

# Как объединять модели

Сергей Николенко

Академический Университет, 2012

# Outline

## 1 Простые методы

- Усреднение
- Bagging

## 2 Бустинг

- AdaBoost
- Расширения: RankBoost

# Как объединять модели

- До сих пор мы разрабатывали (и потом ещё будем разрабатывать) модели, которые делают предсказания (в основном для задач регрессии и классификации).
- Таким образом, мы можем попробовать обучить сразу много разных моделей!
- Model selection – это о том, как выбрать из них лучшую.
- Но, может быть, можно не выбирать, а использовать все сразу?

# Основные подходы

- Комитет: обучаем  $L$  разных моделей, а потом так или иначе усредняем-комбинируем их результаты.
- Альтернатива: обучаем  $L$  разных моделей, а потом обучаем отдельную модель о том, какую из них использовать для предсказания (например, дерево принятия решений).

# Комбинация моделей и байесовское усреднение

- Начнём с самого простого – байесовского усреднения.
- Мы уже знаем, что такое комбинация моделей – например, линейная смесь гауссианов:

$$p(\mathbf{x}) = \sum_k \pi_k \mathcal{N}(\mathbf{x} | \boldsymbol{\mu}_k, \boldsymbol{\Sigma}_k).$$

- Если её обучать, мы обучим коэффициенты смеси, и результат будет порождён

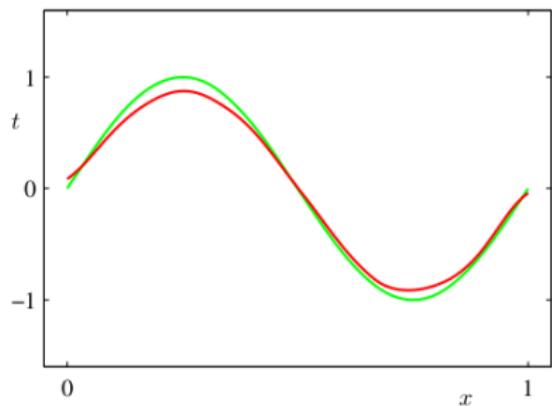
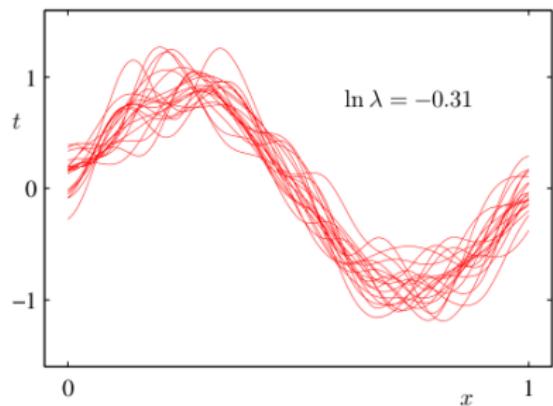
# Комбинация моделей и байесовское усреднение

- А байесовское усреднение будет выглядеть как

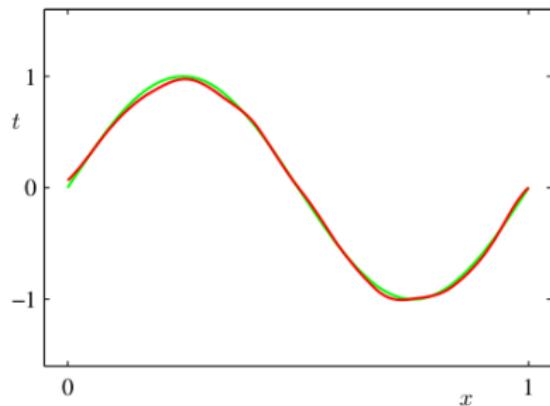
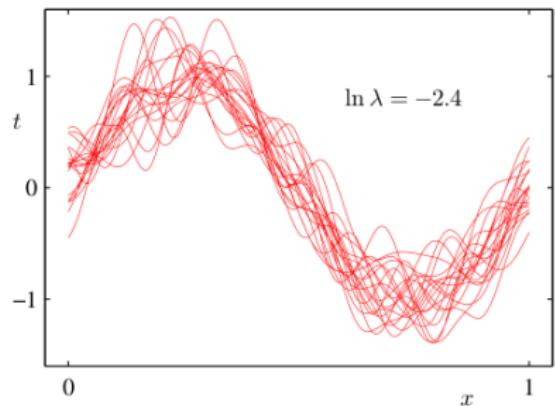
$$p(\mathbf{X}) = \sum_{h=1}^H p(\mathbf{X} | h)p(h).$$

- Смысл теперь в том, что генерирует  $\mathbf{X}$  только одна модель, но мы просто не знаем какая именно; когда  $\mathbf{X}$ , апостериорные распределения  $p(h | \mathbf{X})$  сужаются, и мы выбираем то, что надо.
- Но метод очень простой: взять много моделей и усреднить.
- Где-то мы это уже видели...

Где-то мы это уже видели



Где-то мы это уже видели



# Bagging

- На этих картинках – модели с высоким *bias*, которые обучены по разным датасетам, сгенерированным одним и тем же распределением.
- И если их усреднить, получится как раз то, что надо.
- Но в жизни у нас нет возможности генерировать много датасетов: сколько данных есть, столько есть.
- Просто разбивать датасет на части – не поможет. Что делать?

# Bagging

- Пусть у нас есть датасет  $\mathbf{X} = \{\mathbf{x}_1, \dots, \mathbf{x}_N\}$ .
- Давайте сгенерируем много датасетов так: будем выбирать из  $\mathbf{X}$   $N$  точек с замещением, т.е. в новом датасете некоторые точки будут повторяться.
- Этот метод называется *bootstrapping*.

# Bagging

- Мы сделаем так  $M$  датасетов размера  $N$  (с повторяющимися точками), потом обучим  $M$  моделей, а потом образуем из них комитет и будем предсказывать как

$$y(\mathbf{x}) = \frac{1}{M} \sum_{m=1}^M y_m(\mathbf{x}).$$

- Это называется *bagging* (bootstrap aggregation).
- На первый взгляд кажется, что это какая-то ерунда: мы пытаемся получить что-то из ничего...

# Bagging

- Пусть настоящая функция, которую мы пытаемся предсказать –  $h(\mathbf{x})$ , т.е. модели наши выглядят как

$$y_m(\mathbf{x}) = h(\mathbf{x}) + \epsilon_m(\mathbf{x}).$$

- Тогда средняя ошибка модели – это

$$\mathbb{E}_{\mathbf{x}} \left[ (y_m(\mathbf{x}) - h(\mathbf{x}))^2 \right] = \mathbb{E}_{\mathbf{x}} \left[ \epsilon_m(\mathbf{x})^2 \right].$$

- И средняя ошибка тех моделей, которые мы обучаем, получается

$$E_{\text{avg}} = \frac{1}{M} \sum_{m=1}^M \mathbb{E}_{\mathbf{x}} \left[ \epsilon_m(\mathbf{x})^2 \right].$$

# Bagging

- И средняя ошибка тех моделей, которые мы обучаем, получается

$$E_{\text{avg}} = \frac{1}{M} \sum_{m=1}^M E_x [\epsilon_m(\mathbf{x})^2].$$

- А ошибка комитета – это

$$\begin{aligned} E_{\text{com}} &= E_x \left[ \left( \frac{1}{M} \sum_{m=1}^M (y_m(\mathbf{x}) - h(\mathbf{x})) \right)^2 \right] = \\ &= E_x \left[ \left( \frac{1}{M} \sum_{m=1}^M \epsilon_m(\mathbf{x}) \right)^2 \right]. \end{aligned}$$

# Bagging

- $E_{\text{avg}} = \frac{1}{M} \sum_{m=1}^M E_x [\epsilon_m(\mathbf{x})^2],$   
 $E_{\text{com}} = E_x \left[ \left( \frac{1}{M} \sum_{m=1}^M \epsilon_m(\mathbf{x}) \right)^2 \right].$
- Если предположить, что  $E_x [\epsilon_m(\mathbf{x})] = 0$ , и ошибки некоррелированы:  $E_x [\epsilon_m(\mathbf{x}) \epsilon_l(\mathbf{x})] = 0$ , мы получим

$$E_{\text{com}} = \frac{1}{M} E_{\text{avg}}.$$

# Bagging

- $E_{\text{com}} = \frac{1}{M} E_{\text{avg}}$ !
- Это кажется совершенно невероятным. На самом деле всё не так хорошо – конечно, ошибки на самом деле сильно коррелированы.
- И, конечно, на самом деле обычно уменьшение ошибки не такое большое.
- Но можно показать, что в любом случае  $E_{\text{com}} \leq E_{\text{avg}}$ , так что хуже от этого не будет, а лучше стать может.

# Outline

## 1 Простые методы

- Усреднение
- Bagging

## 2 Бустинг

- AdaBoost
- Расширения: RankBoost

# AdaBoost

- Следующая идея объединения моделей: предположим, что у нас есть возможность обучать какую-нибудь простую модель (*weak learner*) на подмножестве данных.
- Тогда можно делать так: обучили модель, посмотрели, где она хорошо работает, обучили следующую модель на том подмножестве, где она работает плохо, повторили.
- Этот метод называется *бустинг* (*boosting*).

# AdaBoost

- AdaBoost: самый простой вариант. Рассмотрим задачу бинарной классификации; данные – это  $x_1, \dots, x_N$  с ответами  $t_1, \dots, t_N$ ,  $t_i \in \{-1, 1\}$ .
- Снабдим каждый тестовый пример весом  $w_i$ ; изначально положим  $w_i = \frac{1}{N}$ .
- Предположим, что у нас есть процедура, которая обучает некоторый классификатор, выдающий  $y(x) \in \{-1, 1\}$ , на взвешенных данных (минимизируя взвешенную ошибку).

# AdaBoost

- Тогда в алгоритме AdaBoost мы инициализируем  $w_n^{(1)} := 1/N$ , а потом для  $m = 1..M$ :
  - ① обучаем классификатор  $y_m(\mathbf{x})$ , который минимизирует функцию ошибки

$$J_m = \sum_{n=1}^N w_n^{(m)} [y_m(\mathbf{x}_n) \neq t_n];$$

- ② вычисляем

$$\epsilon_m = \frac{\sum_{n=1}^N w_n^{(m)} [y_m(\mathbf{x}_n) \neq t_n]}{\sum_{n=1}^N w_n^{(m)}}, \quad \alpha_m = \ln \left( \frac{1 - \epsilon_m}{\epsilon_m} \right);$$

- ③ пересчитываем новые веса

$$w_n^{(m+1)} = w_n^{(m)} e^{\alpha_m [y_m(\mathbf{x}_n) \neq t_n]}.$$

- После обучения предсказываем как
- $$Y_M(\mathbf{x}) = \text{sign} \left( \sum_{m=1}^M \alpha_m y_m(\mathbf{x}) \right).$$

# AdaBoost

- Смысл именно такой, как мы говорили: сначала тренируем абстрактно лучший классификатор. Потом увеличиваем веса неправильно классифицированным примерам, обучаем новый классификатор, и т.д.

# Weak learners: деревья принятия решений

- А что за weak learners применяются в реальных приложениях?
- Обычно бустинг применяется, когда есть набор уже посчитанных фич (посчитанных из каких-то более сложных моделей), и нужно объединить их в единую модель.
- Часто слабые классификаторы совершенно тупые: берём одну координату и ищем по ней оптимальное разбиение.
- Могут быть чуть посложнее: деревья принятия решений.

# Weak learners: деревья принятия решений

- Дерево принятия решений — это дерево. На нём есть метки:
  - в узлах, не являющиеся листьями: атрибуты (фичи), по которым различаются случаи;
  - в листьях: значения целевой функции;
  - на рёбрах: значения атрибута, из которого исходит ребро.
- Чтобы классифицировать новый случай, нужно спуститься по дереву до листа и выдать соответствующее значение.

# Weak learners: деревья принятия решений

- Конечно, перебрать все деревья нельзя, их строят жадно.
  - ① Выбираем очередной атрибут  $Q$ , помещаем его в корень.
  - ② Выбираем оптимальное разбиение по атрибуту. Для всех интервалов разбиения:
    - оставляем из тестовых примеров только те, у которых значение атрибута  $Q$  попало в этот интервал;
    - рекурсивно строим дерево в этом потомке.
- Остались три вопроса:
  - ① как проводить разбиение?
  - ② как выбирать новый атрибут?
  - ③ когда останавливаться?

# Weak learners: деревья принятия решений

- Если атрибут бинарный или дискретный с небольшим числом значений, разбиение тривиальное (просто по значениям).
- Если непрерывный – можно брать просто среднее арифметическое (тем самым минимизируя сумму квадратов).
- Выбирают атрибут, оптимизируя целевую функцию. Для задачи регрессии просто минимизируем среднеквадратическую ошибку по отношению к текущему предсказателю

$$y_\tau = \frac{1}{|\mathbf{X}_\tau|} \sum_{x_n \in \mathbf{X}_\tau} t_n.$$

# Weak learners: деревья принятия решений

- Предположим, что мы решаем задачу классификации на  $K$  классов.
- Тогда «сложность» подмножества данных  $\mathbf{X}_\tau$  относительно целевой функции  $f(\mathbf{x}) : \mathbf{X} \rightarrow \{1, \dots, K\}$  характеризуется *перекрёстной энтропией*:

$$Q(\mathbf{X}_\tau) = \sum_{k=1}^K p_{\tau,k} \ln p_{\tau,k}.$$

- Иногда ещё используют *индекс Джини* (Gini index):  
$$G(\mathbf{X}_\tau) = \sum_{k=1}^K p_{\tau,k}(1 - p_{\tau,k}).$$

# Weak learners: деревья принятия решений

- Когда останавливаться? Недоучиться плохо и переучиться плохо.
- Останавливаются, когда ошибка перестанет меняться, тоже плохо (она может опять начать меняться ниже).
- Поэтому делают так: выращивают большое дерево, чтобы наверняка, а потом обрезают его (*pruning*): поддерево τ схлопывают в корень, а правило предсказания в корне считают как  $y_\tau = \frac{1}{|\mathbf{X}_\tau|} \sum_{\mathbf{x}_n \in \mathbf{X}_\tau} t_n$ .
- Обрезают, оптимизируя функцию ошибки с регуляризатором:  $\sum_{\tau=1}^{|T|} Q(\mathbf{X}_\tau) + \lambda |T|$  (для классификаторов здесь можно использовать долю ошибок классификации).

# Теоретические свойства AdaBoost

- Изначально, когда AdaBoost придумали [Freund, Shapire, 1997], мотивация была такая: предположим, что ошибка каждого слабого классификатора  $h_t$  не превышает  $\epsilon_t = \frac{1}{2} - \gamma_t$ .
- Тогда можно показать, что окончательная ошибка не превосходит

$$\prod_t \left( 2\sqrt{\epsilon_t(1-\epsilon_t)} \right) = \prod_t \sqrt{1 - 4\gamma_t^2} \leq e^{-2 \sum_t \gamma_t^2}.$$

- Однако на самом деле гарантий на  $\gamma_t$  обычно нету, и практические результаты AdaBoost лучше, чем можно было бы ожидать из этой оценки.

# Теоретические свойства AdaBoost

- Основная идея [Friedman et al., 2000]: давайте определим экспоненциальную ошибку

$$E = \sum_{n=1}^N e^{-t_n f_m(\mathbf{x}_n)},$$

где  $f_m$  – линейная комбинация базовых классификаторов:

$$f_m(\mathbf{x}) = \frac{1}{2} \sum_{l=1}^m \alpha_l y_l(\mathbf{x}).$$

- Мы хотим минимизировать  $E$  по  $\alpha_l$  и параметрам  $y_l(\mathbf{x})$ .

# Теоретические свойства AdaBoost

- Минимизируем  $E = \sum_{n=1}^N e^{-t_n f_m(\mathbf{x}_n)}$ .
- Вместо глобальной оптимизации будем действовать жадно: пусть  $y_1(\mathbf{x}), \dots, y_{m-1}(\mathbf{x})$  и  $\alpha_1, \dots, \alpha_{m-1}$  уже зафиксированы. Тогда ошибка получается

$$E = \sum_{n=1}^N e^{-t_n f_{m-1}(\mathbf{x}_n) - \frac{1}{2} t_n \alpha_m y_m(\mathbf{x})} = \sum_{n=1}^N w_n^{(m)} e^{-\frac{1}{2} t_n \alpha_m y_m(\mathbf{x})},$$

где  $w_N^{(m)} = e^{-t_n f_{m-1}(\mathbf{x}_n)}$  – это как раз и есть наши веса, и их теперь можно считать константами.

# Теоретические свойства AdaBoost

- На правильных классификациях произведение  $-1$ , на неправильных  $+1$ :

$$\begin{aligned} E &= e^{-\frac{\alpha_m}{2}} \sum_{\text{correct}} w_n^{(m)} + e^{\frac{\alpha_m}{2}} \sum_{\text{wrong}} w_n^{(m)} = \\ &= \left( e^{\frac{\alpha_m}{2}} - e^{-\frac{\alpha_m}{2}} \right) \sum_{n=1}^N w_n^{(m)} [y_m(\mathbf{x}_n) \neq t_n] + e^{-\frac{\alpha_m}{2}} \sum_{n=1}^N w_n^{(m)}, \end{aligned}$$

и достаточно минимизировать

$$J_m = \sum_{n=1}^N w_n^{(m)} [y_m(\mathbf{x}_n) \neq t_n].$$

# Теоретические свойства AdaBoost

- Ну а когда мы обучим  $y_m(\mathbf{x})$ , из

$$E = \sum_{n=1}^N w_n^{(m)} e^{-\frac{1}{2} t_n \alpha_m y_m(\mathbf{x})}$$
 получится

$$w_n^{(m+1)} = w_n^{(m)} e^{-\frac{1}{2} t_n \alpha_m y_m(\mathbf{x}_n)} = w_n^{(m)} e^{-\frac{1}{2} \alpha_m e^{\alpha_m [y_m(\mathbf{x}_n) \neq t_n]}},$$

и на  $e^{-\frac{1}{2} \alpha_m}$  можно все веса сократить.

- Таким образом, бустинг можно рассматривать как оптимизацию экспоненциальной ошибки.

# RankBoost

- Предположим, что нам нужно не классифицировать, а упорядочить элементы какого-то множества.
- Задача *ранжирования*: например, мы – поисковая система, и мы хотим ранжировать выдачу по какому-то запросу от более релевантных к менее.
- У нас может быть масса разных фич, характеризующих эти документы.
- Это тоже можно сделать бустингом.

# RankBoost

- Формально говоря, нам надо обучить функцию  $F(\mathbf{x}) : \mathbb{R}^n \rightarrow \mathbb{R}$  по входу  $\{\mathbf{x}_1, \dots, \mathbf{x}_N\}$  и функции частичных предпочтений  $\Phi : \mathbf{X} \times \mathbf{X} \rightarrow \mathbb{R}$  ( $\Phi(\mathbf{x}_i, \mathbf{x}_j) > 0$ , если  $\mathbf{x}_i$  лучше  $\mathbf{x}_j$ , и т.д.).
- Обычно в качестве функции  $\Phi$  подаётся просто разбиение на «хорошие» (например, релевантные) и «плохие»:  $\Phi(\mathbf{x}, \mathbf{y}) = 1$  для хорошего  $\mathbf{x}$  и плохого  $\mathbf{y}$  и 0, если они из одного множества.

# RankBoost

- RankBoost по сути работает примерно как AdaBoost, но раньше веса давали распределение на примерах, а теперь – на парах примеров: инициализируем распределение  $D^{(1)} = D(\mathbf{x}, \mathbf{y})$  на  $\mathbf{X} \times \mathbf{X}$ , а потом для  $m = 1..M$ :

- обучаем слабую ранжирующую функцию  $h_m(\mathbf{x}) : \mathbf{X} \rightarrow \mathbb{R}$  по распределению  $D^{(m)}$ ;
- выбираем  $\alpha_m \in \mathbb{R}$  (потом скажу как);
- пересчитываем новое распределение

$$D^{(m+1)}(\mathbf{x}, \mathbf{y}) = \frac{1}{Z_m} D^{(m)}(\mathbf{x}, \mathbf{y}) e^{\alpha_m (h_m(\mathbf{x}) - h_m(\mathbf{y}))}.$$

- После обучения ранжируем как  $H_M(\mathbf{x}) = \sum_{m=1}^M \alpha_m h_m(\mathbf{x})$ .

# RankBoost

- Тогда получится такая теорема: если вернуться от  $D^{(m+1)}(\mathbf{x}, \mathbf{y})$  к  $D(\mathbf{x}, \mathbf{y})$ , будет

$$D^{(m+1)}(\mathbf{x}, \mathbf{y}) = \frac{1}{\prod_m Z_m} D(\mathbf{x}, \mathbf{y}) e^{H_M(\mathbf{x}) - H_M(\mathbf{y})}.$$

- Значит, ошибку можно оценить как

$$J_M = \sum_{\mathbf{x}, \mathbf{y}} D(\mathbf{x}, \mathbf{y}) [H_M(\mathbf{x}) \geq H_M(\mathbf{y})] \leq$$

$$\leq \sum_{\mathbf{x}, \mathbf{y}} D(\mathbf{x}, \mathbf{y}) e^{H_M(\mathbf{x}) - H_M(\mathbf{y})} = \sum_{\mathbf{x}, \mathbf{y}} D^{(m+1)}(\mathbf{x}, \mathbf{y}) \prod_m Z_m = \prod_m Z_m.$$

# RankBoost

- И выбирать  $\alpha_m$  можно (и нужно) так, чтобы минимизировать  $\prod_m Z_m$ , т.е. на шаге  $m$  минимизировать

$$Z_m = \sum_{\mathbf{x}, \mathbf{y}} D^{(m)}(\mathbf{x}, \mathbf{y}) e^{\alpha_m(h_m(\mathbf{x}) - h_m(\mathbf{y}))}.$$

- Формально для нас  $h_m$  – чёрный ящик, но на практике мы часто выбираем алгоритм обучения и для  $h_m$ , так что его тоже можно выбирать так, чтобы минимизировать  $Z_m$ .

# RankBoost

- Теорема: для любого слабого ранжирования  $h$   $Z(\alpha)$  имеет единственный минимум, так что можно просто бинарным поиском.
- Если  $h \in \{0, 1\}$ , можно и аналитически: обозначим  $W_b = \sum_{x,y} D(x, y) [h(x) - h(y) = b]$ . Тогда

$$\alpha_{\text{opt}} = \frac{1}{2} \ln \left( \frac{W_{-1}}{W_{+1}} \right), \quad Z = W_0 + 2\sqrt{W_{-1}W_{+1}}.$$

**Упражнение.** Проверьте это.

# RankBoost

- А для  $h \in [0, 1]$  можно приблизить:

$$e^{\alpha x} \leq \left(\frac{1+x}{2}\right) e^\alpha + \left(\frac{1-x}{2}\right) e^{-\alpha}, \quad x \in [-1, 1], \text{ так что}$$

$$Z \leq \left(\frac{1-r}{2}\right) e^\alpha + \left(\frac{1+r}{2}\right) e^{-\alpha}, \quad r = \sum_{\mathbf{x}, \mathbf{y}} D(\mathbf{x}, \mathbf{y}) (h(\mathbf{x}) - h(\mathbf{y})),$$

и можно выбирать

$$\alpha_{\text{opt}} = \frac{1}{2} \ln \left( \frac{1+r}{1-r} \right),$$

а  $h$  можно обучать так, чтобы максимизировать  $|r|$ .

**Упражнение.** Проверьте это.

# Оценки доверия

- Предположим, что наши слабые классификаторы выдают не только один бит, а ещё какую-то оценку доверия своему результату (обычно ведь так и бывает).
- Т.е. слабый классификатор – это слабая гипотеза  $h(\mathbf{x}) : \mathbf{X} \rightarrow \mathbb{R}$ .

# Оценки доверия

- Для этого слегка обобщим исходный AdaBoost, представив его как алгоритм, пересчитывающий распределения:
  - обучаем слабую гипотезу  $h_m(\mathbf{x}) : \mathbf{X} \rightarrow \mathbb{R}$  по распределению  $D^{(m)}$ ;
  - выбираем  $\alpha_m \in \mathbb{R}$  (потом скажу как);
  - пересчитываем новое распределение

$$D^{(m+1)}(\mathbf{x}) = \frac{1}{Z_m} D^{(m)}(\mathbf{x}) e^{-\alpha_m t_m h_m(\mathbf{x})}.$$

- После обучения классифицируем как  
 $H_M(\mathbf{x}) = \text{sign} \left( \sum_{m=1}^M \alpha_m h_m(\mathbf{x}) \right).$

# Оценки доверия

- Теперь будет верна аналогичная теорема:

$$\frac{1}{N} |\{n : H(\mathbf{x}_n) \neq t_n\}| \leq \prod_{m=1}^M Z_m.$$

**Упражнение.** Докажите это.

- И, значит, мы тоже можем минимизировать  $Z_m$  жадно на каждом шаге по  $\alpha_m$  и слабой гипотезе  $h_m$ .

# Оценки доверия

- В частности, исходный AdaBoost получится как одно из приближений к такой минимизации; обозначим  $u_n = t_n y(\mathbf{x}_n)$ :

$$Z = \sum_n D(\mathbf{x}_n) e^{-\alpha u_n} \leq \sum_n D(\mathbf{x}_n) \left( \frac{1+u_i}{2} e^{-\alpha} + \frac{1-u_i}{2} e^{\alpha} \right),$$

причём эта оценка точна для  $u_n \in \{-1, 1\}$  (т.е. для исходного AdaBoost).

- Тогда для  $r = \sum_n D(\mathbf{x}_n) u_n$  мы получим аналитический минимум

$$\alpha_{\text{opt}} = \frac{1}{2} \ln \left( \frac{1+r}{1-r} \right), \quad Z \leq \sqrt{1-r^2}.$$

- И мы доказали исходную теорему про AdaBoost.

# Оценки доверия

- А для общего случая получится

$$Z = \sum_n D(\mathbf{x}_n) e^{-\alpha u_n},$$

$$Z'_\alpha = - \sum_n D(\mathbf{x}_n) u_n e^{-\alpha u_n} = -Z \sum_n D^{(m+1)}(\mathbf{x}_n) e^{-\alpha u_n}.$$

- Т.е. надо выбирать такой  $\alpha$ , чтобы  $Z'_\alpha = 0$ , а значит,

$$\sum_n D^{(m+1)}(\mathbf{x}_n) u_n = \mathbb{E}_{\mathbf{x} \sim D^{(m+1)}} [t_n y_m(\mathbf{x}_n)] = 0,$$

т.е. выбирать так, чтобы по  $D^{(m+1)}$  гипотеза  $h_m$  была бы некоррелирована с метками  $t_n$ .

- Это можно делать, численно решая уравнение  $Z'_\alpha = 0$ ; у него не больше одного корня (проверьте, что  $Z''_\alpha > 0$  для всех  $\alpha$ ).

Thank you!

**Спасибо за внимание!**