

# PAC-Bayes оценки и их приложения в машинном обучении

И. О. Толстыхин, ВЦ РАН

[iliya.tolstikhin@gmail.com](mailto:iliya.tolstikhin@gmail.com)

октябрь 2012

## Основная тема доклада — теория обобщающей способности

- Какие **гарантии** о качестве настраиваемого по обучающей выборке алгоритма мы можем получать?
- Какие **ограничения** на свойства рассматриваемой задачи при этом нужны?
- Применимы ли такие результаты на практике?
- Если да — то как их применять?

## Основная тема доклада — теория обобщающей способности

- Какие **гарантии** о качестве настраиваемого по обучающей выборке алгоритма мы можем получать?
- Какие **ограничения** на свойства рассматриваемой задачи при этом нужны?
- Применимы ли такие результаты на практике?
- Если да — то как их применять?

## Основная тема доклада — теория обобщающей способности

- Какие **гарантии** о качестве настраиваемого по обучающей выборке алгоритма мы можем получать?
- Какие **ограничения** на свойства рассматриваемой задачи при этом нужны?
- Применимы ли такие результаты на практике?
- Если да — то как их применять?

# Основная тема доклада — теория обобщающей способности

- Какие **гарантии** о качестве настраиваемого по обучающей выборке алгоритма мы можем получать?
- Какие **ограничения** на свойства рассматриваемой задачи при этом нужны?
- Применимы ли такие результаты на практике?
- Если да — то как их применять?

PAC-Bayes подход:

«Одни из самых точных оценок обобщающей способности».

«Одни из самых простых доказательств оценок».

# Содержание

## 1 Введение

- Теория статистического обучения
- Байесовский подход
- PAC-Bayes подход к переобучению

## 2 PAC-Bayes оценки

- Определения и постановка задачи
- Основные теоремы PAC-Bayes

## 3 Улучшения и приложения PAC-Bayes

- Приложения: линейные классификаторы
- Выбор априорного распределения

## Определения: Statistical Learning Theory (SLT)

$\mathbb{X}$  и  $\mathbb{Y}$  — пространства объектов и ответов.

На  $\mathbb{X} \times \mathbb{Y}$  задано вероятностное распределение  $P$ .

Обучающая выборка  $\{X_i, Y_i\}_{i=1}^\ell$  — простая (i.i.d) из  $P$ .

$\mathcal{G}$  — множество классификаторов  $g: \mathbb{X} \rightarrow \mathbb{Y}$ .

Функция потерь  $r: \mathbb{Y} \times \mathbb{Y} \rightarrow \mathbb{R}^+$ . Пусть  $r \in [0, 1]$ .

(положим  $r(y_1, y_2) = [y_1 \neq y_2]$  — классификация)

Риск классификатора:

$$Pg \stackrel{\text{def}}{=} \mathbb{E}_{(X, Y) \sim P} r(g(X), Y).$$

Эмпирический риск классификатора:

$$P_\ell g \stackrel{\text{def}}{=} \frac{1}{\ell} \sum_{i=1}^\ell r(g(X_i), Y_i).$$

## Определения: Statistical Learning Theory (SLT)

$\mathbb{X}$  и  $\mathbb{Y}$  — пространства объектов и ответов.

На  $\mathbb{X} \times \mathbb{Y}$  задано вероятностное распределение  $P$ .

Обучающая выборка  $\{X_i, Y_i\}_{i=1}^\ell$  — простая (i.i.d) из  $P$ .

$\mathcal{G}$  — множество классификаторов  $g: \mathbb{X} \rightarrow \mathbb{Y}$ .

Функция потерь  $r: \mathbb{Y} \times \mathbb{Y} \rightarrow \mathbb{R}^+$ . Пусть  $r \in [0, 1]$ .

(положим  $r(y_1, y_2) = [y_1 \neq y_2]$  — классификация)

Риск классификатора:

$$Pg \stackrel{\text{def}}{=} \mathbb{E}_{(X, Y) \sim P} r(g(X), Y).$$

Эмпирический риск классификатора:

$$P_\ell g \stackrel{\text{def}}{=} \frac{1}{\ell} \sum_{i=1}^\ell r(g(X_i), Y_i).$$

## Определения: Statistical Learning Theory (SLT)

$\mathbb{X}$  и  $\mathbb{Y}$  — пространства объектов и ответов.

На  $\mathbb{X} \times \mathbb{Y}$  задано вероятностное распределение  $P$ .

Обучающая выборка  $\{X_i, Y_i\}_{i=1}^\ell$  — простая (i.i.d) из  $P$ .

$\mathcal{G}$  — множество классификаторов  $g: \mathbb{X} \rightarrow \mathbb{Y}$ .

Функция потерь  $r: \mathbb{Y} \times \mathbb{Y} \rightarrow \mathbb{R}^+$ . Пусть  $r \in [0, 1]$ .

(положим  $r(y_1, y_2) = [y_1 \neq y_2]$  — классификация)

Риск классификатора:

$$Pg \stackrel{\text{def}}{=} \mathbb{E}_{(X, Y) \sim P} r(g(X), Y).$$

Эмпирический риск классификатора:

$$P_\ell g \stackrel{\text{def}}{=} \frac{1}{\ell} \sum_{i=1}^{\ell} r(g(X_i), Y_i).$$

## Определения: Statistical Learning Theory (SLT)

$\mathbb{X}$  и  $\mathbb{Y}$  — пространства объектов и ответов.

На  $\mathbb{X} \times \mathbb{Y}$  задано вероятностное распределение  $P$ .

Обучающая выборка  $\{X_i, Y_i\}_{i=1}^\ell$  — простая (i.i.d) из  $P$ .

$\mathcal{G}$  — множество классификаторов  $g: \mathbb{X} \rightarrow \mathbb{Y}$ .

Функция потерь  $r: \mathbb{Y} \times \mathbb{Y} \rightarrow \mathbb{R}^+$ . Пусть  $r \in [0, 1]$ .

(положим  $r(y_1, y_2) = [y_1 \neq y_2]$  — классификация)

Риск классификатора:

$$Pg \stackrel{\text{def}}{=} \mathbb{E}_{(X, Y) \sim P} r(g(X), Y).$$

Эмпирический риск классификатора:

$$P_\ell g \stackrel{\text{def}}{=} \frac{1}{\ell} \sum_{i=1}^\ell r(g(X_i), Y_i).$$

## Определения: Statistical Learning Theory (SLT)

$\mathbb{X}$  и  $\mathbb{Y}$  — пространства объектов и ответов.

На  $\mathbb{X} \times \mathbb{Y}$  задано вероятностное распределение  $P$ .

Обучающая выборка  $\{X_i, Y_i\}_{i=1}^\ell$  — простая (i.i.d) из  $P$ .

$\mathcal{G}$  — множество классификаторов  $g: \mathbb{X} \rightarrow \mathbb{Y}$ .

Функция потерь  $r: \mathbb{Y} \times \mathbb{Y} \rightarrow \mathbb{R}^+$ . Пусть  $r \in [0, 1]$ .

(положим  $r(y_1, y_2) = [y_1 \neq y_2]$  — классификация)

Риск классификатора:

$$Pg \stackrel{\text{def}}{=} \mathbb{E}_{(X, Y) \sim P} r(g(X), Y).$$

Эмпирический риск классификатора:

$$P_\ell g \stackrel{\text{def}}{=} \frac{1}{\ell} \sum_{i=1}^\ell r(g(X_i), Y_i).$$

## Определения: Statistical Learning Theory (SLT)

$\mathbb{X}$  и  $\mathbb{Y}$  — пространства объектов и ответов.

На  $\mathbb{X} \times \mathbb{Y}$  задано вероятностное распределение  $P$ .

Обучающая выборка  $\{X_i, Y_i\}_{i=1}^\ell$  — простая (i.i.d) из  $P$ .

$\mathcal{G}$  — множество классификаторов  $g: \mathbb{X} \rightarrow \mathbb{Y}$ .

Функция потерь  $r: \mathbb{Y} \times \mathbb{Y} \rightarrow \mathbb{R}^+$ . Пусть  $r \in [0, 1]$ .

(положим  $r(y_1, y_2) = [y_1 \neq y_2]$  — классификация)

Риск классификатора:

$$Pg \stackrel{\text{def}}{=} \mathbb{E}_{(X, Y) \sim P} r(g(X), Y).$$

Эмпирический риск классификатора:

$$P_\ell g \stackrel{\text{def}}{=} \frac{1}{\ell} \sum_{i=1}^\ell r(g(X_i), Y_i).$$

## Границы применимости SLT

Мы ввели следующие ограничения:

- Распределение  $P$  фиксировано и неизвестно;
- Обучающая выборка — независимые, одинаково распределенные с. в. из  $P$ .
- Все выборки, которые мы можем наблюдать в будущем, также простые из  $P$ .

## Этап обучения

Мы хотим минимизировать риск:

$$Pg \stackrel{\text{def}}{=} E_{(X, Y) \sim P} r(g(X), Y) \rightarrow \min_{g \in \mathcal{G}}.$$

Но распределение  $P$  **неизвестно**, поэтому мы будем минимизировать эмпирический риск:

$$P_\ell g \stackrel{\text{def}}{=} \frac{1}{\ell} \sum_{i=1}^{\ell} r(g(X_i), Y_i) \rightarrow \min_{g \in \mathcal{G}}. \quad (\text{МЭР})$$

Решение задачи (МЭР) —  $g^\ell$ .

## Основные задачи SLT

- Изучение поведения случайной величины  $Pg^\ell$ .
  - generalization bounds:  
относительно ее эмпирического риска  $P_{\ell} g^\ell$ ;
  - excess risk bounds:  
относительно риска лучшего в классе  $\mathcal{G}$  классификатора  
 $g^* = \arg \min_{g \in \mathcal{G}} Pg$ ;
  - ...
- Выбор оптимального множества  $\mathcal{G}$  (model selection).
  - Structural Risk Minimization;
  - Oracle inequalities;
  - Complexity penalization;
  - ...

## Основные задачи SLT

- Изучение поведения случайной величины  $Pg^\ell$ .
  - generalization bounds:  
относительно ее эмпирического риска  $P_{\ell}g^\ell$ ;
  - excess risk bounds:  
относительно риска лучшего в классе  $\mathcal{G}$  классификатора  
 $g^* = \arg \min_{g \in \mathcal{G}} Pg$ ;
  - ...
- Выбор оптимального множества  $\mathcal{G}$  (model selection).
  - Structural Risk Minimization;
  - Oracle inequalities;
  - Complexity penalization;
  - ...

## Основные задачи SLT

- Изучение поведения случайной величины  $Pg^\ell$ .
  - generalization bounds:  
относительно ее эмпирического риска  $P_{\ell g}^\ell$ ;
  - excess risk bounds:  
относительно риска лучшего в классе  $\mathcal{G}$  классификатора  
 $g^* = \arg \min_{g \in \mathcal{G}} Pg$ ;
  - ...
- Выбор оптимального множества  $\mathcal{G}$  (model selection).
  - Structural Risk Minimization;
  - Oracle inequalities;
  - Complexity penalization;
  - ...

## Основные задачи SLT

- Изучение поведения случайной величины  $Pg^\ell$ .
  - generalization bounds:  
относительно ее эмпирического риска  $P_{\ell g}^\ell$ ;
  - excess risk bounds:  
относительно риска лучшего в классе  $\mathcal{G}$  классификатора  
 $g^* = \arg \min_{g \in \mathcal{G}} Pg$ ;
  - ...
- Выбор оптимального множества  $\mathcal{G}$  (model selection).
  - Structural Risk Minimization;
  - Oracle inequalities;
  - Complexity penalization;
  - ...

## Классические результаты: VC-теория

Для всех  $g \in \mathcal{G}$  с вероятностью не меньше  $1 - \delta$  относительно случайных реализаций обучающей выборки справедливо:

$$Pg \leq P_{\ell}g + C(\mathcal{G}, \ell, \delta),$$

где  $C$  — характеристика **сложности** класса  $\mathcal{G}$  (complexity):

- конечный класс  $\mathcal{G}$ :

$$C(\mathcal{G}, \ell, \delta) = \sqrt{\frac{\ln |\mathcal{G}| + \ln \frac{1}{\delta}}{2\ell}}, \text{ где } |\mathcal{G}| — \text{множество.}$$

- бесконечный (несчетный) класс  $\mathcal{G}$ :

$$C(\mathcal{G}, \ell, \delta) = \sqrt{2 \frac{\ln S_{\mathcal{G}}(2\ell) + \ln \frac{2}{\delta}}{\ell}}, \text{ где } S_{\mathcal{G}}(\ell) — \text{функция роста.}$$

## Классические результаты: VC-теория

Для всех  $g \in \mathcal{G}$  с вероятностью не меньше  $1 - \delta$  относительно случайных реализаций обучающей выборки справедливо:

$$Pg \leq P_{\ell}g + C(\mathcal{G}, \ell, \delta),$$

где  $C$  — характеристика сложности класса  $\mathcal{G}$  (complexity):

- конечный класс  $\mathcal{G}$ :

$$C(\mathcal{G}, \ell, \delta) = \sqrt{\frac{\ln |\mathcal{G}| + \ln \frac{1}{\delta}}{2\ell}}, \text{ где } |\mathcal{G}| — \text{мощность.}$$

- бесконечный (несчетный) класс  $\mathcal{G}$ :

$$C(\mathcal{G}, \ell, \delta) = \sqrt{2 \frac{\ln S_{\mathcal{G}}(2\ell) + \ln \frac{2}{\delta}}{\ell}}, \text{ где } S_{\mathcal{G}}(\ell) — \text{функция роста.}$$

## Классические результаты: VC-теория

Для всех  $g \in \mathcal{G}$  с вероятностью не меньше  $1 - \delta$  относительно случайных реализаций обучающей выборки справедливо:

$$Pg \leq P_{\ell}g + C(\mathcal{G}, \ell, \delta),$$

где  $C$  — характеристика сложности класса  $\mathcal{G}$  (complexity):

- конечный класс  $\mathcal{G}$ :

$$C(\mathcal{G}, \ell, \delta) = \sqrt{\frac{\ln |\mathcal{G}| + \ln \frac{1}{\delta}}{2\ell}}, \text{ где } |\mathcal{G}| — \text{мощность.}$$

- бесконечный (несчетный) класс  $\mathcal{G}$ :

$$C(\mathcal{G}, \ell, \delta) = \sqrt{2 \frac{\ln S_{\mathcal{G}}(2\ell) + \ln \frac{2}{\delta}}{\ell}}, \text{ где } S_{\mathcal{G}}(\ell) — \text{функция роста.}$$

## Что гарантируется?

Для большинства обучающих выборок, вытянутых независимо из любого фиксированного распределения  $P$ , нам удалось ограничить сверху риск классификатора  $g^\ell$ .

## Что гарантируется?

Для большинства обучающих выборок, вытянутых независимо из любого фиксированного распределения  $P$ , нам удалось ограничить сверху риск классификатора  $g^\ell$ .



## Проблемы

Оценки **сильно** завышены (иногда  $C(\mathcal{G}, \ell, \delta) \approx 10^8$ ),  
потому что:

## Проблемы

Оценки **сильно** завышены (иногда  $C(\mathcal{G}, \ell, \delta) \approx 10^8$ ),  
потому что:

- не зависят от алгоритма  $g^\ell$ ;

## Проблемы

Оценки **сильно** завышены (иногда  $C(\mathcal{G}, \ell, \delta) \approx 10^8$ ),  
потому что:

- не зависят от алгоритма  $g^\ell$ ;
- не зависят от обучающей выборки;
- ...

## Проблемы

Оценки **сильно** завышены (иногда  $C(\mathcal{G}, \ell, \delta) \approx 10^8$ ),  
потому что:

- не зависят от алгоритма  $g^\ell$ ;
- не зависят от обучающей выборки;
- ...

Значит, не применимы на практике.

## Проблемы

Оценки **сильно** завышены (иногда  $C(\mathcal{G}, \ell, \delta) \approx 10^8$ ),  
потому что:

- не зависят от алгоритма  $g^\ell$ ;
- не зависят от обучающей выборки;
- ...

Значит, не применимы на практике.



## Уточнения оценок

Основные источники улучшений:

- теория эмпирических процессов;
- концентрационные неравенства.

## Уточнения оценок

Основные источники улучшений:

- теория эмпирических процессов;
- концентрационные неравенства.

P. Bartlett, O. Bousquet, S. Mendelson. (2005)

*Local Rademacher Complexities.*

P. Bartlett, S. Mendelson. (2006)

*Empirical Risk Minimization.*

O. Bousquet, V. Koltchinskii, D. Panchenko. (2002)

*Some local measures of complexity of convex hulls and generalization bounds.*

V. Koltchinskii. (2006)

*Local Rademacher Complexities and Oracle Inequalities in Risk Minimization.*

V. Koltchinskii, D. Panchenko. (2000)

*Rademacher processes and bounding the risk of function learning.*

P. Massart. (2000)

*Some applications of concentration inequalities to statistics.*

## Общая идея байесовского подхода (MAP)

- Экспертно определяем априорное распределение на параметрах модели:

$$P(\theta).$$

- Вычисляем апостериорное распределение:

$$P(\theta|X^\ell) \sim P(X^\ell|\theta)P(\theta).$$

- Максимизируем апостериорное распределение:

$$P(\theta|X^\ell) \rightarrow \max_{\theta};$$

$$\ln P(X^\ell|\theta) + \ln P(\theta) \rightarrow \max_{\theta}.$$

## Цель PAC-Bayes

Взять лучшее от обеих подходов:

## Цель PAC-Bayes

Взять лучшее от обеих подходов:

от байесовского

- Возможность введения в модель информативного априора;

## Цель PAC-Bayes

Взять лучшее от обеих подходов:

от байесовского

- Возможность введения в модель информативного априора;

от статистического

- Количественные гарантии о работе классификатора на контрольных данных;
- При этом никаких требований о правильности априора.

## PAC-Bayes: Определения

$\mathbb{X}$  и  $\mathbb{Y}$  — пространства объектов и ответов. ( $\mathbb{Y} = \{-1, +1\}$ ).

На  $\mathbb{X} \times \mathbb{Y}$  задано вероятностное распределение  $P$ .

Обучающая выборка  $\{X_i, Y_i\}_{i=1}^\ell$  — простая (i.i.d) из  $P$ .

$\mathcal{G}$  — множество классификаторов  $g: \mathbb{X} \rightarrow \mathbb{Y}$ .

Функция потерь  $r: \mathbb{Y} \times \mathbb{Y} \rightarrow \mathbb{R}^+$ .

(положим  $r(y_1, y_2) = [y_1 \neq y_2]$  — классификация)

Риск классификатора:

$$R(g) \stackrel{\text{def}}{=} \mathbb{E}_{(X, Y) \sim P} r(g(X), Y).$$

Эмпирический риск классификатора:

$$R_\ell(g) \stackrel{\text{def}}{=} \frac{1}{\ell} \sum_{i=1}^{\ell} r(g(X_i), Y_i).$$

## PAC-Bayes: Определения

$\mathbb{X}$  и  $\mathbb{Y}$  — пространства объектов и ответов. ( $\mathbb{Y} = \{-1, +1\}$ ).

На  $\mathbb{X} \times \mathbb{Y}$  задано вероятностное распределение  $P$ .

Обучающая выборка  $\{X_i, Y_i\}_{i=1}^\ell$  — простая (i.i.d) из  $P$ .

$\mathcal{G}$  — множество классификаторов  $g: \mathbb{X} \rightarrow \mathbb{Y}$ .

Функция потерь  $r: \mathbb{Y} \times \mathbb{Y} \rightarrow \mathbb{R}^+$ .

(положим  $r(y_1, y_2) = [y_1 \neq y_2]$  — классификация)

Риск классификатора:

$$R(g) \stackrel{\text{def}}{=} \mathbb{E}_{(X, Y) \sim P} r(g(X), Y).$$

Эмпирический риск классификатора:

$$R_\ell(g) \stackrel{\text{def}}{=} \frac{1}{\ell} \sum_{i=1}^{\ell} r(g(X_i), Y_i).$$

## PAC-Bayes: Определения

$\mathbb{X}$  и  $\mathbb{Y}$  — пространства объектов и ответов. ( $\mathbb{Y} = \{-1, +1\}$ ).

На  $\mathbb{X} \times \mathbb{Y}$  задано вероятностное распределение  $P$ .

Обучающая выборка  $\{X_i, Y_i\}_{i=1}^\ell$  — простая (i.i.d) из  $P$ .

$\mathcal{G}$  — множество классификаторов  $g: \mathbb{X} \rightarrow \mathbb{Y}$ .

Функция потерь  $r: \mathbb{Y} \times \mathbb{Y} \rightarrow \mathbb{R}^+$ .

(положим  $r(y_1, y_2) = [y_1 \neq y_2]$  — классификация)

Риск классификатора:

$$R(g) \stackrel{\text{def}}{=} \mathbb{E}_{(X, Y) \sim P} r(g(X), Y).$$

Эмпирический риск классификатора:

$$R_\ell(g) \stackrel{\text{def}}{=} \frac{1}{\ell} \sum_{i=1}^{\ell} r(g(X_i), Y_i).$$

## PAC-Bayes: Определения

$\mathbb{X}$  и  $\mathbb{Y}$  — пространства объектов и ответов. ( $\mathbb{Y} = \{-1, +1\}$ ).

На  $\mathbb{X} \times \mathbb{Y}$  задано вероятностное распределение  $P$ .

Обучающая выборка  $\{X_i, Y_i\}_{i=1}^\ell$  — простая (i.i.d) из  $P$ .

$\mathcal{G}$  — множество классификаторов  $g: \mathbb{X} \rightarrow \mathbb{Y}$ .

Функция потерь  $r: \mathbb{Y} \times \mathbb{Y} \rightarrow \mathbb{R}^+$ .

(положим  $r(y_1, y_2) = [y_1 \neq y_2]$  — классификация)

Риск классификатора:

$$R(g) \stackrel{\text{def}}{=} \mathbb{E}_{(X, Y) \sim P} r(g(X), Y).$$

Эмпирический риск классификатора:

$$R_\ell(g) \stackrel{\text{def}}{=} \frac{1}{\ell} \sum_{i=1}^{\ell} r(g(X_i), Y_i).$$

## PAC-Bayes: Определения

$\mathbb{X}$  и  $\mathbb{Y}$  — пространства объектов и ответов. ( $\mathbb{Y} = \{-1, +1\}$ ).

На  $\mathbb{X} \times \mathbb{Y}$  задано вероятностное распределение  $P$ .

Обучающая выборка  $\{X_i, Y_i\}_{i=1}^\ell$  — простая (i.i.d) из  $P$ .

$\mathcal{G}$  — множество классификаторов  $g: \mathbb{X} \rightarrow \mathbb{Y}$ .

Функция потерь  $r: \mathbb{Y} \times \mathbb{Y} \rightarrow \mathbb{R}^+$ .

(положим  $r(y_1, y_2) = [y_1 \neq y_2]$  — классификация)

Риск классификатора:

$$R(g) \stackrel{\text{def}}{=} \mathbb{E}_{(X, Y) \sim P} r(g(X), Y).$$

Эмпирический риск классификатора:

$$R_\ell(g) \stackrel{\text{def}}{=} \frac{1}{\ell} \sum_{i=1}^{\ell} r(g(X_i), Y_i).$$

## PAC-Bayes: Определения

$\mathbb{X}$  и  $\mathbb{Y}$  — пространства объектов и ответов. ( $\mathbb{Y} = \{-1, +1\}$ ).

На  $\mathbb{X} \times \mathbb{Y}$  задано вероятностное распределение  $P$ .

Обучающая выборка  $\{X_i, Y_i\}_{i=1}^\ell$  — простая (i.i.d) из  $P$ .

$\mathcal{G}$  — множество классификаторов  $g: \mathbb{X} \rightarrow \mathbb{Y}$ .

Функция потерь  $r: \mathbb{Y} \times \mathbb{Y} \rightarrow \mathbb{R}^+$ .

(положим  $r(y_1, y_2) = [y_1 \neq y_2]$  — классификация)

Риск классификатора:

$$R(g) \stackrel{\text{def}}{=} \mathsf{E}_{(X, Y) \sim P} r(g(X), Y).$$

Эмпирический риск классификатора:

$$R_\ell(g) \stackrel{\text{def}}{=} \frac{1}{\ell} \sum_{i=1}^{\ell} r(g(X_i), Y_i).$$

## PAC-Bayes: случайный классификатор (Гиббса)

- Мы будем строить композицию классификаторов, выбирая апостериорное распределение  $\rho$  на множестве  $\mathcal{G}$ :

$$B_\rho(X) = \operatorname{sgn}\{\mathbb{E}_{g \sim \rho} g(X)\}.$$

- Задача — найти байесовский классификатор: композицию с минимальным риском:

$$R(B_\rho) \rightarrow \min_{\rho} .$$

- Вместо этого мы будем использовать случайный классификатор Гиббса  $G_\rho$ : для классификации  $X$  вытянем  $g \sim \rho$  и вернем  $g(X)$ .

## PAC-Bayes: случайный классификатор (Гиббса)

- Мы будем строить композицию классификаторов, выбирая апостериорное распределение  $\rho$  на множестве  $\mathcal{G}$ :

$$B_\rho(X) = \operatorname{sgn}\{\mathbb{E}_{g \sim \rho} g(X)\}.$$

- Задача — найти байесовский классификатор: композицию с минимальным риском:

$$R(B_\rho) \rightarrow \min_{\rho} .$$

- Вместо этого мы будем использовать случайный классификатор Гиббса  $G_\rho$ : для классификации  $X$  вытянем  $g \sim \rho$  и вернем  $g(X)$ .

## PAC-Bayes: случайный классификатор (Гиббса)

- Мы будем строить композицию классификаторов, выбирая апостериорное распределение  $\rho$  на множестве  $\mathcal{G}$ :

$$B_\rho(X) = \operatorname{sgn}\{\mathbb{E}_{g \sim \rho} g(X)\}.$$

- Задача — найти байесовский классификатор: композицию с минимальным риском:

$$R(B_\rho) \rightarrow \min_{\rho} .$$

- Вместо этого мы будем использовать случайный классификатор Гиббса  $G_\rho$ : для классификации  $X$  вытянем  $g \sim \rho$  и вернем  $g(X)$ .

# PAC-Bayes: случайный классификатор (Гиббса)

Риск классификатора Гиббса:

$$R(G_\rho) = \mathbb{E}_{g \sim \rho} R(g) = \mathbb{E}_{g \sim \rho} \mathbb{E}_{(X, Y) \sim P} [Y \neq g(X)].$$

Эмпирический риск классификатора Гиббса:

$$R_\ell(G_\rho) = \mathbb{E}_{g \sim \rho} R_\ell(g) = \mathbb{E}_{g \sim \rho} \frac{1}{\ell} \sum_{i=1}^{\ell} [Y_i \neq g(X_i)].$$

Связь рисков классификаторов  $B_\rho$  и  $G_\rho$ :

$$R(B_\rho) \leq 2R(G_\rho).$$

## PAC-Bayes: случайный классификатор (Гиббса)

Риск классификатора Гиббса:

$$R(G_\rho) = \mathbb{E}_{g \sim \rho} R(g) = \mathbb{E}_{g \sim \rho} \mathbb{E}_{(X, Y) \sim P} [Y \neq g(X)].$$

Эмпирический риск классификатора Гиббса:

$$R_\ell(G_\rho) = \mathbb{E}_{g \sim \rho} R_\ell(g) = \mathbb{E}_{g \sim \rho} \frac{1}{\ell} \sum_{i=1}^{\ell} [Y_i \neq g(X_i)].$$

Связь рисков классификаторов  $B_\rho$  и  $G_\rho$ :

$$R(B_\rho) \leq 2R(G_\rho).$$

## Первая теорема PAC-Bayes

### Теорема (McAllester, 1998, 1999)

Пусть  $\ell(y, y') \in [0, 1]$ . Зафиксируем любое априорное распределение  $\pi$  на множестве  $\mathcal{G}$ . Тогда для всех  $\delta \in (0, 1)$  с вероятностью не меньше  $1 - \delta$  (относительно случайного выпадения обучающей выборки) для всех апостериорных распределений  $\rho$  одновременно выполнено:

$$R(G_\rho) \leq R_\ell(G_\rho) + \sqrt{\frac{\text{KL}(\rho\|\pi) + \ln \frac{1}{\delta}}{2\ell}},$$

где  $\text{KL}(\rho\|\pi) = \int \rho(x) \ln \frac{\rho(x)}{\pi(x)} dx$  — KL-дивергенция.

## Первая теорема PAC-Bayes: доказательство

Вариационное определение KL-дивергенции:

$$KL(\rho\|\pi) = \sup_f (E_\rho f - \ln E_\pi e^f).$$

Для всех  $f : \mathcal{G} \rightarrow \mathbb{R}$  и всех пар  $\pi$  и  $\rho$ :

$$E_\rho f \leq KL(\rho\|\pi) + \ln E_\pi e^f. \quad (v)$$

Возьмем  $f = \lambda(R(g) - R_\ell(g))$ . Ограничим  $E_\pi e^f$ :

$$\begin{aligned} E_\pi e^f &\leq (\text{с вер.} \geq 1 - \delta, \text{ н-во Маркова}) \leq \frac{1}{\delta} E_{(X,Y) \sim P} \{ E_\pi e^f \} \leq \\ &\leq (\pi \text{ неслучайно}) \leq \frac{1}{\delta} E_\pi \{ E_{(X,Y) \sim P} e^f \} \leq (\text{лемма Хевдинга}) \leq \\ &\leq \frac{1}{\delta} E_\pi e^{\lambda^2/(8\ell)} = \frac{1}{\delta} e^{\lambda^2/(8\ell)} \end{aligned}$$

## Первая теорема PAC-Bayes: доказательство

Вариационное определение KL-дивергенции:

$$\mathbb{E}_\rho f \leq \text{KL}(\rho\|\pi) + \ln \mathbb{E}_\pi e^f. \quad (\nu)$$

Таким образом с учетом (ν)

$$\mathbb{E}_{g \sim \rho} (R(g) - R_\ell(g)) \leq \frac{\text{KL}(\rho\|\pi) + \ln \frac{1}{\delta}}{\lambda} + \frac{\lambda}{8\ell}.$$

Оптимизируя по  $\lambda$ , получим:

$$R(G_\rho) \leq R_\ell(G_\rho) + \sqrt{\frac{\text{KL}(\rho\|\pi) + \ln \frac{1}{\delta}}{2\ell}}.$$



## Вспомогательная теорема PAC-Bayes

Всюду далее  $\mathbb{R} = \{+1, -1\}$ ,  $r(y_1, y_2) = [y_1 \neq y_2]$ .

### Теорема (Germain et. al. 2009)

Зафиксируем любое априорное распределение  $\pi$  на множестве  $\mathcal{G}$  с  $\pi(g) > 0$  и выпуклую функцию  $D : [0, 1] \times [0, 1] \rightarrow \mathbb{R}$ . Тогда для всех  $\delta \in (0, 1)$  с вероятностью не меньше  $1 - \delta$  (относительно случайного выпадения обучающей выборки) для всех апостериорных распределений  $\rho$  одновременно выполнено:

$$\begin{aligned} D(R_\ell(G_\rho), R(G_\rho)) &\leqslant \\ &\leqslant \frac{1}{\ell} \left( \text{KL}(\rho \| \pi) + \ln \left[ \frac{1}{\delta} \mathbb{E}_{(X, Y) \sim P} \mathbb{E}_{g \sim \pi} e^{\ell D(R_\ell(G_\rho), R(G_\rho))} \right] \right) \end{aligned}$$

## Вспомогательная теорема PAC-Bayes: доказательство

Н-во Маркова дает с вероятностью  $\geq 1 - \delta$ :

$$\mathbb{E}_{g \sim \pi} e^{\ell D(R_\ell(G_\rho), R(G_\rho))} \leq \frac{1}{\delta} \mathbb{E}_{(X, Y) \sim P} \mathbb{E}_{g \sim \pi} e^{\ell D(R_\ell(G_\rho), R(G_\rho))}.$$

Логарифмируем обе части и перейдем к любому новому распределению  $\rho$ :

$$\ln \left[ \mathbb{E}_{g \sim \rho} \frac{\pi(g)}{\rho(g)} e^{\ell D(R_\ell(G_\rho), R(G_\rho))} \right] \leq \ln \left[ \frac{1}{\delta} \mathbb{E}_{(X, Y) \sim P} \mathbb{E}_{g \sim \pi} e^{\ell D(R_\ell(G_\rho), R(G_\rho))} \right].$$

Неравенство Йенсена дает:

$$\mathbb{E}_{g \sim \rho} \ln \left[ \frac{\pi(g)}{\rho(g)} e^{\ell D(R_\ell(G_\rho), R(G_\rho))} \right] \leq \ln \left[ \frac{1}{\delta} \mathbb{E}_{(X, Y) \sim P} \mathbb{E}_{g \sim \pi} e^{\ell D(R_\ell(G_\rho), R(G_\rho))} \right].$$

## Вспомогательная теорема PAC-Bayes: доказательство

$$\mathbb{E}_{g \sim \rho} \ln \left[ \frac{\pi(g)}{\rho(g)} e^{\ell D(R_\ell(G_\rho), R(G_\rho))} \right] \leq \ln \left[ \frac{1}{\delta} \mathbb{E}_{(X, Y) \sim P} \mathbb{E}_{g \sim \pi} e^{\ell D(R_\ell(G_\rho), R(G_\rho))} \right].$$

Поскольку

$$\mathbb{E}_{g \sim \rho} \ln \left[ \frac{\pi(g)}{\rho(g)} \right] = -\text{KL}(\rho \| \pi),$$

а также в силу выпуклости функции  $D$  и

$$\mathbb{E}_{g \sim \rho} [\ell D(R_\ell(G_\rho), R(G_\rho))] \geq \ell D(\mathbb{E}_{g \sim \rho} R_\ell(G_\rho), \mathbb{E}_{g \sim \rho} R(G_\rho))$$

мы получаем

$$\begin{aligned} D(R_\ell(G_\rho), R(G_\rho)) &\leq \\ &\leq \frac{1}{\ell} \left( \text{KL}(\rho \| \pi) + \ln \left[ \frac{1}{\delta} \mathbb{E}_{(X, Y) \sim P} \mathbb{E}_{g \sim \pi} e^{\ell D(R_\ell(G_\rho), R(G_\rho))} \right] \right) \quad \blacksquare \end{aligned}$$

## Вторая теорема PAC-Bayes

Следующая функция выпукла:

$$kl(q, p) \stackrel{\text{def}}{=} \text{KL}([q, 1 - q] \parallel [p, 1 - p]) = q \ln \frac{q}{p} + (1 - q) \ln \frac{1 - q}{1 - p}.$$

### Теорема (Seeger, 2002)

Зафиксируем любое априорное распределение  $\pi$  на множестве  $\mathcal{G}$  с  $\pi(g) > 0$ . Тогда для всех  $\delta \in (0, 1)$  с вероятностью не меньше  $1 - \delta$  (относительно случайного выпадения обучающей выборки) для всех апостериорных распределений  $\rho$  одновременно выполнено:

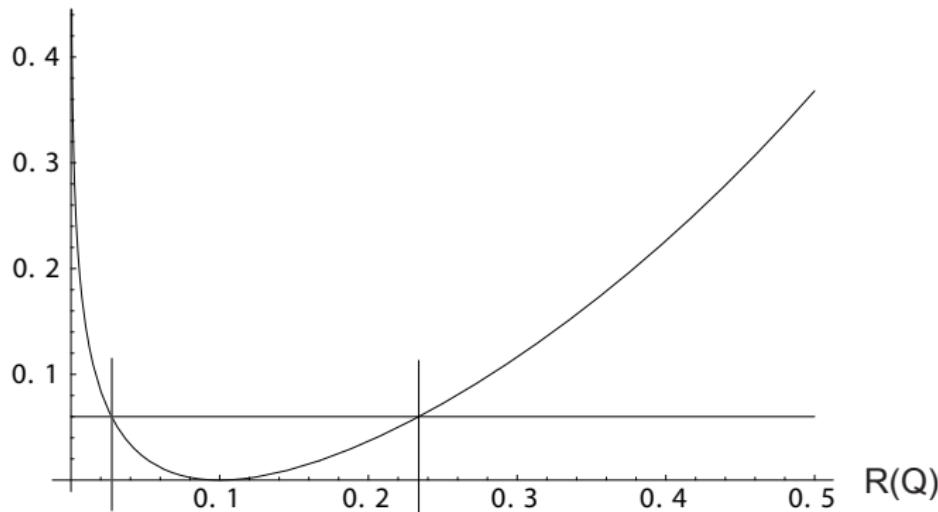
$$kl(R_\ell(G_\rho), R(G_\rho)) \leq \frac{1}{\ell} \left[ \text{KL}(\rho \parallel \pi) + \ln \frac{\xi(\ell)}{\delta} \right],$$

где  $\xi(\ell) = \sum_{i=0}^{\ell} C_\ell^i (i/\ell)^i (1 - i/\ell)^{\ell-i} \leq \ell + 1$ .

## Вторая теорема PAC-Bayes: применение

Дает сразу и верхнюю и нижнюю оценки:

$$kl(0.1||R(Q))$$



## Вторая теорема PAC-Bayes: доказательство

Возьмем во вспомогательной теореме  $D(q, p) = kl(q, p)$ :

$$\begin{aligned}
 & \mathbb{E}_{(X, Y) \sim P} \mathbb{E}_{g \sim \pi} e^{\ell kl(R_\ell(G_p), R(G_p))} \leqslant \\
 & \leqslant \mathbb{E}_{g \sim \pi} \mathbb{E}_{(X, Y) \sim P} \left( \frac{R_\ell(g)}{R(g)} \right)^{\ell R_\ell(g)} \left( \frac{1 - R_\ell(g)}{1 - R(g)} \right)^{\ell(1 - R_\ell(g))} \leqslant \\
 & \leqslant \mathbb{E}_{g \sim \pi} \sum_{i=1}^{\ell} \mathbb{P}_{X^\ell \sim P^\ell} \left( R_\ell(g) = \frac{i}{\ell} \right) \left( \frac{\frac{i}{\ell}}{R(g)} \right)^i \left( \frac{1 - \frac{i}{\ell}}{1 - R(g)} \right)^{\ell-i} = \\
 & = \mathbb{E}_{g \sim \pi} \sum_{i=1}^{\ell} C_\ell^i \left( \frac{i}{\ell} \right)^i \left( 1 - \frac{i}{\ell} \right)^{\ell-i} = \\
 & \sum_{i=1}^{\ell} C_\ell^i \left( \frac{i}{\ell} \right)^i \left( 1 - \frac{i}{\ell} \right)^{\ell-i}. \quad \blacksquare
 \end{aligned}$$

## Первая теорема PAC-Bayes: revisited

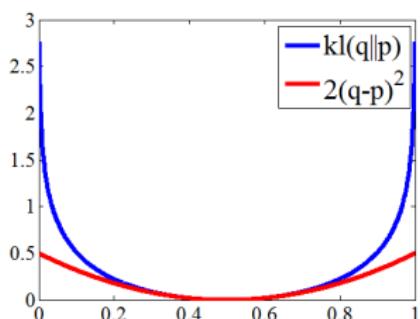
Неравенство Пинскера:

$$kl(q, p) \geq 2(q - p)^2.$$

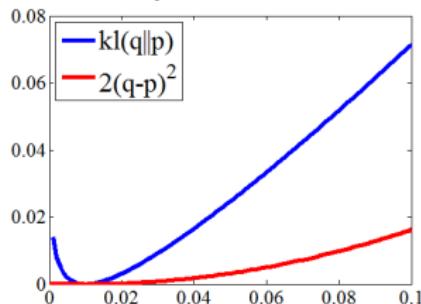
Отсюда из второй теоремы PAC-Bayes можно получить первую:

$$R(G_\rho) - R_\ell(G_\rho) \leq \frac{1}{2} \sqrt{kl(R_\ell(G_\rho), R(G_\rho))} \leq \frac{1}{2} \sqrt{\frac{KL(\rho\|\pi) + \ln \frac{\ell+1}{\delta}}{\ell}}.$$

$$q = 0.5$$



$$q = 0.01$$



## PAC-Bayes vs. SLT

$$R(G_\rho) \leq R_\ell(G_\rho) + \sqrt{\frac{\text{KL}(\rho\|\pi) + \ln \frac{1}{\delta}}{2\ell}}.$$

Сходства:

- Количественные гарантии о качестве классификатора без ограничений вида  $P$ ;
- Явная зависимость оценок от функции потерь.

Различия:

- Вместо «сложности класса» (например, VC-размерность) оценки учитывают сложность конкретного классификатора с помощью  $\pi(g)$ ;
- Позволяет в явном виде включить в модель априор;
- Оценки получаются для классификатора Гиббса;
- Оценки остаются точными даже при  $\text{VCdim} = \infty$ !

## PAC-Bayes vs. SLT

$$R(G_\rho) \leq R_\ell(G_\rho) + \sqrt{\frac{\text{KL}(\rho\|\pi) + \ln \frac{1}{\delta}}{2\ell}}.$$

Сходства:

- Качественные гарантии о качестве классификатора без ограничений вида  $P$ ;
- Явная зависимость оценок от функции потерь.

Различия:

- Вместо «сложности класса» (например, VC-размерность) оценки учитывают сложность конкретного классификатора с помощью  $\pi(g)$ ;
- Позволяет в явном виде включить в модель априор;
- Оценки получаются для классификатора Гиббса;
- Оценки остаются точными даже при  $\text{VCdim} = \infty$ !

## PAC-Bayes vs. SLT

$$R(G_\rho) \leq R_\ell(G_\rho) + \sqrt{\frac{\text{KL}(\rho\|\pi) + \ln \frac{1}{\delta}}{2\ell}}.$$

Сходства:

- Качественные гарантии о качестве классификатора без ограничений вида  $P$ ;
- Явная зависимость оценок от функции потерь.

Различия:

- Вместо «сложности класса» (например, VC-размерность) оценки учитывают сложность конкретного классификатора с помощью  $\pi(g)$ ;
- Позволяет в явном виде включить в модель априор;
- Оценки получаются для классификатора Гиббса;
- Оценки остаются точными даже при  $\text{VCdim} = \infty$ !

## PAC-Bayes vs. Bayes

$$R(G_\rho) \leq R_\ell(G_\rho) + \sqrt{\frac{\text{KL}(\rho\|\pi) + \ln \frac{1}{\delta}}{2\ell}}.$$

Сходства:

- Учет априора в явном виде.

Различия:

- Количественные гарантии о качестве классификатора;
- Не нужны никакие предположения об адекватности априора;
- Оценки справедливы одновременно для всех апостериорных распределений  $\rho$ .

## PAC-Bayes vs. Bayes

$$R(G_\rho) \leq R_\ell(G_\rho) + \sqrt{\frac{\text{KL}(\rho\|\pi) + \ln \frac{1}{\delta}}{2\ell}}.$$

Сходства:

- Учет априора в явном виде.

Различия:

- Количественные гарантии о качестве классификатора;
- Не нужны никакие предположения об адекватности априора;
- Оценки справедливы одновременно для всех апостериорных распределений  $\rho$ .

## PAC-Bayes vs. Bayes

$$R(G_\rho) \leq R_\ell(G_\rho) + \sqrt{\frac{\text{KL}(\rho\|\pi) + \ln \frac{1}{\delta}}{2\ell}}.$$

Сходства:

- Учет априора в явном виде.

Различия:

- Количественные гарантии о качестве классификатора;
- Не нужны никакие предположения об адекватности априора;
- Оценки справедливы одновременно для всех апостериорных распределений  $\rho$ .

## Применение PAC-Bayes оценок: линейные классификаторы

Рассмотрим линейные классификаторы вида

$$\mathcal{G} = \{g_w(\mathbf{x}) = \text{sgn}(\mathbf{w}^\top \varphi(\mathbf{x}))\},$$

проходящие через начало координат ( $b = 0$ ).

- PAC-Bayes дает оценки для классификатора Гиббса.
- Как применить, например, для SVM?

Идея:

- Построить композицию классификаторов, эквивалентную нашему классификатору;
- Оценить риск этой композиции с помощью удвоенного риска Гиббса!

## Применение PAC-Bayes оценок: линейные классификаторы

Положим

$$\rho = \mathcal{N}(\mu \mathbf{w} / \|\mathbf{w}\|, I), \quad \mu \in \mathbb{R}.$$

Тогда

$$\operatorname{sgn}(\mathbf{w}^\top \varphi(\mathbf{x})) = \operatorname{sgn}(E_{w \sim \rho} g_w(\mathbf{x}));$$

и для соответствующего классификатора Гиббса:

$$R_\ell(G_\rho) = \frac{1}{\ell} \sum_{i=1}^{\ell} \tilde{F}(\mu \gamma(\mathbf{x}_i, y_i));$$

$$\gamma(\mathbf{x}, y) = \frac{y \mathbf{w}^\top \varphi(\mathbf{x})}{\|\varphi(\mathbf{x})\| \|\mathbf{w}\|};$$

$$\tilde{F}(x) = 1 - \int_{-\infty}^x \frac{1}{\sqrt{2\pi}} e^{-x^2/2} dx.$$

## Применение PAC-Bayes оценок: линейные классификаторы

### Теорема (Langford, Shawe-Taylor, 2002, 2005)

Для всех  $\delta \in (0, 1)$  с вероятностью не меньше  $1 - \delta$   
(относительно случайной реализации обучающей выборки)  
**одновременно** для всех классификаторов Гиббса  $G_\rho$ ,  
 $\rho = \mathcal{N}(\mu\mathbf{w}/\|\mathbf{w}\|, I)$ , выполнено:

$$kl(R_\ell(G_\rho) \| R(G_\rho)) \leq \frac{\frac{\mu^2}{2} + \ln \frac{\ell+1}{\delta}}{\ell}. \quad (1)$$

Рецепт:

- Настройте SVM и получите  $\mathbf{w}$ ;
- Оптимизируйте оценку (1) по  $\mu$ . Тогда

$$\mathbb{E}_{(\mathbf{x}, y) \sim D} [\text{sgn}(\mathbf{w}^\top \mathbf{x}) \neq y] \leq 2R(G_\rho).$$

## Применение PAC-Bayes оценок: линейные классификаторы

(Langford, 2005)

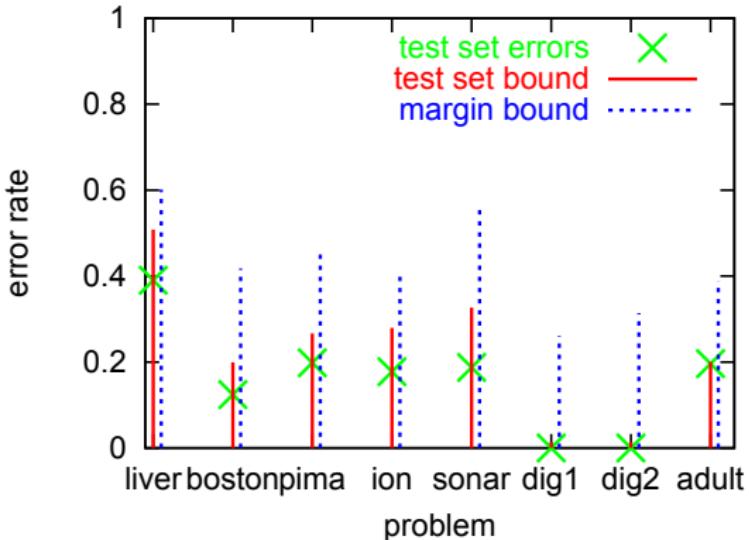


Figure 10: This figure shows the results of applying SVMlight to 8 datasets with a Gaussian kernel and a 70/30 train/test split. The observed test error rate is graphed as an X. On the test set, we calculate a binomial confidence interval (probability of bound failure equals 0.01) which upper bounds the true error rate. On the training set we calculate the PAC-Bayes margin bound for an optimized choice of  $\mu$ .

## Обучаем априорное распределение на данных

- Оценки зависят от KL-дивергенции между  $\rho$  и  $\pi$ ;
- Чем лучше априор, тем лучше оценки;
- Давайте обучать априор по части обучающей выборки;
- Подставлять этот априор в оценку;
- Вычислять оценку по оставшимся данным.

Настроим SVM  $\mathbf{w}_r$  по первым  $r$  объектам обучающей выборки.

Обозначим  $\bar{\mathbf{w}} = \mathbf{w}/\|\mathbf{w}\|$ .

Теперь введем априор  $\pi = \mathcal{N}(\eta \bar{\mathbf{w}}_r, I)$ .

Снова применим вторую PAC-Bayes теорему.

## Обучаем априорное распределение на данных

### Теорема (Ambroladze et. al., 2007)

Для всех  $\delta \in (0, 1)$  с вероятностью не меньше  $1 - \delta$   
(относительно случайной реализации обучающей выборки)  
одновременно для всех классификаторов Гиббса  $G_\rho$ ,  
 $\rho = \mathcal{N}(\mu \bar{\mathbf{w}}, I)$ , выполнено:

$$kl(R_{\ell-r}(G_\rho) \| R(G_\rho)) \leq \frac{\frac{\|\eta \bar{\mathbf{w}} - \mu \bar{\mathbf{w}}\|^2}{2} + \ln \frac{\ell-r+1}{\delta}}{\ell-r}, \quad (1)$$

где

$$R_{\ell-r}(G_\rho) = \frac{1}{\ell-r} \sum_{i=r+1}^{\ell} \tilde{F}(\mu \gamma(\mathbf{x}_i, y_i)).$$

**Важно:**  $\mathbf{w}$  можно вычислять по всей обучающей выборке!

## Обучаем априорное распределение на данных: Еще лучше!

Введем  $J$  разных априоров  $\pi_j = \mathcal{N}(\eta_j \mathbf{w}_r / \|\mathbf{w}_r\|, I)$ .

### Теорема (Ambroladze et. al., 2007)

Для всех  $\delta \in (0, 1)$  с вероятностью не меньше  $1 - \delta$   
(относительно случайной реализации обучающей выборки)  
одновременно для всех классификаторов Гиббса  $G_\rho$ ,  
 $\rho = \mathcal{N}(\mu \bar{\mathbf{w}}, I)$ , и одновременно для всех  $j$  выполнено:

$$kI(R_{\ell-r}(G_\rho) \| R(G_\rho)) \leq \frac{\frac{\|\eta_j \bar{\mathbf{w}}_r - \mu \bar{\mathbf{w}}\|^2}{2} + \ln \frac{\ell-r+1}{\delta} + \ln J}{\ell - r}.$$

- Для каждого  $j$  оптимизируем по  $\mu$ ;
- Выбираем лучшую из полученных оценок.

## Обучаем априорное распределение на данных: SVM

Problem	# samples	input dim.	Pos/Neg
Handwritten-digits	5620	64	2791 / 2829
Waveform	5000	21	1647 / 3353
Pima	768	8	268 / 500
Ringnorm	7400	20	3664 / 3736
Spam	4601	57	1813 / 2788

## Обучаем априорное распределение на данных

Problem		2FCV	10FCV	PAC	PrPAC
digits	Bound	–	–	0.175	0.107
	CE	0.007	0.007	0.007	0.014
waveform	Bound	–	–	0.203	0.185
	CE	0.090	0.086	0.084	0.088
pima	Bound	–	–	0.424	0.420
	CE	0.244	0.245	0.229	0.229
ringnorm	Bound	–	–	0.203	0.110
	CE	0.016	0.016	0.018	0.018
spam	Bound	–	–	0.254	0.198
	CE	0.066	0.063	0.067	0.077

Усреднение по 50 случайным разбиениям  
на обучение/контроль (80%/20%).

## Другие направления . . .

- KL-дивергенцию можно заставить исчезнуть!
- Классификаторы, минимизирующие PAC-Bayes оценки;
- PAC-Bayes оценки плотности (непрерывной и дискретной);
- Приложения в collaborative filtering (co-clustering);
- “Non i.i.d”, martingales, reinforcement learning;
- Приложения в transductive и unsupervised learning;
- Минимизируя PAC-Bayes оценки можно получить SVM, KL-Regularized AdaBoost, Kernel Ridge Regression, . . . ;
- Distribution-dependant prior.

## Обзор литературы

- *Amiran Ambroladze, Emilio Parrado-Hernandez, and John Shawe-Taylor. Tighter PAC-Bayesbounds. Advances in Neural Information Processing Systems (NIPS), 2007.*
- *Jean-Yves Audibert, Olivier Bousquet. Combining PAC-Bayesian and generic chaining bounds. Journal of Machine Learning Research, 8:863–889, 2007.*
- *Olivier Catoni. PAC-Bayesian supervised classification: The thermodynamics of statistical learning. IMS Lecture Notes Monograph Series, 56, 2007.*
- *John Shawe-Taylor, Yevgeny Seldin, Francois Laviolette. PAC-Bayesian Analysis in Supervised, Unsupervised, and Reinforcement Learning. Tutorial, ECML-PKDD 2012, Bristol.*

## Обзор литературы

- *Pascal Germain, Alexandre Lacasse, Francois Laviolette, and Mario Marchand. PAC-Bayesian learning of linear classifiers.* In *Proceedings of the International Conference on Machine Learning (ICML)*, 2009.
- *John Langford and John Shawe-Taylor. PAC-Bayes and margins.* *Advances in Neural Information Processing Systems (NIPS)*, 2002.
- *John Langford. Tutorial on practical prediction theory for classification.* *Journal of Machine Learning Research*, 6:273–306, 2005.
- *Guy Lever, Francois Laviolette, and John Shawe-Taylor. Distribution-dependent PAC-Bayes priors.* In *Proceedings of the International Conference on Algorithmic Learning Theory (ALT)*, 2010.

## Обзор литературы

- *Matthias Seeger. PAC-Bayesian generalization error bounds for Gaussian process classification. Journal of Machine Learning Research, 2002.*
- *Yevgeny Seldin and Naftali Tishby. PAC-Bayesian analysis of co-clustering and beyond. Journal of Machine Learning Research, 11, 2010.*  
*Yevgeny Seldin, Peter Auer, Francois Laviolette, John Shawe-Taylor, and Ronald Ortner. PAC-Bayesian analysis of contextual bandits. In Advances in Neural Information Processing Systems (NIPS), 2011.*
- *Yevgeny Seldin, Francois Laviolette, Nicolo Cesa-Bianchi, John Shawe-Taylor, and Peter Auer. PAC-Bayesian inequalities for martingales. IEEE Transactions on Information Theory, 2012.*

## Обзор литературы

- *John Shawe-Taylor and Robert C. Williamson. A PAC analysis of a Bayesian estimator.* In *Proceedings of the International Conference on Computational Learning Theory (COLT)*, 1997.
- *John Shawe-Taylor, Peter L. Bartlett, Robert C. Williamson, and Martin Anthony. Structural risk minimization over data-dependent hierarchies.* *IEEE Transactions on Information Theory*, 44(5), 1998.
- *David McAllester. Some PAC-Bayesian theorems.* *Machine Learning*, 37, 1999.

videolectures.net:  
Workshop on PAC Bayesian Learning, 2010, London.

Спасибо!

Спасибо за внимание!

