x_i \cdot x_j$

Логистическая регрессия

Прогнозируют вероятность p_+ отнесения примера x к классу $+1$

$$z = \sum_i^N w_i x_i$$

Функция стоимости

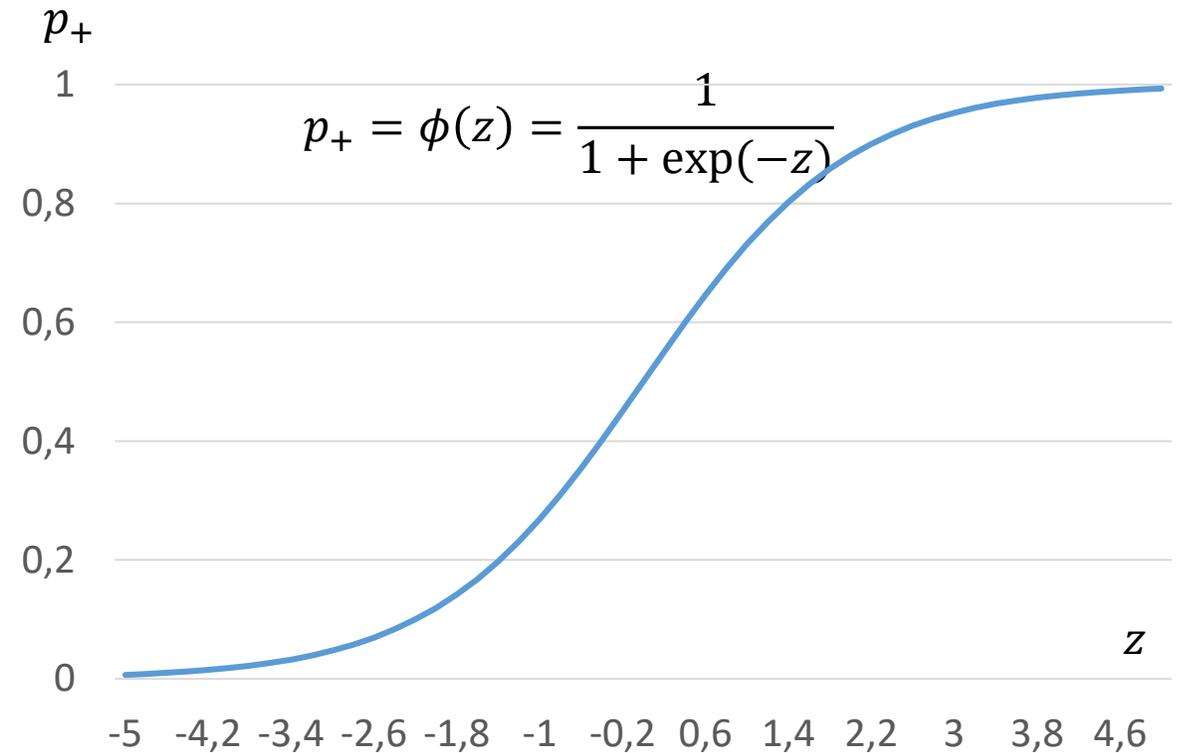
$$J(w) = \frac{1}{2} \sum_i (\phi(z^{(i)}) - y^{(i)})^2$$

Функция правдоподобия

$$L(w) = P(y|x; w) = \prod_{i=1}^n P(y^{(i)}|x^{(i)}; w) = \prod_{i=1}^n (\phi(z^{(i)}))^{y^{(i)}} \cdot (1 - \phi(z^{(i)}))^{1-y^{(i)}}$$

Логарифмическая функция правдоподобия

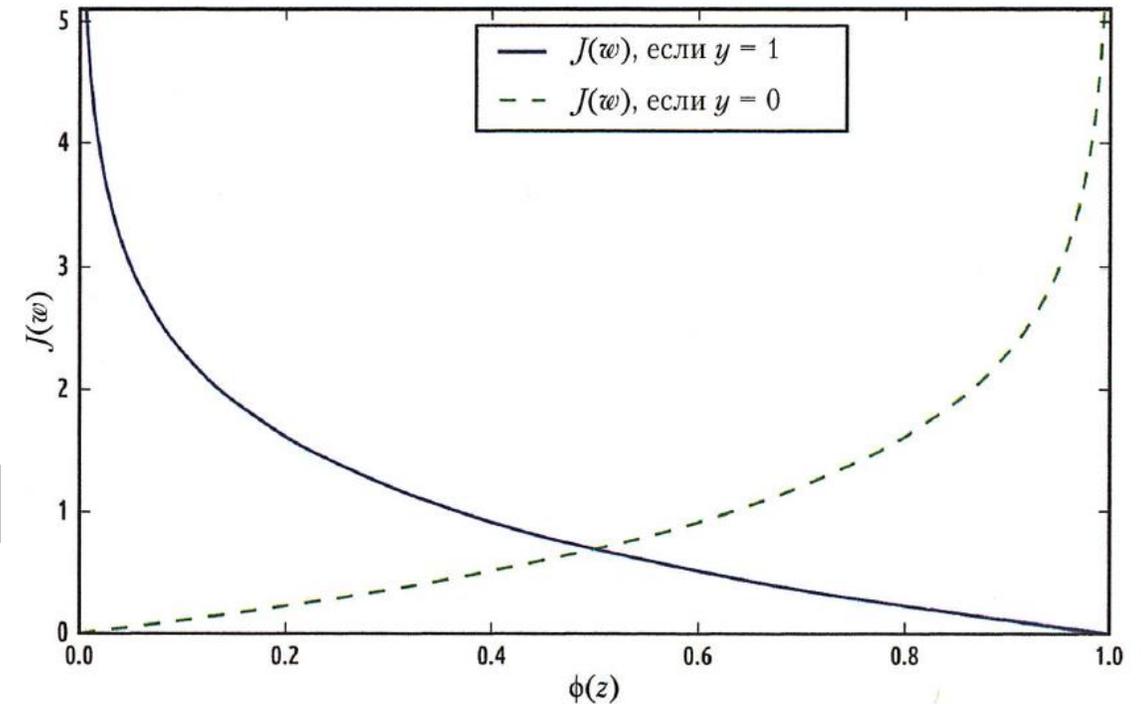
$$l(w) = \log L(w) = \sum_{i=1}^n [y^{(i)} \log(\phi(z^{(i)})) + (1 - y^{(i)}) \log(1 - \phi(z^{(i)}))]$$



Логистическая регрессия: обучение

Функция, используемая для поиска параметров модели

$$J(w) = \sum_{i=1}^n \left[-y^{(i)} \log(\phi(z^{(i)})) - (1 - y^{(i)}) \log(1 - \phi(z^{(i)})) \right]$$



Регуляризация

L2 - регуляризация $\frac{\lambda}{2} \|w\|_2^2 = \frac{\lambda}{2} \sum_{j=1}^m w_j^2$

Новая функция,
учитывающая штрафы $J(w) = \sum_{i=1}^n \left[-y^{(i)} \log(\phi(z^{(i)})) - (1 - y^{(i)}) \log(1 - \phi(z^{(i)})) \right] + \frac{\lambda}{2} \|w\|_2^2$

Дерево решений

Разбиение данных на подмножества, приводящему к самому большому приросту информации (получению однородных регионов решения)

Функция прироста информации:

$$IG(D_p, f) = I(D_p) - \frac{N_{left}}{N_p} I(D_{left}) - \frac{N_{right}}{N_p} I(D_{right})$$

Меры неоднородности

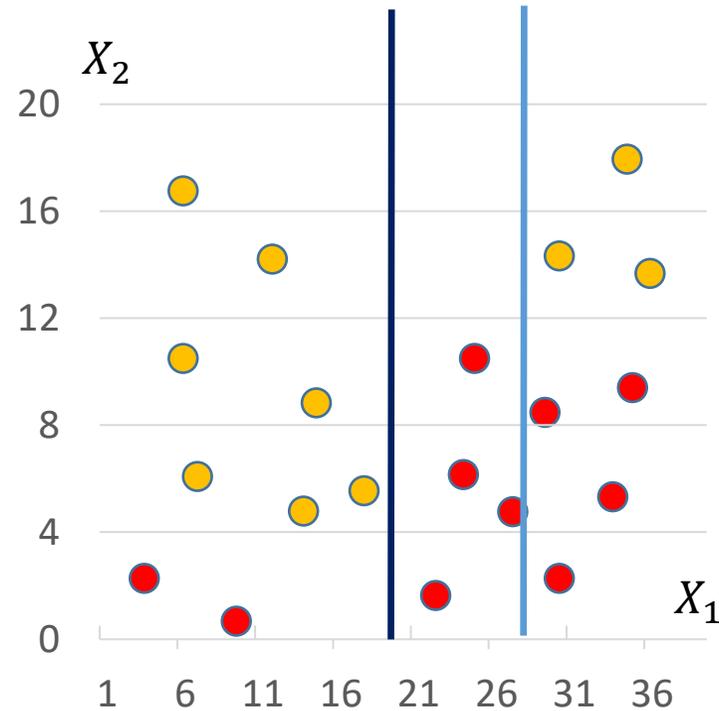
Энтропия: $I_G(t) = 1 - \sum_{i=1}^c p(i|t)^2$

Мера неопределенности Джини: $I_H(t) = - \sum_{i=1}^c p(i|t) \log_2 p(i|t)$

Ошибка классификации: $I_E(t) = 1 - \max(p(i|t))$

$p(i|t)$ - доля образцов, принадлежащая классу i для узла t

Дерево решений: пример-1



$$IG(D_p, f) = I(D_p) - \frac{N_{left}}{N_p} I(D_{left}) - \frac{N_{right}}{N_p} I(D_{right})$$

В качестве критерия взята ошибка классификации:

$$I_E(t) = 1 - \max(p(i|t))$$

Неоднородность корневого узла:

$$I(D_0) = 1 - \max\left(\frac{10}{20}, \frac{10}{20}\right) = 1 - 0.5 = 0.5$$

Для расщепления $x_1 = 20$: $IG(D_0, x_1 = 20) = 0.5 - \frac{9}{20} \left(1 - \frac{7}{9}\right) - \frac{11}{20} \left(1 - \frac{8}{11}\right) = 0.25$

Для расщепления $x_1 = 28$: $IG(D_0, x_1 = 28) = 0.5 - \frac{13}{20} \left(1 - \frac{7}{13}\right) - \frac{7}{20} \left(1 - \frac{4}{7}\right) = 0.05$

Дерево решений: пример-2

