

# Теория статистического обучения

Н. К. Животовский

nikita.zhivotovskiy@phystech.edu

22 мая 2016 г.

Материал находится в стадии разработки, может содержать ошибки и неточности. Автор будет благодарен за любые замечания и предложения, направленные по указанному адресу

## 1 Выбор модели, регуляризация и устойчивость

Методы, изложенные в предыдущем разделе, тесно связаны с так называемыми регуляризованными методами. Однако ранее они использовались как методы выбора модели. Мы уже знаем, что в случае когда класс потерь является равномерным классом Гливенко–Кантелли, можно обучаться с помощью минимизации эмпирического риска. В этой лекции мы считаем, что наша задача не обязательно задача классификации, а функция потерь не обязательно индикатор ошибки. Более того мы рассмотрим так называемые *методы минимизации регуляризованного риска* с помощью которых будет доказана агностическая РАС—обучаемость для задачи, класс потерь которой не обязательно является равномерным классом Гливенко–Кантелли.

Если класс решающих правил  $\mathcal{F}$  линейный, то отождествим каждую функцию в нем с соответствующим вектором весов  $\mathbf{w}$ .

**Пример 1.1.** Рассмотрим хорошо известную задачу *гребневой регрессии* (Ridge Regression). В этой задаче выбирается вектор весов по правилу

$$\hat{\mathbf{w}} = \arg \min_{\mathbf{w} \in \mathbb{R}^d} (L_n(\mathbf{w}) + \lambda \|\mathbf{w}\|_2^2),$$

для некоторого  $\lambda > 0$ . В случае квадратичной функции потерь в классе линейных решающих правил задача имеет аналитическое решение. В наших обозначениях привычнее записывать задачу в нематричном виде

$$\hat{\mathbf{w}} = \arg \min \left( \lambda \|\mathbf{w}\|_2^2 + \frac{1}{n} \sum_{i=1}^n ((x_i, \mathbf{w}) - y_i)^2 \right).$$

Если  $\mathbf{A} = \left( \sum_{i=1}^n \mathbf{x}_i \mathbf{x}_i^T \right)^{-1}$ ,  $\mathbf{b} = \sum_{i=1}^n \mathbf{x}_i y_i$ , то

$$\hat{\mathbf{w}} = (\mathbf{A} + \lambda n I)^{-1} \mathbf{b}.$$

Данный пример является одним из стандартных примеров регуляризованной минимизации риска: к эмпирическому риску прибавляется член  $\lambda \|\mathbf{w}\|_2^2$ , который не позволяет весам разрастаться слишком сильно. Стоит отметить, что подобная квадратичная регуляризация является частным случаем *регуляризации по Тихонову*.

## §1.1 Устойчивость алгоритмов обучения

Неформально *устойчивость* алгоритмов заключается в том, что небольшое изменение обучающей выборке не изменяет значительно результата обучения. Обозначим  $S, S^{(i)}$  — две обучающие выборки, отличающиеся только на  $i$ -ом объекте.

**Лемма 1.1.** Пусть  $U$  — равномерное распределение на индексах  $\{1, \dots, n\}$ . Тогда для любого метода обучения

$$\mathbb{E}(L(\hat{f}_S) - L_n(\hat{f}_S)) = \mathbb{E}_{S, i \sim U}(\ell(\hat{f}_{S^{(i)}}(X_i, Y_i) - \ell(\hat{f}_S(X_i, Y_i))).$$

**Доказательство.**

Воспользуемся аддитивностью математических ожиданий и сравним первые слагаемые:

$$\mathbb{E}(L(\hat{f}_S)) = \mathbb{E}_{S, X', Y'}[\ell(\hat{f}_S(X', Y'))] = \mathbb{E}_{S, i \sim U}[\ell(\hat{f}_{S^{(i)}}(X_i, Y_i))].$$

Аналогично доказываем, что

$$\mathbb{E}L_n(\hat{f}_S) = \mathbb{E}_{S, i \sim U}\ell(\hat{f}_S(X_i, Y_i)).$$

■

Говорят, что алгоритм обучения *переобучается*, если частота ошибок выбранного им решающего правила на обучении сильно меньше чем реальная ошибка.

**Опр. 1.1.** Алгоритм обучения называется *устойчивым в среднем*, если для некоторой убывающей функции  $\varepsilon : \mathbb{N} \rightarrow \mathbb{R}$ , такой что  $\varepsilon(n) \rightarrow 0$  при  $n \rightarrow \infty$ :

$$\mathbb{E}_{S, i \sim U}(\ell(\hat{f}_{S^{(i)}}(X_i, Y_i) - \ell(\hat{f}_S(X_i, Y_i))) \leq \varepsilon(n).$$

Последняя лемма показывает, что алгоритм не переобучается тогда и только тогда, когда он устойчив в среднем. Однако отсутствие переобучения не есть гарант хорошей обобщающей способности. Пусть, например, алгоритм обучения выбирает всегда некоторое фиксированное решающее правило вне зависимости от обучающей выборки. Тогда он является устойчивым в среднем, более того  $\varepsilon(n) \equiv 0$ , однако его эмпирическая ошибка, а значит и реальный риск может быть велик.

**Опр. 1.2 (Выпуклая задача статистического обучения).** Задача статистического обучения называется *выпуклой*, если класс  $\mathcal{F}$  является выпуклым множеством и для всех  $(X, Y)$  функция  $\ell(\mathbf{w}, X, Y)$  является выпуклой по первому аргументу.

**Пример 1.2.** В задаче линейной регрессии классу  $\mathcal{F}$  мы сопоставляем пространство  $\mathbb{R}^d$ , далее легко видеть, что функция потерь как функция одного аргумента является выпуклой. Таким образом данная задача — выпуклая.

**Опр. 1.3 (Сильно выпуклая функция).** Функция называется *сильно выпуклой* с параметром  $\lambda$ , если для всех  $\mathbf{u}, \mathbf{w}, \alpha \in (0, 1)$ :

$$f(\alpha \mathbf{w} + (1 - \alpha) \mathbf{u}) \leq \alpha f(\mathbf{w}) + (1 - \alpha) f(\mathbf{u}) - \frac{\lambda}{2} \alpha (1 - \alpha) \|\mathbf{w} - \mathbf{u}\|^2.$$

**Лемма 1.2.** *Имеют место следующие свойства:*

- $f(\mathbf{w}) = \lambda \|\mathbf{w}\|_2^2 - 2\lambda$  сильно выпуклая функция.
- Сумма сильно выпуклой и выпуклой функции — сильно выпуклая с тем же параметром.
- Если  $f$  — сильно выпуклая, гладкая и  $\mathbf{u}$  минимизирует  $f$ , то

$$f(\mathbf{w}) - f(\mathbf{u}) \geq \frac{\lambda}{2} \|\mathbf{w} - \mathbf{u}\|_2^2.$$

**Упр. 1.1.** Доказать лемму.

В выпуклой задаче обозначим  $\mathbf{w}_S$  как вектор, получаемый с помощью регуляризованной минимизации эмпирического риска по обучающей выборке  $S$ . То есть:

$$\mathbf{w}_S = \arg \min_{\mathbf{w} \in \mathbb{R}^d} (L_n(\mathbf{w}) + \lambda \|\mathbf{w}\|_2^2),$$

**Лемма 1.3.** *В выпуклой задаче для регуляризованной минимизации эмпирического риска имеет место неравенство:*

$$\lambda \|\mathbf{w}_S - \mathbf{w}_{S^i}\|_2^2 \leq \frac{1}{n} (\ell(\mathbf{w}_{S^i}, X_i, Y_i) - \ell(\mathbf{w}_S, X_i, Y_i)) + \frac{1}{n} (\ell(\mathbf{w}_S, X', Y') - \ell(\mathbf{w}_{S^i}, X', Y'))$$

**Доказательство.**

Пусть  $g_S(\mathbf{w}) = L_{n,S}(\mathbf{w}) + \lambda \|\mathbf{w}\|_2^2$ . Данная функция является сильно выпуклой как сумма сильно выпуклой и выпуклой функции. Мы знаем, что

$$g_S(\mathbf{w}) - g_S(\mathbf{w}_S) \geq \frac{\lambda}{2} \|\mathbf{w} - \mathbf{w}_S\|_2^2.$$

С другой стороны:

$$\begin{aligned} g_S(\mathbf{u}) - g_S(\mathbf{w}) &= L_{n,S}(\mathbf{u}) + \lambda \|\mathbf{u}\|_2^2 - L_{n,S}(\mathbf{w}) - \lambda \|\mathbf{w}\|_2^2 \\ &= L_{n,S^{(i)}}(\mathbf{u}) + \lambda \|\mathbf{u}\|_2^2 - L_{n,S^{(i)}}(\mathbf{w}) - \lambda \|\mathbf{w}\|_2^2 \\ &\quad + \frac{1}{n} (\ell(\mathbf{w}_{S^i}, X_i, Y_i) - \ell(\mathbf{w}_S, X_i, Y_i)) + \frac{1}{n} (\ell(\mathbf{w}_S, X', Y') - \ell(\mathbf{w}_{S^i}, X', Y')). \end{aligned}$$

Заменяем  $\mathbf{u}$  на  $\mathbf{w}_{S^{(i)}}$  и  $\mathbf{w}$  на  $\mathbf{w}_S$  получаем, что

$$\lambda \|\mathbf{w}_S - \mathbf{w}_{S^i}\|_2^2 \leq \frac{1}{n} (\ell(\mathbf{w}_{S^i}, X_i, Y_i) - \ell(\mathbf{w}_S, X_i, Y_i)) + \frac{1}{n} (\ell(\mathbf{w}_S, X', Y') - \ell(\mathbf{w}_{S^i}, X', Y'))$$

■

**Опр. 1.4 (Липшицева функция потерь).** *Функция потерь  $\ell$  называется липшицевой с параметром  $\rho$ , если для всех допустимых  $X, Y$  функция, задаваемая  $\ell(\mathbf{w}, X, Y)$ , является липшицевой по первому аргументу с параметром  $\rho$ :*

$$\|\ell(\mathbf{w}, X, Y) - \ell(\mathbf{u}, X, Y)\| \leq \rho \|\mathbf{w} - \mathbf{u}\|.$$

**Лемма 1.4.** Если функция потерь  $\ell$  является липшицевой с параметром  $\rho$ , то в выпуклой задаче регуляризованный метод минимизации эмпирического риска является устойчивым в среднем с  $\varepsilon(n) = \frac{2\rho^2}{\lambda n}$ .

**Доказательство.**

Воспользуемся предыдущей леммой. Из определения липшицевости

$$\ell(\mathbf{w}_{S^i}, X_i, Y_i) - \ell(\mathbf{w}_S, X_i, Y_i) \leq \rho \|\mathbf{w}_{S^i} - \mathbf{w}_S\|.$$

Таким образом,

$$\lambda \|\mathbf{w}_S - \mathbf{w}_{S^i}\|^2 \leq \frac{2\rho \|\mathbf{w}_{S^i} - \mathbf{w}_S\|}{n}$$

Следовательно,

$$\|\mathbf{w}_S - \mathbf{w}_{S^i}\| \leq \frac{2\rho}{\lambda n}.$$

Еще раз применяя Липшицевость, получаем, что

$$\ell(\mathbf{w}_{S^i}, X_i, Y_i) - \ell(\mathbf{w}_S, X_i, Y_i) \leq \frac{2\rho^2}{\lambda n}.$$

Беря математические ожидания, получаем утверждение леммы. ■

## 2 Баланс эмпирического риска и устойчивости

Для любого правила  $\hat{f}$  можно сделать очевидное разложение:

$$\mathbb{E}L(\hat{f}) = \mathbb{E}L_n(\hat{f}) + \mathbb{E}\left(L(\hat{f}) - L_n(\hat{f})\right).$$

Первый член отвечает за ожидаемую ошибку на обучающей выборке, а второй — за устойчивость. Для того чтобы ожидаемый риск был мал необходимо чтобы оба слагаемых были в балансе. Рассмотрим, например случай выпуклой и липшицевой функции потерь в задаче регуляризованных методов минимизации эмпирического риска. Очевидно, что для любого вектора  $\mathbf{w}^*$  имеет место соотношение:

$$L_n(\mathbf{w}_S) \leq L_n(\mathbf{w}_S) + \lambda \|\mathbf{w}_S\|^2 \leq L_n(\mathbf{w}^*) + \lambda \|\mathbf{w}^*\|^2.$$

**Теорема 2.1 (Оракульное неравенство).** Если функция потерь  $\ell$  является липшицевой с параметром  $\rho$ , то в выпуклой задаче для регуляризованного метода минимизации эмпирического риска для любого вектора  $\mathbf{w}^*$  выполнено:

$$\mathbb{E}L(\mathbf{w}_S) \leq L(\mathbf{w}^*) + \lambda \|\mathbf{w}^*\|^2 + \frac{2\rho^2}{\lambda n}.$$

**Доказательство.**

Доказательство получается с помощью неравенства  $L_n(\mathbf{w}_S) \leq L_n(\mathbf{w}^*) + \lambda \|\mathbf{w}^*\|^2$  и леммы 1.4. ■

Термин оракульное неравенство здесь уместен. Каждый вектор весов можно рассматривать как отдельную модель, а регуляризованный метод минимизации эмпирического риска как метод выбора модели. Тогда данное неравенство сравнивает ожидаемый риск выбранной модели, в частности, с риском оракульной модели.

**Теорема 2.2 (Оракульное неравенство, ограниченный случай).** *Если функция потерь  $\ell$  является липшицевой с параметром  $\rho$ , то в выпуклой задаче для регуляризованного метода минимизации эмпирического риска параметр  $\lambda$  может быть выбран таким образом, что будет выполнено неравенство:*

$$\mathbb{E}L(\mathbf{w}_S) \leq \inf_{\mathbf{w}} L(\mathbf{w}) + \rho B \sqrt{\frac{8}{n}}.$$

**Упр. 2.1.** Доказать теорему.

**Упр. 2.2.** Доказать агностическую PAC-обучаемость выпуклой ограниченной задачи с липшицевой функцией потерь.

## Список литературы

- [1] *Boucheron S., Bousquet O., Lugosi G.* Theory of classification: A Survey of Some Recent Advances // ESAIM: Probability and Statistics, 2005.
- [2] *Koltchinskii V.* Oracle Inequalities in Empirical Risk Minimization and Sparse Recovery Problems // Ecole d'Eté de Probabilités de Saint-Flour XXXVIII-2008. Lecture Notes in Mathematics. Springer-Verlag, 2011.
- [3] *Massart P.* Concentration Inequalities and Model Selection // Ecole d'Eté de Probabilités de Saint-Flour XXXIII-2003. Springer-Verlag, 2007.
- [4] *Shalev-Shwartz S., Ben-David S.* Understanding Machine Learning: From Theory to Algorithms // Cambridge University Press, 2014