

Метод опорных векторов  
Лекция N 7 курса  
“Алгоритмы для Интернета”

---

Юрий Лифшиц

ПОМИ РАН - СПбГУ ИТМО

Осень 2006

## Рекорд

Книга 1995 года “The Nature of Statistical Learning Theory” Владимира Вапника цитируется более **6400** раз

*Статистика Google Scholar*



1. Оптимальная разделяющая гиперплоскость
  - Случай линейной разделимости
  - Шумы и штрафы

1. Оптимальная разделяющая гиперплоскость
  - Случай линейной разделимости
  - Шумы и штрафы
2. Обучение машины опорных векторов
  - Постановка задачи квадратичной оптимизации
  - Метод последовательных мини-оптимизаций

- 1 Оптимальная разделяющая гиперплоскость
  - Случай линейной делимости
  - Шумы и штрафы
- 2 Обучение машины опорных векторов
  - Постановка задачи квадратичной оптимизации
  - Метод последовательных мини-оптимизаций
- 3 Расширение пространства признаков

## Часть I

Формальная постановка задачи классификации

Как выбрать лучший линейный классификатор?

Как определить уровень ошибки линейного  
классификатора?

## Абстрактная задача классификации

**Объекты:** вектора  $n$ -мерного пространства

Каждая **координата** соответствует признаку

**Категории:** сегодня рассматриваем только бинарную классификацию (две категории)

## Абстрактная задача классификации

**Объекты:** вектора  $n$ -мерного пространства

Каждая **координата** соответствует признаку

**Категории:** сегодня рассматриваем только бинарную классификацию (две категории)

**Учебная коллекция:** даны документы (вектора)

$x_1, \dots, x_n$  и их принадлежность к двум классам

$y_1, \dots, y_n \in \{1, -1\}$



## Абстрактная задача классификации

**Объекты:** вектора  $n$ -мерного пространства

Каждая **координата** соответствует признаку

**Категории:** сегодня рассматриваем только бинарную классификацию (две категории)

**Учебная коллекция:** даны документы (вектора)

$x_1, \dots, x_n$  и их принадлежность к двум классам

$y_1, \dots, y_n \in \{1, -1\}$

Цель ученых: построить по учебной коллекции


**оптимальное** классифицирующее правило

**заданного** вида.

## Линейный классификатор (1/3)

$$w \cdot x_i > b \Rightarrow y_i = 1$$

$$w \cdot x_i < b \Rightarrow y_i = -1$$




## Линейный классификатор (2/3)

### Разделение полосой:

$$w \cdot x_i \geq b + \varepsilon \Rightarrow y_i = 1$$

$$w \cdot x_i \leq b - \varepsilon \Rightarrow y_i = -1$$



## Линейный классификатор (3/3)

Умножив  $w$  на  $\frac{1}{\varepsilon}$ , можем считать  $\varepsilon = 1$ :

$$w \cdot x_i - b \geq 1 \Rightarrow y_i = 1$$

$$w \cdot x_i - b \leq -1 \Rightarrow y_i = -1$$

## Линейный классификатор (3/3)

Домножив  $w$  на  $\frac{1}{\varepsilon}$ , можем считать  $\varepsilon = 1$ :

$$w \cdot x_i - b \geq 1 \Rightarrow y_i = 1$$

$$w \cdot x_i - b \leq -1 \Rightarrow y_i = -1$$

Как выбрать наилучшую разделяющую полосу?

## Линейный классификатор (3/3)

Умножив  $w$  на  $\frac{1}{\varepsilon}$ , можем считать  $\varepsilon = 1$ :

$$w \cdot x_i - b \geq 1 \Rightarrow y_i = 1$$

$$w \cdot x_i - b \leq -1 \Rightarrow y_i = -1$$

Как выбрать наилучшую разделяющую полосу?

Выберем самую **широкую**

Факт: ширина полосы равна  $\frac{2}{\|w\|}$

Переформулировка поиска оптимальной разделяющей полосы в виде задачи **квадратичной оптимизации**:

**При ограничениях**

$$y_i(w \cdot x_i - b) \geq 1$$

**минимизировать**

$$\|w\|^2 = w \cdot w$$

## Шумы и штрафы

Как определить оптимальную полосу, когда категории нельзя разделить строго?



## Шумы и штрафы

Как определить оптимальную полосу, когда категории нельзя разделить строго?

Нужно определить штраф за неправильную классификацию учебных документов и минимизировать сумму  $\|w\|^2$  и всех штрафов:

**При ограничениях**

$$y_i(w \cdot x_i - b) \geq 1 - \xi_i, \quad \xi_i \geq 0$$

**минимизировать**

$$\|w\|^2 + C \sum \xi_i$$

## Часть II

Как решить задачу оптимизации?

Можно ли найти оптимальную гиперплоскость, не зная самих векторов, а только скалярные произведения между ними?

## Множители Лагранжа (1/2)

Метод Лагранжа для нахождения минимума целевой функции при нескольких условиях-равенствах:

- Ввести дополнительные переменные (множители Лагранжа)  $\lambda_i$  и составить новую целевую функцию  $F - \sum \lambda_i G_i$

## Множители Лагранжа (1/2)

Метод Лагранжа для нахождения минимума целевой функции при нескольких условиях-равенствах:

- Ввести дополнительные переменные (множители Лагранжа)  $\lambda_i$  и составить новую целевую функцию  $F - \sum \lambda_i G_i$
- Взять все производные по старым переменным (координатам  $x$ ) и приравнять их к нулю

## Множители Лагранжа (1/2)

Метод Лагранжа для нахождения минимума целевой функции при нескольких условиях-равенствах:

- Ввести дополнительные переменные (множители Лагранжа)  $\lambda_i$  и составить новую целевую функцию  $F - \sum \lambda_i G_i$
- Взять все производные по старым переменным (координатам  $x$ ) и приравнять их к нулю
- С помощью получившихся уравнений выразить  $x$  через  $\lambda_1, \dots, \lambda_k$

## Множители Лагранжа (1/2)

Метод Лагранжа для нахождения минимума целевой функции при нескольких условиях-равенствах:

- Ввести дополнительные переменные (множители Лагранжа)  $\lambda_i$  и составить новую целевую функцию  $F - \sum \lambda_i G_i$
- Взять все производные по старым переменным (координатам  $x$ ) и приравнять их к нулю
- С помощью получившихся уравнений выразить  $x$  через  $\lambda_1, \dots, \lambda_k$
- Подставить получившуюся формулу для  $x$  в  $k$  ограничений-равенств и решить эти  $k$  уравнений с  $k$  неизвестными

## Множители Лагранжа (2/2)

Метод Лагранжа для нахождения минимума целевой функции при нескольких условиях-неравенствах:

- Ввести дополнительные переменные (множители Лагранжа)  $\lambda_i \geq 0$  и составить новую целевую функцию  $F - \sum \lambda_i G_i$

## Множители Лагранжа (2/2)

Метод Лагранжа для нахождения минимума целевой функции при нескольких условиях-**н**еравенствах:

- Ввести дополнительные переменные (множители Лагранжа)  $\lambda_i \geq 0$  и составить новую целевую функцию  $F - \sum \lambda_i G_i$
- Взять все производные по старым переменным (координатам  $x$ ) и приравнять их к нулю



## Множители Лагранжа (2/2)

Метод Лагранжа для нахождения минимума целевой функции при нескольких условиях-**н**еравенствах:

- Ввести дополнительные переменные (множители Лагранжа)  $\lambda_i \geq 0$  и составить новую целевую функцию  $F - \sum \lambda_i G_i$
- Взять все производные по старым переменным (координатам  $x$ ) и приравнять их к нулю
- С помощью получившихся уравнений выразить  $x$  через  $\lambda_1, \dots, \lambda_k$

## Множители Лагранжа (2/2)

Метод Лагранжа для нахождения минимума целевой функции при нескольких условиях-неравенствах:

- Ввести дополнительные переменные (множители Лагранжа)  $\lambda_i \geq 0$  и составить новую целевую функцию  $F - \sum \lambda_i G_i$
- Взять все производные по старым переменным (координатам  $x$ ) и приравнять их к нулю
- С помощью получившихся уравнений выразить  $x$  через  $\lambda_1, \dots, \lambda_k$
- Для каждого ограничения-неравенства верно одно из двух:  
(1) или в том условии выполняется строгое равенство, или  
(2) соответствующий множитель  $\lambda_i$  равен нулю. Получается  $k$  “или-уравнений” для  $k$  переменных

## Применим метод Лагранжа (1/3)

**Исходная задача:** при ограничениях

$$y_i(w \cdot x_i - b) \geq 1 - \xi_i$$

минимизировать

$$w \cdot w + C \sum \xi_i$$

## Применим метод Лагранжа (1/3)

**Исходная задача:** при ограничениях

$$y_i(w \cdot x_i - b) \geq 1 - \xi_i$$

минимизировать

$$w \cdot w + C \sum \xi_i$$

По методу Лагранжа, нам нужен минимум по  $w, b, \xi_i$  и максимум по  $\lambda_i$  новой целевой функции

$$w \cdot w + C \sum \xi_i - \sum \lambda_i (\xi_i + y_i(w \cdot x_i - b) - 1)$$

при условиях

$$\xi_i \geq 0, \lambda_i \geq 0$$

## Применим метод Лагранжа (2/3)

Вектор  $w$  выражается через множители Лагранжа:

$$w = \sum \lambda_i y_i x_i$$

Уравнение разделяющей гиперплоскости:

$$\sum \lambda_i y_i x \cdot x_i + b = 0$$

## Применим метод Лагранжа (2/3)

Вектор  $w$  выражается через множители Лагранжа:

$$w = \sum \lambda_i y_i x_i$$

Уравнение разделяющей гиперплоскости:

$$\sum \lambda_i y_i x \cdot x_i + b = 0$$

Постойте, а как найти  $b$ ?

## Применим метод Лагранжа (3/3)

Решению исходной задачи оптимизации соответствуют такие значения множителей, при которых достигается максимум

$$\sum \lambda_i - \sum_{i,j} \lambda_i \lambda_j y_i y_j (x_i \cdot x_j)$$

при условиях

$$\sum \lambda_i y_i = 0, \quad 0 \leq \lambda_i \leq C$$

## Преимущества новой задачи

Новая (двойственная) задача: максимизировать

$$\sum \lambda_i - \sum_{i,j} \lambda_i \lambda_j y_i y_j (x_i \cdot x_j)$$

при условиях

$$\sum \lambda_i y_i = 0, \quad 0 \leq \lambda_i \leq C$$

### Важные свойства:



Целевая функция зависит не от самих  $x_i$ ,  
а от скалярных произведений между ними  
Только пограничные и “заграничные” учебные  
влияют на итоговое правило



## Как решать двойственную задачу

Алгоритм Джона Платта (Microsoft Research):

- 1 Начать с набора  $\lambda_i$  удовлетворяющего ограничением
- 2 Выбрать (используются хитрые эвристики) пару  $\lambda_i, \lambda_j$
- 3 При фиксированных значениях остальных множителей и имеющихся ограничениях  $y_i \lambda_i + y_j \lambda_j = y_i \lambda_i^{old} + y_j \lambda_j^{old}$  и  $0 \leq \lambda_i, \lambda_j \leq C$  выбрать оптимальную пару значений (**мини-оптимизация**)
- 4 Продолжать процесс до наступления стоп-условий



## Часть III

Как применить разработанную технику к поиску оптимального разделяющего **эллипса**?

Обобщение метода оптимальной полосы на произвольные поверхности, заданные полиномиальными уравнениями

## Идея расширенного пространства

Машина опорных векторов:

- Выбираем отображение векторов в **расширенное пространство**  $x \rightarrow \phi(x)$
- Автоматически получается новая функция скалярного произведения  $K(x, y) = \phi(x) \cdot \phi(y)$
- Находим линейный разделитель  $w, b$  в расширенном пространстве
- Получается классифицирующая поверхность  $w \cdot \phi(x) - b$  в исходном пространстве

## Два примера

$$\phi(x) = \phi((x_1, x_2)) \rightarrow (x_1^2, x_2^2, \sqrt{2}x_1x_2)$$

$$K(x, y) = x_1^2y_1^2 + x_2^2y_2^2 + 2x_1x_2y_1y_2 = (x \cdot y)^2$$


## Два примера

$$\phi(x) = \phi((x_1, x_2)) \rightarrow (x_1^2, x_2^2, \sqrt{2}x_1x_2)$$

$$K(x, y) = x_1^2y_1^2 + x_2^2y_2^2 + 2x_1x_2y_1y_2 = (x \cdot y)^2$$

$$\phi(x) = (1, c_{10\dots 0}x_1, \dots, c_{110\dots 0}x_1x_2, \dots, c_{0\dots 0d}x_k^d)$$

$$K(x, y) = (1 + x \cdot y)^d$$



## Полиномиальные разделители

Второй пример:

$$\phi(x) = (1, c_{10\dots 0}x_1, \dots, c_{110\dots 0}x_1x_2, \dots, c_{0\dots 0d}x_k^d)$$

$$K(x, y) = (1 + x \cdot y)^d$$

Разделяющая гиперплоскость  $w \cdot \phi(x) - b$  — это полином степени не выше  $d$ . То есть мы ищем

**оптимальную полиномиальную разделяющую поверхность!**

Преимущества:

Преимущества:

- + На тестах  
превосходит другие  
методы



Преимущества:

- + На тестах  
превосходит другие  
методы
- + При различных  
выборах ядер  
можно  
эмулировать  
другие подходы

Преимущества:

- + На тестах  
превосходит другие  
методы
- + При различных  
выборах ядер  
можно  
эмулировать  
другие подходы
- + Теоретическое  
обоснование

Преимущества:

- + На тестах  
превосходит другие  
методы
- + При различных  
выборах ядер  
можно  
эмулировать  
другие подходы
- + Теоретическое  
обоснование

Преимущества:

- + На тестах превосходит другие методы
- + При различных выборах ядер можно эмулировать другие подходы
- + Теоретическое обоснование

Недостатки:

## Анализ метода SVM

### Преимущества:

- + На тестах превосходит другие методы
- + При различных выборах ядер можно эмулировать другие подходы
- + Теоретическое обоснование

### Недостатки:

- Мало параметров для настройки

## Анализ метода SVM

### Преимущества:

- + На тестах превосходит другие методы
- + При различных выборах ядер можно эмулировать другие подходы
- + Теоретическое обоснование

### Недостатки:

- Мало параметров для настройки
- Как выбирать ядро?

# Анализ метода SVM

## Преимущества:

- + На тестах превосходит другие методы
- + При различных выборах ядер можно эмулировать другие подходы
- + Теоретическое обоснование

## Недостатки:

- Мало параметров для настройки
- Как выбирать ядро?
- Медленное обучение

Докажите, что гиперплоскость с максимальной шириной разделяющей полосы единственна



### Сегодня мы узнали:

- Метод опорных векторов сводит обучение классификатора к задаче квадратичной оптимизации

### Сегодня мы узнали:

- Метод опорных векторов сводит обучение классификатора к задаче квадратичной оптимизации
- Задача квадратичной оптимизации решается эвристическими алгоритмами путем последовательного уменьшения целевой функции

### Сегодня мы узнали:

- Метод опорных векторов сводит обучение классификатора к задаче квадратичной оптимизации
- Задача квадратичной оптимизации решается эвристическими алгоритмами путем последовательного уменьшения целевой функции
- Для построения нелинейных классификаторов используется отображение исходных объектов в расширенное пространство признаков

### Сегодня мы узнали:

- Метод опорных векторов сводит обучение классификатора к задаче квадратичной оптимизации
- Задача квадратичной оптимизации решается эвристическими алгоритмами путем последовательного уменьшения целевой функции
- Для построения нелинейных классификаторов используется отображение исходных объектов в расширенное пространство признаков

### Сегодня мы узнали:

- Метод опорных векторов сводит обучение классификатора к задаче квадратичной оптимизации
- Задача квадратичной оптимизации решается эвристическими алгоритмами путем последовательного уменьшения целевой функции
- Для построения нелинейных классификаторов используется отображение исходных объектов в расширенное пространство признаков

Вопросы?

Страница курса <http://logic.pdmi.ras.ru/~yura/internet.html>

Использованные материалы:



Wikipedia

Support Vector machine

[http://en.wikipedia.org/wiki/Support\\_vector\\_machine](http://en.wikipedia.org/wiki/Support_vector_machine)



CJC Burges

A Tutorial on Support Vector Machines for Pattern Recognition

<http://www.music.mcgill.ca/~rfergu/adamTex/references/Burges98.pdf>



Константин Воронцов

Лекция по методу опорных векторов

<http://www.ccas.ru/voron/download/SVM.pdf>



John Platt

Sequential Minimal Optimization

<http://research.microsoft.com/users/jplatt/smo.html>