

# Математические основы прогнозирования временных рядов

А. М. Миронов<sup>1</sup>

В статье излагаются основные понятия и методы прогнозирования временных рядов. Рассматриваются различные алгоритмы смешивающего прогнозирования, и приводятся оценки качества этих алгоритмов.

**Ключевые слова:** временные ряды, алгоритмы прогнозирования, смешивающие алгоритмы прогнозирования

## Введение

Основным объектом исследования в данной статье являются алгоритмы прогнозирования временных рядов (называемые ниже просто алгоритмами прогнозирования), которые основаны на следующей идее: пусть заданы несколько алгоритмов прогнозирования  $A_1, \dots, A_N$ , искомый алгоритм прогнозирования  $A$  (называемый смешивающим алгоритмом) должен использовать результаты работы алгоритмов  $A_1, \dots, A_N$ , качество прогнозирования смешивающего алгоритма  $A$  (т.е. доля правильных прогнозов этого алгоритма) должно быть близким к качеству наилучшего из алгоритмов  $A_1, \dots, A_N$ .

Цель настоящей работы заключается в систематизации изложения основных подходов к смешивающему прогнозированию. Содержание работы имеет следующий вид. Сначала рассматриваются простейшие алгоритмы смешивающего прогнозирования: алгоритм большинства, алгоритм взвешенного большинства, алгоритм оптимального распределения потерь. Далее рассматриваются более сложные алгоритмы смешивающего прогнозирования: алгоритм следования за возмущённым лидером, агрегирующий алгоритм Вовка. Кроме того, рассматривается алгоритм усиления классификаторов (бустинг), природа которого сходна природе смешивающих алгоритмов. Затем рассматриваются понятие прогнозной стратегии и примеры детерминированной и вероятностной прогнозных стратегий. Содержание статьи основано на материале из книги [1], в настоящем тексте представлены новые, более простые доказательства соответствующих теорем из [1].

---

<sup>1</sup>*Миронов Андрей Михайлович* — доцент каф. математической теории интеллектуальных систем мех.-мат. ф-та МГУ, e-mail: amironov66@gmail.com.

Mironov Andrew Mikhaylovich — associate professor, Lomonosov Moscow State University, Faculty of Mechanics and Mathematics, Chair of Mathematical Theory of Intellectual Systems.

# 1. Задача прогнозирования временных рядов

Под **временным рядом** понимается последовательность  $y = (y_1, y_2, \dots)$  элементов некоторого множества  $Y$ , называемых **исходами**. Мы будем рассматривать случай, когда  $Y = \{0, 1\}$  или  $[0, 1]$  (вместо 0 м.б.  $-1$ ).

Прогнозируемый временной ряд  $y$  может быть бесконечным или иметь конечную длину, которую мы будем обозначать символом  $T$ , т.е. во втором случае  $y = (y_1, \dots, y_T)$ .

Задача прогнозирования временного ряда  $y$  заключается в построении **прогнозирующего алгоритма (ПА)**  $A$ , который на каждом шаге прогнозирования  $t = 1, 2, \dots$  выдаёт значение  $\gamma_t \in Y$ , называемое **прогнозом** временного ряда  $y$  на шаге  $t$ . После того, как  $A$  выдал  $\gamma_t$ , становится известным значение  $y_t \in Y$  **исхода** в момент  $t$ .

На каждом шаге прогнозирования  $t$ , который выполняет ПА  $A$ , определена **потеря**  $l_t \in [0, 1]$  ПА  $A$ , связанная с несовпадением прогноза  $\gamma_t$  и исхода  $y_t$ . Будем считать, что  $l_t = 0$  тогда и только тогда, когда  $\gamma_t = y_t$ . Как правило, потеря  $l_t$  является значением некоторой **функции потерь**  $\lambda$  на паре  $(\gamma_t, y_t)$ , например  $l_t = \llbracket \gamma_t \neq y_t \rrbracket$ . Напомним, что для каждого логического утверждения  $\varphi$  запись  $\llbracket \varphi \rrbracket$  обозначает число 1, если  $\varphi$  истинно, и 0, если  $\varphi$  ложно. Если  $y = (y_1, \dots, y_T)$ , то будем называть **кумулятивной потерей** ПА  $A$  величину  $L_T \stackrel{\text{def}}{=} \sum_{t=1}^T l_t$ .

## 2. Смешивающее прогнозирование

Один из методов построения прогнозирующих алгоритмов заключается в следующем. Пусть имеется несколько ПА  $A_1, \dots, A_N$ . Для каждого  $i = 1, \dots, N$  в каждый момент времени  $t = 1, \dots, T$  ПА  $A_i$  выдаёт прогноз  $\gamma_t^i$ . Будем обозначать записью  $L_T^i$  кумулятивную потерю ПА  $A_i$ . Используя алгоритмы  $A_1, \dots, A_N$  можно построить ПА  $A$ , называемый **смешивающим** ПА. На каждом шаге прогнозирования  $t$  прогноз  $\gamma_t$ , выдаваемый алгоритмом  $A$ , определяется как некоторая функция от прогнозов  $\gamma_t^1, \dots, \gamma_t^N$ , называемая **функцией смешивания**.

Алгоритмы  $A_1, \dots, A_N$ , участвующие в определении смешивающего ПА  $A$ , будем называть **экспертами**. Экспертов можно сравнивать по качеству их прогнозов: эксперт  $A_i$  лучше эксперта  $A_j$ , если  $L_T^i < L_T^j$ . Будем обозначать экспертов просто их номерами  $1, \dots, N$ , и множество экспертов  $\{1, \dots, N\}$  будем обозначать символом  $I$ .

Величина  $R_T = L_T - \min_{i \in I} L_T^i$  называется **регретом** смешивающего ПА  $A$ . Данная величина выражает собой отличие кумулятивной потери ПА  $A$  от кумулятивной потери наилучшего эксперта. При построении смешивающих ПА функция смешивания должна выбираться так, чтобы регрет смешивающего ПА был как можно меньше.

### 3. Алгоритм большинства

В этом пункте излагается простейший смешивающий ПА, который может использоваться лишь в ситуации, когда среди экспертов из множества  $I = \{1, \dots, N\}$  существует эксперт  $i_0$ , в каждый момент времени выдающий правильный прогноз, т.е. такой, что  $\forall t \geq 1 \quad \gamma_t^{i_0} = y_t$ . Этот алгоритм называется **алгоритмом большинства (Majority Algorithm, МА)**. Прогнозы данного ПА определяются следующим образом:

$$\forall t \geq 1 \quad \gamma_t := \lfloor \lfloor \{i \in B_t \mid \gamma_t^i = 1\} \rfloor \geq \frac{|B_t|}{2} \rfloor, \quad (1)$$

где для каждого конечного множества  $X$  запись  $|X|$  обозначает число элементов в  $X$ , и  $\forall t \geq 1$  множество  $B_t$  определяется следующим образом:

$$B_t = \{i \in I \mid \forall t' = 1, \dots, t-1 \quad \gamma_{t'}^i = y_{t'}\}. \quad (2)$$

Будем говорить, что ПА  $A$  делает **ошибку** на шаге  $t$ , если  $\gamma_t \neq y_t$ .

#### Теорема 1.

МА делает не более  $\log_2 N$  ошибок.

#### Доказательство.

Нетрудно видеть, что последовательность множеств (2) обладает свойством  $B_1 \supseteq B_2 \supseteq \dots$ , и каждое из множеств  $B_t$  непусто, т.к.  $i_0 \in B_t$ .

Если МА делает ошибку на шаге  $t$ , т.е.  $\gamma_t \neq y_t$ , то

- либо  $\gamma_t = 1$  и  $y_t = 0$ , в этом случае, согласно (1),

$$|\{i \in B_t \mid \gamma_t^i = 1\}| \geq \frac{|B_t|}{2}, \quad (3)$$

согласно (2),  $B_{t+1} = \{i \in B_t \mid \gamma_t^i = 0\}$ , и из (3) следует  $|B_{t+1}| \leq \frac{|B_t|}{2}$ ,

- либо  $\gamma_t = 0$  и  $y_t = 1$ , в этом случае, согласно (1),

$$|\{i \in B_t \mid \gamma_t^i = 1\}| < \frac{|B_t|}{2}, \quad (4)$$

согласно (2),  $B_{t+1} = \{i \in B_t \mid \gamma_t^i = 1\}$ , и из (4) следует  $|B_{t+1}| < \frac{|B_t|}{2}$ .

В обоих случаях  $|B_{t+1}| \leq \frac{|B_t|}{2}$ .

Пусть МА делает  $k$  ошибок, и  $t$  – момент, в который делается  $k$ -я ошибка, тогда, по установленному выше,

$$N \geq |B_1| \geq 2^k |B_{t+1}|. \quad (5)$$

Учитывая  $|B_{t+1}| \geq 1$ , из (5) получаем  $N \geq 2^k$ , или  $k \leq \log_2 N$ . ■

## 4. Алгоритм взвешенного большинства

В этом пункте излагается смешивающий алгоритм, называемый **алгоритмом взвешенного большинства (Weighted Majority Algorithm, WMA)**, впервые он был изложен в работе [2]. Данный алгоритм может использоваться в том случае, когда среди экспертов из  $I = \{1, \dots, N\}$  может не быть эксперта, выдающего в каждый момент времени правильный прогноз.

В каждый момент времени  $t$  данный алгоритм сопоставляет каждому эксперту  $i \in I$  некоторое число  $w_t^i \in [0, 1]$ , называемое **весом** этого эксперта. В начальный момент  $t = 1$  вес каждого эксперта равен 1. Считаем, что потери имеют вид  $l_t = |\gamma_t - y_t|$ ,  $l_t^i = |\gamma_t^i - y_t|$ .

Прогнозы данного ПА и изменения весов определяются следующим образом: выбирается параметр  $\varepsilon \in (0, 1)$ , и

$$\forall t = 1, \dots, T \quad \begin{cases} \gamma_t := \lfloor \sum_{i:\gamma_t^i=0} w_t^i \leq \sum_{i:\gamma_t^i=1} w_t^i \rfloor \\ w_{t+1}^i := w_t^i(1 - \varepsilon l_t^i). \end{cases} \quad (6)$$

### Теорема 2.

Для кумулятивных потерь WMA верно неравенство

$$L_T \leq \frac{2}{1-\varepsilon} \min_{i \in I} L_T^i + \frac{2}{\varepsilon} \ln N \quad (7)$$

(т.е. WMA ошибается примерно не более чем в  $\frac{2}{1-\varepsilon}$  раз, чем наилучший эксперт).

### Доказательство.

Будем использовать следующие обозначения:

$$M = L_T, \quad m = \min_{i \in I} L_T^i, \quad |\vec{w}_t| = \sum_{i \in I} w_t^i.$$

Пусть  $i$  – номер наилучшего эксперта.

$w_t^i$  корректируется  $\leq m$  раз, поэтому

$$|\vec{w}_T| \geq w_T^i \geq (1 - \varepsilon)^m. \quad (8)$$

Нетрудно проверить (это делается так же, как в доказательстве предыдущей теоремы), что если WMA делает ошибку на шаге  $t$ , то

$$\sum_{i:\gamma_t^i \neq y_t} w_t^i \geq \sum_{i:\gamma_t^i = y_t} w_t^i. \quad (9)$$

Прибавив к обеим частям (9) слагаемое  $\sum_{i:\gamma_t^i \neq y_t} w_t^i$ , получаем

$$\sum_{i:\gamma_t^i \neq y_t} w_t^i \geq \frac{|\vec{w}_t|}{2}. \quad (10)$$

Из (10) и из определения  $w_{t+1}^i$  в (6) следует, что если WMA делает ошибку на шаге  $t$ , то

$$\begin{aligned} |\vec{w}_{t+1}| &= \sum_{i \in I} w_t^i (1 - \varepsilon l_t^i) = \\ &= |\vec{w}_t| - \varepsilon \sum_{i: \gamma_t^i \neq y_t} w_t^i \leq |\vec{w}_t| (1 - \frac{\varepsilon}{2}), \end{aligned}$$

т.е. если WMA делает ошибку на шаге  $t$ , то  $\frac{|\vec{w}_{t+1}|}{|\vec{w}_t|} \leq 1 - \frac{\varepsilon}{2}$ .

Из определения весов в (6) следует, что для каждого  $t = 1, \dots, T - 1$   $\frac{|\vec{w}_{t+1}|}{|\vec{w}_t|} \leq 1$ . Следовательно,

$$\frac{|\vec{w}_T|}{|\vec{w}_1|} = \prod_{t=1}^{T-1} \frac{|\vec{w}_{t+1}|}{|\vec{w}_t|} \leq (1 - \frac{\varepsilon}{2})^M,$$

откуда, учитывая (8) и равенство  $|\vec{w}_1| = N$ , получаем неравенство

$$\frac{(1-\varepsilon)^m}{N} \leq (1 - \frac{\varepsilon}{2})^M,$$

логарифмируя которое, и учитывая неравенство

$$\ln(1 + x) \leq x \quad \text{при } x \in (-1, 1) \quad (11)$$

получаем:

$$m \ln(1 - \varepsilon) - \ln N \leq M \ln(1 - \frac{\varepsilon}{2}) \leq -\frac{\varepsilon}{2} M$$

откуда следует неравенство

$$\frac{\varepsilon}{2} M \leq m \ln \frac{1}{1-\varepsilon} + \ln N. \quad (12)$$

Применяя (11) для  $x = \frac{\varepsilon}{1-\varepsilon}$ , получаем соотношения

$$\ln \frac{1}{1-\varepsilon} = \ln(1 + \frac{\varepsilon}{1-\varepsilon}) \leq \frac{\varepsilon}{1-\varepsilon} \quad (13)$$

Из (12) и (13) следует неравенство

$$\frac{\varepsilon}{2} M \leq m \frac{\varepsilon}{1-\varepsilon} + \ln N,$$

которое эквивалентно доказываемому неравенству (7). ■

## 5. Алгоритм оптимального распределения потерь

В этом пункте рассматривается другая постановка задачи построения смешивающего ПА: как и выше, задано множество экспертов  $I = \{1, \dots, N\}$ , но для каждого шага прогнозирования  $t$  вместо прогнозов экспертов  $\gamma_t^i$  известны лишь потери  $l_t^i \in [0, 1]$ , которые несут эксперты на шаге  $t$ . Требуется построить ПА, кумулятивные потери которого были бы как можно ближе к кумулятивным потерям наилучшего из этих экспертов (т.е. к  $\min_{i \in I} L_T^i$ ).

Будем использовать понятие **вероятностного распределения (ВР)** на множестве  $I = \{1, \dots, N\}$ , которое представляет собой произвольный вектор  $\vec{p} = (p^1, \dots, p^N)$  неотрицательных действительных чисел, удовлетворяющих условию  $\sum_{i \in I} p^i = 1$ . Множество всех ВР на  $I$  будем обозначать записью  $I^\Delta$ . Вектор из  $I^\Delta$ , все компоненты которого совпадают (т.е. равны  $\frac{1}{N}$ ) будем называть **равномерно распределённым (р.р.)**.

Также будем использовать следующее обозначение – если  $\vec{w}$  – вектор неотрицательных действительных чисел вида  $(w^1, \dots, w^N)$ , то  $norm(\vec{w})$  – это ВР  $(p^1, \dots, p^N)$ , где

$$\forall i \in I \quad p^i = \frac{w^i}{|\vec{w}|}, \quad \text{где } |\vec{w}| = \sum_{i=1}^N w^i.$$

Предлагается следующее решение описанной выше задачи: на каждом шаге прогнозирования  $t$  определяется ВР  $\vec{p}_t = (p_t^1, \dots, p_t^N) \in I^\Delta$ , и прогноз искомого алгоритма  $A$  на шаге  $t$  полагается равным прогнозу эксперта  $i$ , номер которого выбран из  $I$  случайным образом, в соответствии с распределением  $\vec{p}_t$  (т.е. с вероятностью  $p_t^1$  выбран эксперт 1, с вероятностью  $p_t^2$  выбран эксперт 2, и т.д.). Потери ПА  $A$  в момент  $t$  совпадают с потерями выбранного эксперта  $i$  в момент  $t$ .

Нетрудно видеть, что математическое ожидание  $l_t$  потери ПА  $A$  в момент  $t$  совпадает со **скалярным произведением**  $\langle \vec{p}_t, \vec{l}_t \rangle = \sum_{i \in I} p_t^i l_t^i$ , где  $\vec{l}_t = (l_t^1, \dots, l_t^N)$ .

$\forall t = 1, \dots, T$  определяем  $\vec{p}_t$  как  $norm(\vec{w}_t)$ , где

$$\begin{aligned} \vec{w}_1 & \text{ – р.р.} \\ \forall t = 1, \dots, T-1, \forall i \in I \quad w_{t+1}^i & := w_t^i \beta^i \end{aligned} \tag{14}$$

где  $\beta \in (0, 1)$  – параметр.

Описанный выше алгоритм называется **алгоритмом оптимального распределения потерь**, и обозначается записью  $Hedge(\beta)$ . Впервые он был изложен в [3].

### Лемма 1.

Средняя кумулятивная потеря  $L_T = \sum_{t=1}^T l_t$  данного алгоритма удовлетворяет неравенству

$$\ln |\vec{w}_{T+1}| \leq -(1 - \beta)L_T. \tag{15}$$

### Доказательство.

Докажем эквивалентное неравенство:

$$|\vec{w}_{T+1}| \leq e^{-(1-\beta)L_T}. \tag{16}$$

Согласно определению (14),  $\forall t = 1, \dots, T$

$$|\vec{w}_{t+1}| = \sum_{i \in I} w_{t+1}^i = \sum_{i \in I} w_t^i \beta^{l_t^i} \leq \sum_{i \in I} w_t^i (1 - (1 - \beta)l_t^i) \quad (17)$$

(в (17) используем неравенство

$$\beta^{l_t^i} \leq 1 - (1 - \beta)l_t^i, \quad (18)$$

которое следует из выпуклости функции  $y = \beta^x$ ).

Правая часть (17) равна

$$|\vec{w}_t| - (1 - \beta) \sum_{i \in I} w_t^i l_t^i = |\vec{w}_t| (1 - (1 - \beta)l_t) \quad (19)$$

Из неравенства  $1 + x \leq e^x$  ( $\forall x \in \mathbb{R}$ ), где  $\mathbb{R}$  обозначает множество действительных чисел, следует неравенство

$$1 - (1 - \beta)l_t \leq e^{-(1-\beta)l_t} \quad (20)$$

Из (17), (19) и (20) следует, что  $\forall t = 1, \dots, T$

$$|\vec{w}_{t+1}| \leq |\vec{w}_t| e^{-(1-\beta)l_t} \quad (21)$$

Перемножая неравенства (21) для  $t = 1, \dots, T$ , производя сокращения, и учитывая  $|\vec{w}_1| = 1$ , получаем искомое неравенство (16). ■

Перепишем (15) в виде

$$L_T \leq -\frac{1}{1-\beta} \ln |\vec{w}_{T+1}|. \quad (22)$$

$\forall i \in I$  из неравенства  $w_{T+1}^i \leq |\vec{w}_{T+1}|$  следует неравенство

$$-\frac{1}{1-\beta} \ln |\vec{w}_{T+1}| \leq -\frac{1}{1-\beta} \ln w_{T+1}^i \quad (23)$$

Из (14) следует, что

$$w_{T+1}^i = w_1^i \beta^{L_T^i} = \frac{1}{N} \beta^{L_T^i}. \quad (24)$$

Из (22), (23) и (24) следует, что

$$L_T \leq -\frac{1}{1-\beta} (\ln \frac{1}{N} + L_T^i \ln \beta). \quad (25)$$

Поскольку  $\forall i \in I$  верно (25), то получаем соотношение

$$L_T \leq \frac{1}{1-\beta} \ln \frac{1}{\beta} \min_{i \in I} L_T^i + \frac{\ln N}{1-\beta}. \quad (26)$$

Неравенство (26) означает, что средние кумулятивные потери ПА  $Hedge(\beta)$  не превосходят кумулятивных потерь наилучшего эксперта,

умноженных на константу  $\frac{1}{1-\beta} \ln \frac{1}{\beta}$ , к которым добавлен регрет (т.е. ошибка обучения)  $\frac{\ln N}{1-\beta}$ .

### Теорема 3.

Если в ПА  $Hedge(\beta)$  значение параметра  $\beta$  равно  $\frac{1}{1+\sqrt{\frac{2}{T/\ln N}}}$ , то

$$L_T \leq \min_{i \in I} L_T^i + \sqrt{2T \ln N} + \ln N. \quad (27)$$

### Доказательство.

Сначала докажем утверждение: если действительные числа  $L, L', R, R'$  удовлетворяют неравенствам  $L' > L \geq 0, R' \geq R > 0$ , и  $\beta = \frac{1}{1+\sqrt{\frac{2}{L'/R'}}}$ , то

$$\frac{1}{1-\beta} \ln \frac{1}{\beta} L + \frac{1}{1-\beta} R \leq L + \sqrt{2L'R'} + R. \quad (28)$$

Обозначим  $\sigma = \sqrt{2R'/L'}$ .

Имеет место неравенство

$$\ln \frac{1}{\beta} \leq \frac{1-\beta^2}{2\beta} \quad (29)$$

т.к. производная функции  $f(\beta) = \frac{1-\beta^2}{2\beta} - \ln \frac{1}{\beta}$  равна  $-\frac{(\beta-1)^2}{2\beta^2}$ , и поскольку  $f(1) = 0$ , то если бы неравенство (29) было бы неверно, т.е.  $f(\beta) < 0$ , то, по теореме Лагранжа,  $\exists \beta' \in (0, 1) : f'(\beta') > 0$ , что невозможно (производная функции  $f$  отрицательна во всех точках интервала  $(0, 1)$ ).

Из (29) следует, что  $\frac{1}{1-\beta} \ln \frac{1}{\beta} \leq \frac{1+\beta}{2\beta}$ , поэтому

$$\begin{aligned} \text{левая часть (28)} &\leq \frac{1+\beta}{2\beta} L + \frac{1}{1-\beta} R = \\ &= \frac{1}{2} \left(1 + \frac{1}{\beta}\right) L + \frac{1}{1-\beta} R = L + \frac{1}{2} L \sigma + \frac{1}{1-\frac{1}{1+\sigma}} R \leq \\ &\leq L + \sqrt{\frac{L'R'}{2}} + R + \frac{R}{\sigma} \leq \text{правая часть (28)}. \end{aligned}$$

(мы используем равенство  $\frac{1}{1-\frac{1}{1+\sigma}} = 1 + \frac{1}{\sigma}$ ).

Рассматривая (28) для  $L = \min_{i \in I} L_T^i, L' = T, R = R' = \ln N$ , и учитывая (26), получаем (27). ■

## 6. Бустинг

В этом параграфе рассматривается задача построения сильных алгоритмов машинного обучения. Для ее описания приведем необходимые определения.

Пусть заданы множества  $X$  и  $Y$ , элементы которых называются **объектами** и **ответами** соответственно, как правило,  $Y = \{0, 1\}$ . **Обучающей выборкой (ОВ)** будем называть совокупность  $S$  вида

$$S = \{(x^i, y^i, p^i) \mid i \in I\} \quad (30)$$

где  $I = \{1, \dots, N\}$ ,  $\forall i \in I \ x^i \in X, y^i \in Y, (p^1, \dots, p^N) \in I^\Delta$ . Запись  $|S|$  обозначает число компонентов в  $S$  (т.е.  $N$ ).

Каждая тройка  $(x, y, p)$  из ОВ  $S$  интерпретируется как утверждение о том, что объекту  $x$  соответствует ответ  $y$  с мерой уверенности  $p$ .

Под **алгоритмом машинного обучения (АМО)** понимаем алгоритм, получающий на вход ОВ  $S$ , и выдающий функцию  $h : X \rightarrow Y$ , называемую **классификатором**. **Ошибка** классификатора  $h$  на ОВ  $S$  – это число

$$Err(h, S) = \sum_{i \in I} p^i [h(x^i) \neq y^i].$$

АМО называется

- **сильным**, если для каждой ОВ  $S$  и  $\forall \varepsilon, \delta \in (0, 1)$  он выдает с вероятностью  $> 1 - \delta$  за время, полиномиально зависящее от  $\frac{1}{\varepsilon}, \frac{1}{\delta}, |S|$ , классификатор  $h$ , такой, что  $Err(h, S) \leq \varepsilon$ ,
- **слабым**, если для каждой ОВ  $S \exists \varepsilon \in (0, \frac{1}{2})$ :  $\forall \delta \in (0, 1)$  верно то же свойство, что и для сильного АМО.

Ниже решается следующая задача: пусть имеется слабый АМО, требуется на базе него построить сильный АМО. Метод преобразования слабого АМО в сильный АМО называется **бустингом**. Излагаемый ниже бустинг называется **AdaBoost (адаптивное усиление)**. Впервые он был изложен в [3]. Говоря неформально, в основе данного бустинга лежит выделение таких элементов ОВ  $S$ , на которых классификатор  $h$ , получаемый при помощи слабого АМО делает наибольшую ошибку, и коррекция  $h$  на именно этих элементах. Входными данными для алгоритма AdaBoost являются ОВ (30) и слабый АМО *WeakLearn*.

Алгоритм AdaBoost имеет следующий вид. Выбирается натуральное число  $T$ , и выполняется нижеследующая последовательность из  $T$  шагов. На каждом шаге  $t = 1, \dots, T$  определяются следующие объекты:

- вектора  $\vec{w}_t = (w_t^1, \dots, w_t^N)$  и  $\vec{p}_t = (p_t^1, \dots, p_t^N)$ , где

$$\begin{aligned} \vec{p}_t &= \text{norm}(\vec{w}_t), \\ \vec{w}_1 &= (p^1, \dots, p^N) \quad (p^i - \text{компоненты исходной ОВ } S, \end{aligned}$$

- классификатор  $h_t$ , получаемый применением исходного слабого АМО *WeakLearn* к ОВ  $S(\vec{p}_t)$ , где  $S(\vec{p}_t)$  получается из  $S$  заменой в каждой входящей в неё тройке  $(x^i, y^i, p^i)$  компоненты  $p^i$  на  $p_t^i$ ,

- $\varepsilon_t := \text{Err}(h_t, S(\vec{p}_t)) (< \frac{1}{2})$ ,  $\beta_t := \frac{\varepsilon_t}{1-\varepsilon_t}$ ,
- $w_{t+1}^i := w_t^i \beta_t^{l_t^i}$ , где  $l_t^i = \llbracket h_t(x^i) = y^i \rrbracket$ .

Затем определяется искомый классификатор  $h$ :

$$h(x) = \llbracket \langle \vec{q}, \vec{h}(x) \rangle \geq \frac{1}{2} \rrbracket \quad (31)$$

где  $\vec{q} = \text{norm}(\ln \frac{1}{\beta_1}, \dots, \ln \frac{1}{\beta_T})$ ,  $\vec{h}(x) = (h_1(x), \dots, h_T(x))$ .

#### Теорема 4.

Ошибка результирующего классификатора (31) удовлетворяет неравенству

$$\text{Err}(h, S) \leq 2^T \prod_{t=1}^T \sqrt{\varepsilon_t(1-\varepsilon_t)}. \quad (32)$$

#### Доказательство.

Согласно определениям,  $\forall t = 1, \dots, T$  верны равенства

$$\varepsilon_t = \sum_{i \in I} p_t^i (1 - l_t^i) = 1 - \sum_{i \in I} p_t^i l_t^i = 1 - \frac{1}{|\vec{w}_t|} \sum_{i \in I} w_t^i l_t^i$$

Следовательно,  $\sum_{i \in I} w_t^i l_t^i = |\vec{w}_t| (1 - \varepsilon_t)$ , откуда, учитывая неравенство (18) для  $\beta = \beta_t$ , получаем:

$$\begin{aligned} |\vec{w}_{t+1}| &= \sum_{i \in I} w_t^i \beta_t^{l_t^i} \leq \sum_{i \in I} w_t^i (1 - (1 - \beta_t) l_t^i) = \\ &= |\vec{w}_t| - (1 - \beta_t) \sum_{i \in I} w_t^i l_t^i = \\ &= |\vec{w}_t| - (1 - \beta_t) |\vec{w}_t| \sum_{i \in I} p_t^i l_t^i = \\ &= |\vec{w}_t| (1 - (1 - \beta_t)(1 - \varepsilon_t)) = |\vec{w}_t| 2\varepsilon_t. \end{aligned} \quad (33)$$

Таким образом,  $\forall t = 1, \dots, T$

$$|\vec{w}_{t+1}| \leq |\vec{w}_t| 2\varepsilon_t. \quad (34)$$

Перемножая неравенства (34) для  $t = 1, \dots, T$ , и учитывая  $|\vec{w}_1| = 1$ , получаем:

$$|\vec{w}_{T+1}| \leq 2^T \prod_{t=1}^T \varepsilon_t. \quad (35)$$

Отметим, что  $\forall i \in I$  из  $h(x_i) \neq y_i$  следует, что

$$\prod_{t=1}^T \beta_t^{l_t^i} \geq (\prod_{t=1}^T \beta_t)^{1/2} \quad (36)$$

Действительно,  $l_t^i = 1 - |h_t(x_i) - y_i|$ , и

- если  $y_i = 0$  и  $h(x_i) = 1$ , то  $\forall t = 1, \dots, T$

$$\begin{aligned} \beta_t^{l_t^i} &= \beta_t^{1 - |h_t(x_i) - y_i|} = \beta_t^{1 - h_t(x_i)} \\ \sum_{t=1}^T \ln \frac{1}{\beta_t} h_t(x_i) &\geq \frac{1}{2} \sum_{t=1}^T \ln \frac{1}{\beta_t} \end{aligned}$$

откуда следует (36) для данного случая, и

- если  $y_i = 1$  и  $h(x_i) = 0$ , то  $\forall t = 1, \dots, T$

$$\beta_t^{l_i} = \beta_t^{1-|h_t(x_i)-y_i|} = \beta_t^{h_t(x_i)}$$

$$\sum_{t=1}^T \ln \frac{1}{\beta_t} h_t(x_i) < \frac{1}{2} \sum_{t=1}^T \ln \frac{1}{\beta_t}$$

откуда следует (36) для данного случая.

Учитывая (36), получаем:

$$|\vec{w}_{T+1}| \geq \sum_{i:h(x_i) \neq y_i} w_{T+1}^i = \sum_{i:h(x_i) \neq y_i} p^i \prod_{t=1}^T \beta_t^{l_i} \geq$$

$$\geq (\sum_{i:h(x_i) \neq y_i} p^i) (\prod_{t=1}^T \beta_t)^{1/2} = Err(h, S) (\prod_{t=1}^T \beta_t)^{1/2},$$

откуда, учитывая (35), получаем (32). ■

### Следствие 1.

Пусть  $\forall t = 1, \dots, T$  ошибка  $\varepsilon_t$  классификатора  $h_t$  из алгоритма AdaBoost удовлетворяет условию  $\varepsilon_t \leq \frac{1}{2} - \gamma_t$ , где  $\gamma_t > 0$ . Тогда ошибка результирующего классификатора (31) удовлетворяет условию

$$Err(h, S) \leq e^{-2 \sum_{t=1}^T \gamma_t^2}. \quad (37)$$

### Доказательство.

В данном случае правая часть (32) равна

$$\prod_{t=1}^T \sqrt{1 - 4\gamma_t^2} = e^{\sum_{t=1}^T \frac{1}{2} \ln(1 - 4\gamma_t^2)},$$

откуда, учитывая неравенство  $\ln(1 - 4\gamma_t^2) \leq -4\gamma_t^2$ , получаем (37). ■

В частности, если  $\forall t = 1, \dots, T$   $\gamma_t = \gamma$ , то (37) будет иметь вид

$$Err(h, S) \leq e^{-2T\gamma^2}$$

откуда получаем оценку на число итераций AdaBoost, достаточных для выполнения условия  $Err(h, S) < \varepsilon$ :

$$T > \frac{1}{2\gamma^2} \ln \frac{1}{\varepsilon}.$$

## 7. Алгоритм следования за возмущённым лидером

В этом пункте рассматривается другой подход к решению задачи прогнозирования, описанной в пункте 5. ПА, построенный в соответствии с данным подходом, называется **алгоритмом следования за возмущённым лидером (Follow the Perturbed Leader, FPL)**, описания данного алгоритма и его разновидностей впервые было изложено

в работах [4], [5], [6], [7]. Данный алгоритм является вероятностной модификацией обычного ПА  $A$  следования за лидером, который имеет следующий вид: на каждом шаге прогнозирования  $t$  определяется лидер, т.е. такой эксперт  $i$ , кумулятивные потери  $L_{t-1}^i$  которого минимальны, и на шаге  $t$  прогноз  $A$  полагается равным прогнозу лидера  $i$ . Потери ПА  $A$  в момент  $t$  совпадают с потерями эксперта  $i$  в момент  $t$ . Такой ПА может привести к потерям, существенно превышающим потери каждого из экспертов. Например, пусть число экспертов равно двум, и последовательности их потерь на шагах  $1, \dots, 7$  имеют вид

$$\begin{aligned} l_{1,\dots,7}^1 &= (0.5, 0, 1, 0, 1, 0, 1), \\ l_{1,\dots,7}^2 &= (0, 1, 0, 1, 0, 1, 0). \end{aligned}$$

Последовательности соответствующих кумулятивных потерь имеют вид

$$\begin{aligned} L_{1,\dots,7}^1 &= (0.5, 0.5, 1.5, 1.5, 2.5, 2.5, 3.5), \\ L_{1,\dots,7}^2 &= (0, 1, 1, 2, 2, 3, 3). \end{aligned}$$

Нетрудно видеть, что в данном случае лидерами на шагах  $2, \dots, 7$  являются соответственно  $2, 1, 2, 1, 2, 1$ , и каждый раз, следуя за лидером на текущем шаге, ПА следования за лидером будет нести потерю  $1$ , и его кумулятивные потери на шагах  $2, \dots, 7$  будет иметь вид

$$L_{2,\dots,7} = (1, 2, 3, 4, 5, 6)$$

т.е. его кумулятивные потери на каждом шаге примерно вдвое больше кумулятивных потерь каждого из экспертов.

Излагаемый ниже ПА FPL отличается от детерминированного ПА следования за лидером лишь в изменении понятия лидера: на каждом шаге  $t$  лидером среди экспертов  $1, \dots, N$  является тот эксперт  $i$  (называемый **возмущённым лидером**), у которого минимальной является величина

$$L_{t-1}^i - \frac{1}{\varepsilon_t} \xi^i,$$

где  $\varepsilon_t$  – параметр, и  $\xi^1, \dots, \xi^N$  – независимые одинаково распределенные **случайные величины (СВ)**, с экспоненциальным законом распределения, т.е. их плотность имеет вид  $p(x) = e^{-x}$  ( $x \geq 0$ ).

$\forall t = 1, \dots, T$  обозначим

$$\begin{aligned} i_t &= \text{СВ } \arg \min_{i \in I} (L_{t-1}^i - \frac{1}{\varepsilon_t} \xi^i) \\ l_t &= \mathbf{E} l_t^{i_t} = \sum_{i \in I} l_t^i \mathbf{P}\{i_t = i\}, \quad L_T = \sum_{t=1}^T l_t, \end{aligned}$$

где  $\mathbf{P}\{\varphi\}$  обозначает вероятность события  $\varphi$ , а  $\mathbf{E}\xi$  обозначает математическое ожидание СВ  $\xi$ .

**Теорема 5.**

Если параметр  $\varepsilon_t$  из ПА FPL имеет вид  $\sqrt{\frac{2 \ln N}{t}}$ , то

$$L_T \leq \min_{i \in I} L_T^i + 3\sqrt{2T \ln N}. \quad (38)$$

**Доказательство.**

$\forall t = 1, \dots, T$  обозначим

$$\begin{aligned} i'_t &= \text{CB } \arg \min_{i \in I} (L_t^i - \frac{1}{\varepsilon_t} \xi^i) \\ l'_t &= \mathbf{E} l'_t = \sum_{i \in I} l_t^i \mathbf{P}\{i'_t = i\}, \quad L'_T = \sum_{t=1}^T l'_t. \end{aligned}$$

Неравенство (38) следует из доказываемых ниже соотношений (39) и (49).

1) Докажем неравенства

$$L_T \leq L'_T + \sum_{t=1}^T \varepsilon_t \leq L'_T + 2\sqrt{2T \ln N}. \quad (39)$$

Второе неравенство следует из определения  $\varepsilon_t$  и свойства

$$\sum_{t=1}^T \frac{1}{\sqrt{t}} \leq 1 + \int_1^T \frac{dt}{\sqrt{t}} < 2\sqrt{T}, \quad (40)$$

а первое неравенство следует из свойства

$$\forall t = 1, \dots, T \quad l_t - l'_t \leq \varepsilon_t l_t \quad (\leq \varepsilon_t, \text{ т.к. } l_t \in [0, 1]). \quad (41)$$

(41) следует из неравенств

$$l'_t \geq e^{-\varepsilon_t} l_t \geq (1 - \varepsilon_t) l_t. \quad (42)$$

Второе неравенство в (42) следует из свойства

$$\forall x \in \mathbb{R} \quad e^{-x} \geq 1 - x,$$

а первое неравенство в (42) можно переписать в виде

$$\sum_{i \in I} l_t^i \mathbf{P}\{i_t = i\} \leq e^{\varepsilon_t} \sum_{i \in I} l_t^i \mathbf{P}\{i'_t = i\} \quad (43)$$

(43) следует из свойства  $\forall i \in I$

$$\mathbf{P}\{i_t = i\} \leq e^{\varepsilon_t} \mathbf{P}\{i'_t = i\}. \quad (44)$$

(44) следует из соответствующих неравенств для условных вероятностей:  $\forall c_1, \dots, c_N \geq 0$

$$\begin{aligned} & \mathbf{P}\{i_t = i \mid \forall j \neq i \quad \xi^j = c_j\} \leq \\ & \leq e^{\varepsilon_t} \mathbf{P}\{i'_t = i \mid \forall j \neq i \quad \xi^j = c_j\} \end{aligned} \quad (45)$$

Докажем (45). Обозначим условие  $\forall j \neq i \quad \xi^j = c_j$  символом  $\varphi$ , и определим

$$\begin{aligned} m_i &= \min_{j \neq i} (L_{t-1}^j - \frac{1}{\varepsilon_t} c_j), \\ m'_i &= \min_{j \neq i} (L_t^j - \frac{1}{\varepsilon_t} c_j) = \min_{j \neq i} (L_{t-1}^j + l_t^j - \frac{1}{\varepsilon_t} c_j). \end{aligned}$$

Нетрудно видеть, что  $m_i \leq m'_i$ .

Используя введенные выше обозначения, неравенство (45) можно переписать в виде неравенства условных вероятностей:

$$\begin{aligned} &\mathbf{P}\{L_{t-1}^i - \frac{1}{\varepsilon_t} \xi^i \leq m_i \mid \varphi\} \leq \\ &\leq e^{\varepsilon t} \mathbf{P}\{L_{t-1}^i + l_t^i - \frac{1}{\varepsilon_t} \xi^i \leq m'_i \mid \varphi\}. \end{aligned} \quad (46)$$

Если в неравенстве в правой части (46) заменить  $l_t^i$  на 1, а  $m'_i$  на  $m_i$ , то данное неравенство усилится, поэтому (46) следует из неравенства

$$\begin{aligned} &\mathbf{P}\{L_{t-1}^i - \frac{1}{\varepsilon_t} \xi^i \leq m_i \mid \varphi\} \leq \\ &\leq e^{\varepsilon t} \mathbf{P}\{L_{t-1}^i + 1 - \frac{1}{\varepsilon_t} \xi^i \leq m_i \mid \varphi\}, \end{aligned} \quad (47)$$

которое эквивалентно неравенству

$$\begin{aligned} &\mathbf{P}\{\xi^i \geq \varepsilon_t (L_{t-1}^i - m_i) \mid \varphi\} \leq \\ &\leq e^{\varepsilon t} \mathbf{P}\{\xi^i \geq \varepsilon_t (L_{t-1}^i - m_i + 1) \mid \varphi\}. \end{aligned} \quad (48)$$

(48) обосновывается следующими свойствами экспоненциально распределенной СВ  $\xi$ :  $\forall a, b \geq 0$

$$\begin{aligned} \mathbf{P}\{\xi \geq a\} &= e^{-a}, \\ \mathbf{P}\{\xi \geq a + b\} &= e^{-b} \mathbf{P}\{\xi \geq a\}. \end{aligned}$$

2) Докажем, что

$$L'_T \leq \min_{i \in I} L_T^i + \frac{\ln N}{\varepsilon_T}. \quad (49)$$

Будем использовать следующие обозначения:

$$\begin{aligned} \vec{l}_t &:= (l_t^1, \dots, l_t^N), \quad \vec{L}_t := (L_t^1, \dots, L_t^N), \\ \vec{\xi} &:= (\xi^1, \dots, \xi^N), \\ \tilde{l}_t &= \vec{l}_t - \vec{\xi} \left( \frac{1}{\varepsilon_t} - \frac{1}{\varepsilon_{t-1}} \right), \quad \tilde{L}_t = \vec{L}_t - \vec{\xi} \frac{1}{\varepsilon_t} \end{aligned} \quad (50)$$

(полагаем  $\varepsilon_0 = 1$ ).

Нетрудно доказать, что  $\tilde{L}_T = \tilde{L}_{T-1} + \tilde{l}_T$ .

Пусть  $E = \{\vec{e}_1, \dots, \vec{e}_N\} \subseteq \mathbb{R}^N$ , где  $\forall i = 1, \dots, N$   $\vec{e}_i$  имеет вид  $(0, \dots, 1, \dots, 0)$  (единица – на  $i$ -м месте).

$\forall \vec{l} = (l^1, \dots, l^N) \in \mathbb{R}$  обозначим

$$M(\vec{l}) = \arg \min_{\vec{e}_i \in E} \langle \vec{e}_i, \vec{l} \rangle,$$

Нетрудно видеть, что

$$\begin{aligned} \langle M(\vec{l}), \vec{l} \rangle &= \min_{i \in I} l^i, \\ \tilde{l}_t^i &= \langle M(\tilde{L}_t), \tilde{l}_t \rangle, \quad L'_T = \mathbf{E} \sum_{t=1}^T \langle M(\tilde{L}_t), \tilde{l}_t \rangle, \\ \langle M(\tilde{L}_{T-1}), \tilde{L}_{T-1} \rangle &\leq \langle M(\tilde{L}_T), \tilde{L}_{T-1} \rangle \end{aligned} \quad (51)$$

(неравенство в третьей строчке (51) следует из того, что его левая часть – минимальная компонента  $\tilde{L}_{T-1}$ , а правая – некоторая компонента  $\tilde{L}_{T-1}$ ).

Индукцией по  $T$  докажем неравенство

$$\sum_{t=1}^T \langle M(\tilde{L}_t), \tilde{l}_t \rangle \leq \langle M(\tilde{L}_T), \tilde{L}_T \rangle. \quad (52)$$

При  $T = 1$  (52) имеет вид  $\langle M(\tilde{l}_1), \tilde{l}_1 \rangle \leq \langle M(\tilde{l}_1), \tilde{l}_1 \rangle$ .

Индуктивный переход (от  $T - 1$  к  $T$ ): используя индуктивное предположение, и учитывая неравенство в третьей строчке (51), получаем:

$$\begin{aligned} &\text{левая часть (52)} \leq \\ &\leq \langle M(\tilde{L}_{T-1}), \tilde{L}_{T-1} \rangle + \langle M(\tilde{L}_T), \tilde{l}_T \rangle \leq \\ &\leq \langle M(\tilde{L}_T), \tilde{L}_{T-1} \rangle + \langle M(\tilde{L}_T), \tilde{l}_T \rangle = \langle M(\tilde{L}_T), \tilde{L}_T \rangle = \\ &= \text{правая часть (52)}. \end{aligned}$$

Используя определение  $\tilde{l}_t$  (см. третью строчку в (50)), неравенство (52) можно переписать так:

$$\begin{aligned} \sum_{t=1}^T \langle M(\tilde{L}_t), \tilde{l}_t \rangle &\leq \\ &\leq \langle M(\tilde{L}_T), \tilde{L}_T \rangle + \sum_{t=1}^T \langle M(\tilde{L}_t), \vec{\xi} \rangle \left( \frac{1}{\varepsilon_t} - \frac{1}{\varepsilon_{t-1}} \right). \end{aligned} \quad (53)$$

Из определения  $\tilde{L}_T$ , следует неравенство

$$\begin{aligned} \langle M(\tilde{L}_T), \tilde{L}_T \rangle &\leq \langle M(\vec{L}_T), \vec{L}_T - \vec{\xi} \frac{1}{\varepsilon_T} \rangle = \\ &= \min_{i \in I} L_T^i - \langle M(\vec{L}_T), \vec{\xi} \rangle \frac{1}{\varepsilon_T}. \end{aligned} \quad (54)$$

Т.к.  $\langle M(\vec{L}_T), \vec{\xi} \rangle = \xi^k$  для некоторого  $k$ , и  $\mathbf{E} \xi^k = 1$ , то

$$\mathbf{E} \langle M(\vec{L}_T), \vec{\xi} \rangle \frac{1}{\varepsilon_T} = \frac{1}{\varepsilon_T} \mathbf{E} \xi^k = \frac{1}{\varepsilon_T}. \quad (55)$$

Оценим второй член в (53):

$$\begin{aligned} & \sum_{t=1}^T \langle M(\tilde{L}_t), \vec{\xi} \rangle \left( \frac{1}{\varepsilon_t} - \frac{1}{\varepsilon_{t-1}} \right) \leq \\ & \leq \sum_{t=1}^T \max_{i \in I} \xi^i \left( \frac{1}{\varepsilon_t} - \frac{1}{\varepsilon_{t-1}} \right) \leq \frac{1}{\varepsilon_T} \max_{i \in I} \xi^i. \end{aligned}$$

Нетрудно доказать, что

$$\mathbf{E} \max_{i=1, \dots, N} \xi^i \leq 1 + \ln N. \quad (56)$$

Действительно, поскольку СВ  $\xi^1, \dots, \xi^N$  независимы, и функция распределения показательного распределённой СВ имеет вид  $1 - e^{-x}$ , то функция распределения СВ  $\max_{i=1, \dots, N} \xi^i$  имеет вид  $(1 - e^{-x})^N$ , поэтому её плотность равна  $N(1 - e^{-x})^{N-1}$ , и следовательно её мат. ожидание равно

$$N \int_0^\infty (1 - e^{-x})^{N-1} e^{-x} x dx. \quad (57)$$

Обозначим (57) записью  $a_N$ . Поскольку

$$\begin{aligned} a_N &= N \int_0^\infty (1 - e^{-x})^{N-1} e^{-x} x dx = \\ &= N \int_0^\infty (1 - e^{-x})(1 - e^{-x})^{N-2} e^{-x} x dx = \\ &= \frac{N}{N-1} a_{N-1} - N \int_0^\infty e^{-x} (1 - e^{-x})^{N-2} e^{-x} x dx = \\ &= \frac{N}{N-1} a_{N-1} - \frac{N}{N-1} \int_0^\infty e^{-x} x d(1 - e^{-x})^{N-1} = \\ & \text{(применяем интегрирование по частям)} \\ &= \frac{N}{N-1} a_{N-1} + \frac{N}{N-1} \int_0^\infty (1 - e^{-x})^{N-1} d e^{-x} x = \\ &= \frac{N}{N-1} a_{N-1} + \frac{N}{N-1} \int_0^\infty (1 - e^{-x})^{N-1} e^{-x} (1 - x) dx = \\ &= \frac{N}{N-1} a_{N-1} + \frac{1}{N-1} (1 - a_N), \end{aligned}$$

откуда получаем:  $a_N = a_{N-1} + \frac{1}{N}$ , следовательно

$$\mathbf{E} \max_{i=1, \dots, N} \xi^i = a_N = 1 + \frac{1}{2} + \dots + \frac{1}{N}, \quad (58)$$

откуда следует (56), поэтому

$$\begin{aligned} & \mathbf{E} \sum_{t=1}^T \langle M(\tilde{L}_t), \vec{\xi} \rangle \left( \frac{1}{\varepsilon_t} - \frac{1}{\varepsilon_{t-1}} \right) \leq \\ & \leq \frac{\mathbf{E} \max_{i=1, \dots, N} \xi^i}{\varepsilon_T} \leq \frac{1 + \ln N}{\varepsilon_T} \end{aligned} \quad (59)$$

Таким образом, согласно второй строчке в (51), а также (53), (54), (55) и (59)

$$L'_T = \mathbf{E} \sum_{t=1}^T \langle M(\tilde{L}_t), \vec{l}_t \rangle \leq \min_{i \in I} L_T^i - \frac{1}{\varepsilon_T} + \frac{1 + \ln N}{\varepsilon_T}$$

откуда следует (49). ■

## 8. Агрегирующий алгоритм В.Г.Вовка

В этом пункте описывается агрегирующий алгоритм В.Г.Вовка, существенной особенностью которого является зависимость регрета  $R_T = L_T - \min_{i \in I} L_T^i$  только от количества экспертов  $N$  и независимость регрета от величины периода наблюдения  $T$ . Данный алгоритм был впервые описан в [8].

### 8.1. Смешиваемые функции потерь

Напомним некоторые введённые ранее понятия и обозначения:

- $Y = \{0, 1\}$  – множество **исходов**,
- $\Gamma = [0, 1]$ , или  $[-1, 1]$ , или  $Y^\Delta$  – множество **прогнозов**,
- $\eta > 0$  – **параметр обучения**,  $\beta = e^{-\eta}$ ,
- $\lambda : Y \times \Gamma \rightarrow \mathbb{R}_{\geq 0}$  – **функция потерь (ФП)**, она предполагается непрерывной по второму аргументу,
- $I = 1, \dots, N$  – множество **экспертов**,
- $\forall t \geq 1, \forall i \in I$ 
  - $\gamma_t^i$  – **прогноз** эксперта  $i$  на шаге  $t$ ,
  - $y_t$  – **исход** на шаге  $t$ ,
  - $l_t^i = \lambda(\gamma_t^i, y_t)$  – **потери** эксперта  $i$  на шаге  $t$ ,
  - $L_t^i = \sum_{t'=1}^t l_{t'}^i$  – **кумулятивные потери** эксперта  $i$  на шаге  $t$ ,
  - $m_t = \log_\beta \sum_{i \in I} \beta^{L_t^i} p_{t-1}^i$  – **средние потери** на шаге  $t$ ,
  - $M_t = \sum_{t'=1}^t m_{t'}$  – **кумулятивные средние потери**.

**Алгоритм обучения:** это построение последовательностей  $\vec{w}_0, \vec{w}_1, \dots$  и  $\vec{p}_0, \vec{p}_1, \dots$  векторов из  $\mathbb{R}^I$ , где

- $\vec{w}_0 = \vec{p}_0 \in I^\Delta$ ,
- $\forall t \geq 1, \forall i \in I$   $w_t^i = \beta^{L_t^i} w_{t-1}^i = \beta^{L_t^i} p_0^i$ ,
- $\forall t \geq 1$   $\vec{p}_t = \text{norm}(\vec{w}_t) \in I^\Delta$ .

Отметим, что  $M_t = \log_\beta \sum_{i \in I} \beta^{L_t^i} p_0^i$ . Действительно,

$$\begin{aligned}
 m_t &= \log_\beta \sum_{i \in I} \beta^{L_t^i} p_{t-1}^i = \log_\beta \sum_{i \in I} \beta^{L_t^i} \frac{w_{t-1}^i}{\sum_{j \in I} w_{t-1}^j} = \\
 &= \log_\beta \frac{\sum_{i \in I} \beta^{L_t^i} w_{t-1}^i}{\sum_{j \in I} w_{t-1}^j} = \log_\beta \frac{\sum_{i \in I} \beta^{L_t^i} p_0^i}{\sum_{j \in I} \beta^{L_{t-1}^j} p_0^j} = \\
 &= \log_\beta \sum_{i \in I} \beta^{L_t^i} p_0^i - \log_\beta \sum_{i \in I} \beta^{L_{t-1}^i} p_0^i
 \end{aligned}$$

откуда непосредственно следует доказываемое равенство.

Примеры ФП:

$$\lambda(\gamma, y) = \begin{cases} c(y - \gamma)^2 & (\text{квадратичная, } c - \text{константа}), \\ c|y - \gamma| & (\text{абсолютная, } c - \text{константа}), \\ \llbracket y \neq \gamma \rrbracket & (\text{простая}), \\ -\ln \gamma(y) & (\text{логарифмическая, } \Gamma = Y^\Delta). \end{cases}$$

В последнем случае можно отождествить распределение

$$\gamma = (\gamma(1), \gamma(0)) \in Y^\Delta$$

с числом  $\gamma(1) \in [0, 1]$ , которое будем обозначать тем же символом  $\gamma$ , и значение  $\lambda(\gamma, y)$  в данном случае можно записать в виде  $-\ln |1 - y - \gamma|$ .

ФП  $\lambda$  называется **смешиваемой ФП (СФП)**, если

$$\mathcal{U}_\lambda = \bigcup_{\gamma \in \Gamma} [0, \beta^{\lambda(\gamma, 0)}] \times [0, \beta^{\lambda(\gamma, 1)}] \quad (60)$$

является выпуклым подмножеством  $\mathbb{R}^2$  (это будет, например, когда ФП  $\lambda$  – квадратичная или логарифмическая).

В настоящей статье рассматривается задача вычисления прогнозов в том случае, когда ФП  $\lambda$  является СФП.

### Теорема 6.

Если  $\lambda$  – СФП, то  $\forall t \geq 1 \exists \gamma_t^* \in \Gamma : \forall y \in Y$

$$\lambda(\gamma_t^*, y) \leq m_t. \quad (61)$$

### Доказательство.

Совокупность точек

$$\{(\beta^{\lambda(\gamma_i^i, 0)}, \beta^{\lambda(\gamma_i^i, 1)}) \mid i \in I\} \quad (62)$$

принадлежит выпуклому множеству  $\mathcal{U}_\lambda$ .

Согласно определению,  $m_t$  – выпуклая комбинация вида

$$m_t = \log_\beta \sum_{i \in I} \beta^{\lambda(\gamma_i^i, y)} p_{t-1}^i.$$

Т.к.  $\mathcal{U}_\lambda$  выпукло, то выпуклая комбинация

$$\sum_{i \in I} (\beta^{\lambda(\gamma_i^i, 0)}, \beta^{\lambda(\gamma_i^i, 1)}) p_{t-1}^i \quad (63)$$

точек из множества (62) тоже принадлежит  $\mathcal{U}_\lambda$ .

Построим луч с началом в  $0 = (0, 0)$ , проходящий через точку (63). Этот луч пересекает границу

$$\{(\beta^{\lambda(\gamma, 0)}, \beta^{\lambda(\gamma, 1)}) \mid \gamma \in \Gamma\}$$

множества  $\mathcal{U}_\lambda$  в некоторой точке

$$u = (\beta^{\lambda(\gamma_t^*, 0)}, \beta^{\lambda(\gamma_t^*, 1)}). \quad (64)$$

Поскольку точка (63) принадлежит отрезку  $[0, u]$ , то её абсцисса и ордината не превосходят абсциссы и ординаты соответственно точки  $u$ , т.е.

$$\begin{aligned} \sum_{i \in I} \beta^{\lambda(\gamma_t^i, 0)} p_{t-1}^i &\leq \beta^{\lambda(\gamma_t^*, 0)}, \\ \sum_{i \in I} \beta^{\lambda(\gamma_t^i, 1)} p_{t-1}^i &\leq \beta^{\lambda(\gamma_t^*, 1)}, \end{aligned}$$

т.е. верно утверждение

$$\forall y \in Y \quad \sum_{i \in I} \beta^{\lambda(\gamma_t^i, y)} p_{t-1}^i \leq \beta^{\lambda(\gamma_t^*, y)}. \quad (65)$$

Логарифмируя неравенство в (65), получаем (61). ■

$L_T^{AA}$  обозначает кумулятивную потерю  $\sum_{t=1}^T \lambda(\gamma_t^*, y_t)$ , где  $\gamma_t^*$  – прогнозы, определяемые в доказательстве теоремы 6 (AA является аббревиатурой словосочетания «агрегирующий алгоритм»). Из теоремы 6 следует неравенство

$$L_T^{AA} \leq M_T.$$

Отметим, что если  $\vec{p}_0$  – р.р., то  $\forall i \in I$

$$L_t^{AA} \leq M_t = \log_\beta(\sum_{i \in I} \beta^{L_t^i} \frac{1}{N}) \leq \log_\beta(\beta^{L_t^i} \frac{1}{N}),$$

поэтому

$$L_T^{AA} \leq \min_{i \in I} L_T^i + \frac{\ln N}{\eta}. \quad (66)$$

## 8.2. Смешиваемость квадратичной функции потерь

Будем считать, что  $\Gamma = [-1, 1]$ ,  $Y = \{-1, 1\}$  (м.б. и  $[-1, 1]$ ). В этом случае  $\mathcal{U}_\lambda$  имеет вид

$$\bigcup_{\gamma \in \Gamma} [0, \beta^{\lambda(\gamma, -1)}] \times [0, \beta^{\lambda(\gamma, 1)}]$$

### Лемма 2.

ФП  $\lambda(\gamma, y) = (y - \gamma)^2$  является  $\eta$ -смешиваемой тогда и только тогда, когда  $\eta \leq \frac{1}{2}$ .

### Доказательство.

Нетрудно доказать, что множество  $\mathcal{U}_\lambda$  выпукло тогда и только тогда, когда его граница – кривая

$$\begin{aligned} \hat{\mathcal{U}}_\lambda &\stackrel{\text{def}}{=} \{(\beta^{\lambda(\gamma, -1)}, \beta^{\lambda(\gamma, 1)}) \mid \gamma \in [-1, 1]\} = \\ &= \{(e^{-\eta(-1-\gamma)^2}, e^{-\eta(1-\gamma)^2}) \mid \gamma \in [-1, 1]\} \end{aligned} \quad (67)$$

обладает следующим свойством: при увеличении  $\gamma$  от  $-1$  до  $1$  абсцисса соответствующей точки кривой уменьшается и кривая поворачивает налево, что эквивалентно свойству

$$\forall \gamma \in [-1, 1] \quad \begin{cases} \gamma_x < 0, \\ y_{xx} = \gamma_x \frac{x_\gamma y_{\gamma\gamma} - x_{\gamma\gamma} y_\gamma}{x_\gamma^2} \leq 0. \end{cases} \quad (68)$$

Из первого неравенства в (68) следует, что второе неравенство в (68) равносильно неравенству

$$x_\gamma y_{\gamma\gamma} \geq x_{\gamma\gamma} y_\gamma. \quad (69)$$

Нетрудно видеть, что

$$\begin{aligned} x_\gamma &= -2\eta(1 + \gamma)e^{-\eta(1+\gamma)^2} \\ x_{\gamma\gamma} &= 2\eta(-1 + 2\eta(1 + \gamma)^2)e^{-\eta(1+\gamma)^2} \\ y_\gamma &= 2\eta(1 - \gamma)e^{-\eta(1-\gamma)^2} \\ y_{\gamma\gamma} &= 2\eta(-1 + 2\eta(1 - \gamma)^2)e^{-\eta(1-\gamma)^2} \end{aligned}$$

откуда следует, что (69) можно переписать в виде

$$-(1 + \gamma)(-1 + 2\eta(1 - \gamma)^2) \geq (1 - \gamma)(-1 + 2\eta(1 + \gamma)^2).$$

Последнее неравенство эквивалентно утверждению

$$\eta(1 - \gamma^2) \leq \frac{1}{2},$$

которое должно быть верным для каждого  $\gamma \in [-1, 1]$ , что равносильно неравенству  $\eta \leq \frac{1}{2}$ . ■

Рассмотрим задачу вычисления оптимального прогноза  $\gamma_t^*$  для квадратичной ФП в случае  $\eta = \frac{1}{2}$ .

Точка (63) в данном случае имеет вид  $(A, B)$ , где

$$A = \sum_i \beta^{\lambda(\gamma_t^i, -1)} p_{t-1}^i, \quad B = \sum_i \beta^{\lambda(\gamma_t^i, 1)} p_{t-1}^i,$$

и точка (64) ищется из уравнения

$$\frac{B}{A} = \frac{\beta^{\lambda(\gamma_t^*, 1)}}{\beta^{\lambda(\gamma_t^*, -1)}} = \beta^{(1-\gamma_t^*)^2 - (-1-\gamma_t^*)^2} = \beta^{-4\gamma_t^*}.$$

Поэтому  $\gamma_t^* = \frac{1}{4} \log_\beta \frac{A}{B}$ .

### 8.3. Супермартингалы

#### 8.3.1. Понятие супермартингала

Пусть  $Y = \{0, 1\}$ ,  $\Gamma = [0, 1]$ . Ниже запись  $u_n$  обозначает произвольную последовательность из  $(\Gamma \times Y)^n$  ( $n \geq 0$ ):

$$u_n = ((\gamma_1, y_1), \dots, (\gamma_n, y_n)).$$

Последовательность  $u_0$  пуста и обозначается  $\varepsilon$ .

**Супермартингал (СМ)** – это семейство функций

$$Q = \{Q_n : (\Gamma \times Y)^n \rightarrow \mathbb{R}_{\geq 0} \mid n \geq 0\} \quad (70)$$

таких, что

- $Q_0(\varepsilon) \leq 1$ ,
- $\forall n \geq 0, \forall u_n \in (\Gamma \times Y)^n, \forall y \in Y$  функция

$$Q_{n+1}(u_n, (\cdot, y)) : \Gamma \rightarrow \mathbb{R}_{\geq 0}$$

непрерывна, и верно свойство

$$\forall \gamma \in \Gamma \quad \gamma Q_{n+1}(u_n, (\gamma, 1)) + (1 - \gamma) Q_{n+1}(u_n, (\gamma, 0)) \leq Q_n(u_n). \quad (71)$$

#### Теорема 7.

Пусть задан СМ  $Q$  вида (70).

Тогда  $\forall n \geq 0, \forall u_n \in (\Gamma \times Y)^n \exists \gamma^*$ :

$$\forall y \in Y \quad Q_n(u_n) \geq Q_{n+1}(u_n, (\gamma^*, y)). \quad (72)$$

#### Доказательство.

Определим функцию  $f_{u_n} : \Gamma \times Y \rightarrow \mathbb{R}_{\geq 0}$ :

$$f_{u_n}(\gamma, y) = Q_{n+1}(u_n, (\gamma, y)) - Q_n(u_n).$$

$f_{u_n}$  непрерывна по  $\gamma$ , и из (71) следует, что

$$\forall \gamma \in \Gamma \quad \gamma f_{u_n}(\gamma, 1) + (1 - \gamma) f_{u_n}(\gamma, 0) \leq 0 \quad (73)$$

поэтому  $f_{u_n}(1, 1) \leq 0$  и  $f_{u_n}(0, 0) \leq 0$ .

Докажем, что

$$\exists \gamma^* : f_{u_n}(\gamma^*, 0) \leq 0 \text{ и } f_{u_n}(\gamma^*, 1) \leq 0. \quad (74)$$

Отметим, что из (74) следует (72).

- Если  $f_{u_n}(1, 0) \leq 0$ , то  $\gamma^* = 1$ , и если  $f_{u_n}(0, 1) \leq 0$ , то  $\gamma^* = 0$ ,
- иначе  $f_{u_n}(1, 0) > 0$  и  $f_{u_n}(0, 1) > 0$ , в этом случае рассмотрим непрерывную функцию

$$f(\gamma) = f_{u_n}(\gamma, 1) - f_{u_n}(\gamma, 0).$$

Поскольку  $f(0) > 0$ ,  $f(1) < 0$ , и  $f$  непрерывна, то

$$\exists \gamma^* \in (0, 1) : f(\gamma^*) = 0,$$

т.е.  $f_{u_n}(\gamma^*, 1) = f_{u_n}(\gamma^*, 0)$ . По (73), отсюда следует (74). ■

### 8.3.2. Пример супермартингала

Определим  $\forall i \in I = \{1, \dots, N\}$

$$R_n^i(u_n) = \sum_{t=1}^n (\lambda(\gamma_t, y_t) - \lambda(\gamma_t^i, y_t)).$$

В некоторых случаях  $Q_n^i(u_n) = e^{\eta R_n^i} = e^{\eta(L_n - L_n^i)}$  будет СМ. Неравенство в (71) равносильно неравенству

$$\gamma e^{\eta(\lambda(\gamma, 1) - \lambda(\gamma_{n+1}^i, 1))} + (1 - \gamma) e^{\eta(\lambda(\gamma, 0) - \lambda(\gamma_{n+1}^i, 0))} \leq 1 \quad (75)$$

1) Если  $\lambda(\gamma, y) = -\ln|1 - y - \gamma|$ , то (75) имеет вид

$$\gamma e^{\eta(-\ln \gamma + \ln \gamma_{n+1}^i)} + (1 - \gamma) e^{\eta(-\ln(1-\gamma) + \ln(1-\gamma_{n+1}^i))} \leq 1 \quad (76)$$

что равносильно неравенству

$$\gamma^{1-\eta} (\gamma_{n+1}^i)^\eta + (1 - \gamma)^{1-\eta} (1 - \gamma_{n+1}^i)^\eta \leq 1. \quad (77)$$

Если  $\eta = \frac{1}{2}$ , то (77) следует из неравенства Коши-Буняковского для векторов

$$(\gamma^{1-\eta}, (1 - \gamma)^{1-\eta}), \quad ((\gamma_{n+1}^i)^\eta, (1 - \gamma_{n+1}^i)^\eta).$$

Левая часть (77) – скалярное произведение этих векторов, а их норма в случае  $\eta = \frac{1}{2}$  равна 1.

2)  $\lambda(\gamma, y) = (y - \gamma)^2 : y \in \{0, 1\}, \gamma \in [0, 1], \eta \in (0, 2]$ .

В этом случае (75) равносильно неравенству

$$\gamma e^{\eta((\gamma-1)^2 - (1-\gamma_{n+1}^i)^2)} + (1 - \gamma) e^{\eta(\gamma^2 - (\gamma_{n+1}^i)^2)} \leq 1. \quad (78)$$

Представим  $\gamma_{n+1}^i$  в виде  $\gamma + x$  и перепишем (78) в виде

$$\gamma e^{2\eta(1-\gamma)x} + (1-\gamma)e^{-2\eta\gamma x} \leq e^{\eta x^2} \quad (79)$$

(79) вытекает из следующего утверждения: если значения СВ  $\xi$  лежат в отрезке  $[a, b]$ , то  $\forall s \in \mathbb{R}$

$$\ln \mathbf{E}e^{s\xi} \leq s\mathbf{E}\xi + \frac{s^2(b-a)^2}{8}. \quad (80)$$

Если СВ  $\xi$  принимает значение 1 с вероятностью  $\gamma$  и значение 0 с вероятностью  $1-\gamma$ , то полагая  $a=0$ ,  $b=1$  получаем: (80) имеет вид

$$\gamma e^{s(1-\gamma)} + (1-\gamma)e^{-s\gamma} \leq e^{s^2/8}.$$

Если  $s := 2\eta x$ , то Л.Ч. (79)  $\leq e^{\eta^2 x^2/2} \leq$  Пр.Ч. (79), ибо  $\eta \leq 2$ .

### 8.3.3. Применение теоремы 7

Пусть  $Y = \{0, 1\}$ ,  $\Gamma = [0, 1]$ , ФП  $\lambda(\gamma, y)$  –  $\eta$ -смешиваемая,  $w_0 \in I^\Delta$ , где  $I = \{1, \dots, N\}$ , построены прогнозы  $\gamma_1, \dots, \gamma_{T-1}$  и имеются прогнозы экспертов  $\gamma_1^i, \dots, \gamma_T^i$  ( $i \in I$ ).

(66) будет выполнено, если  $\forall t$  верно (65), что равносильно следующему:  $\forall y \in \{0, 1\}$  верно неравенство

$$\sum_{i \in I} w_{t-1}^i \geq \sum_{i \in I} w_{t-1}^i e^{-\eta(\lambda(\gamma_t^i, y) - \lambda(\gamma_t, y))}$$

которое эквивалентно неравенству

$$\sum_{i \in I} p_0^i e^{-\eta L_{t-1}^i} \geq \sum_{i \in I} p_0^i e^{-\eta L_{t-1}^i} e^{\eta(\lambda(\gamma_t, y) - \lambda(\gamma_t^i, y))},$$

после домножения обеих частей которого на  $e^{\eta L_{t-1}}$  получаем

$$\sum_{i \in I} p_0^i Q_{t-1}^i \geq \sum_{i \in I} p_0^i Q_{t-1}^i e^{\eta(\lambda(\gamma_t, y) - \lambda(\gamma_t^i, y))} = \sum_{i \in I} p_0^i Q_t^i(y).$$

Таким образом утверждение (65) равносильно тому, что последовательность  $\{\sum_{i \in I} p_0^i Q_t^i \mid t \geq 1\}$  не возрастает с ростом  $t$ .

Нетрудно доказать, что семейство функций

$$\{\sum_{i \in I} p_0^i Q_n^i \mid n \geq 1\}$$

тоже является СМ, и поэтому для него верна теорема 7, т.е.  $\forall t > 0$ ,  $\forall u \in (\Gamma \times Y)^{t-1} \exists \gamma_t : \forall y \in Y$

$$\sum_{i \in I} p_0^i Q_t^i(u, (\gamma_t, y)) \leq \sum_{i \in I} p_0^i Q_{t-1}^i(u) \leq 1. \quad (81)$$

$\forall t \geq 1$  из свойства

$$\sum_{i \in I} p_0^i Q_t^i = \sum_{i \in I} p_0^i e^{\eta(L_t - L_t^i)} \leq 1$$

следует, что  $\forall i \in I$   $p_0^i e^{\eta(L_t - L_t^i)} \leq 1$ , откуда следует (66), если  $p_0^i = 1/N$ .

## 9. Прогнозные стратегии

В этом пункте рассматривается задача прогнозирования временного ряда в ситуации, когда эксперты отсутствуют. Для определения качества алгоритма прогнозирования в данном случае используется понятие калибруемости алгоритма, впервые введённое в [10]. Излагаемый в данном пункте вероятностный алгоритм вычисления калибруемых прогнозов впервые был описан в [11], см. также [9] и [6].

### 9.1. Понятие прогнозной стратегии

Пусть множество исходов  $Y$  имеет вид  $\{0, 1\}$ . Будем обозначать произвольную последовательность из  $Y^n = \underbrace{Y \times \dots \times Y}_n$  записью  $y^n$ , и последний элемент последовательности  $y^n$  — записью  $y_n$ . Обозначим записью  $Y^*$  множество  $\bigcup_{n \geq 0} Y^n$ , где  $Y^0$  состоит из пустой последовательности  $y^0$  (которая обозначается  $\varepsilon$ ). Символом  $y$  будем обозначать неограниченную последовательность элементов множества  $Y$ , и если  $y$  — такая последовательность, то  $\forall n \geq 1$  записи  $y^n$  и  $y_n$  обозначают префикс последовательности  $y$  длины  $n$  и  $n$ -й элемент  $y$  соответственно.

**Прогнозная стратегия (ПС)** — это функция

$$f : Y^* \rightarrow [0, 1], \text{ где } f(\varepsilon) = 1 \text{ и } \forall n \geq 0, \forall y^n \in Y^n \\ f(y^n) = \mathbf{P}\{y^n = \text{последовательность первых } n \text{ исходов}\}$$

Для каждой ПС  $f$  и  $\forall n \geq 0$  верно равенство

$$\sum_{y^n \in Y^n} f(y^n) = 1.$$

Будем обозначать  $f(y_n | y^{n-1}) = \frac{f(y^n)}{f(y^{n-1})}$ .

Пусть  $\mathcal{F}$  — некоторый класс ПС.  $\forall y \in Y^*$  будем обозначать записью  $\mathcal{F}(y)$  число  $\sum_{\varphi \in \mathcal{F}} \varphi(y)$ .

Ниже будем опускать « $\in \mathcal{F}$ » в  $\sum_{\varphi \in \mathcal{F}}, \sup_{\varphi \in \mathcal{F}}, \inf_{\varphi \in \mathcal{F}}$ .

**Потери** ПС  $f$  определяются следующим образом:  $\forall n \geq 1$

$$l_n^f(y) = -\ln f(y_n | y^{n-1}), \\ L_n^f(y) = \sum_{i=1}^n l_i^f(y) = -\sum_{i=1}^n \ln f(y_i | y^{i-1}) = -\ln f(y^n).$$

**Регрет** ПС  $f$  относительно класса ПС  $\mathcal{F}$ :

$$R_n^f(y) = L_n^f(y) - \inf_{\varphi} L_n^\varphi(y) = \sup_{\varphi} \ln \frac{\varphi(y^n)}{f(y^n)} = \ln \frac{\sup_{\varphi} \varphi(y^n)}{f(y^n)} \\ R_n(y) = \inf_{\varphi} R_n^\varphi(y).$$

## 9.2. Примеры прогнозных стратегий

### 9.2.1. Смешивающая и минимаксная прогнозные стратегии

Пусть задан конечный класс  $\mathcal{F}$  ПС. **Смешивающая ПС** для класса  $\mathcal{F}$  определяется следующим образом:

$$f(y^n) = \frac{1}{|\mathcal{F}|} \mathcal{F}(y^n).$$

Нетрудно видеть, что

$$\begin{aligned} R_n^f(y) &= \sup_{\varphi} \ln \frac{\varphi(y^n)}{f(y^n)} = \sup_{\varphi} \ln \frac{\varphi(y^n)}{\frac{1}{|\mathcal{F}|} \mathcal{F}(y^n)} = \\ &= \ln |\mathcal{F}| + \sup_{\varphi} \ln \frac{\varphi(y^n)}{\mathcal{F}(y^n)} \leq \ln |\mathcal{F}|. \end{aligned}$$

**Минимаксная ПС** для класса  $\mathcal{F}$  определяется следующим образом:

$$f(y^n) = \frac{\sup_{\varphi} \varphi(y^n)}{\sum_{u^n \in Y^n} \sup_{\varphi} \varphi(u^n)}.$$

Ниже будем опускать « $\in Y^n$ » в записях  $\sum_{u^n \in Y^n}$ .

**Минимаксный регрет** определяется следующим образом:

$$\begin{aligned} V_n^f &= \sup_{y^n} R_n^f(y) = \sup_{y^n} \ln \frac{\sup_{\varphi} \varphi(y^n)}{f(y^n)} \\ V_n &= \inf_{\varphi \in \mathcal{F}} V_n^{\varphi}. \end{aligned}$$

Нетрудно видеть, что

$$\begin{aligned} R_n^f(y) &= \ln \frac{\sup_{\varphi} \varphi(y^n)}{f(y^n)} = \ln \frac{\sup_{\varphi} \varphi(y^n)}{\frac{\sup_{\varphi} \varphi(y^n)}{\sum_{u^n} \sup_{\varphi} \varphi(u^n)}} = \\ &= \ln \sum_{u^n} \sup_{\varphi} \varphi(u^n). \end{aligned} \tag{82}$$

Отметим, что правая часть (82) не зависит от  $y$  и  $f$ , поэтому можно обозначить её  $R_n$  или  $V_n$ .

ПС  $f$  называется **оптимальной**, если  $\forall n \geq 0 V_n^f = V_n$ .

Докажем оптимальность минимаксной ПС  $f$ , т.е. следующее свойство: для каждой ПС  $f' \neq f V_n^{f'} \geq V_n$ :

- если  $\forall y^n \in Y^n f'(y^n) = f(y^n)$ , то

$$V_n^{f'} = \sup_{y^n} \ln \frac{\sup_{\varphi} \varphi(y^n)}{f'(y^n)} = \sup_{y^n} \ln \frac{\sup_{\varphi} \varphi(y^n)}{f(y^n)} = V_n^f,$$

- иначе, если  $\exists y^n \in Y^n : f'(y^n) \neq f(y^n)$ , то, поскольку

$$\sum_{y^n} f'(y^n) = \sum_{y^n} f(y^n) = 1,$$

то  $\exists y^n : f'(y^n) < f(y^n)$ , поэтому

$$R_n^{f'}(y) = \ln \frac{\sup_{\varphi} \varphi(y^n)}{f'(y^n)} > \ln \frac{\sup_{\varphi} \varphi(y^n)}{f(y^n)} = V_n,$$

откуда следует:  $V_n^{f'} = \sup_{y^n} R_n^{f'}(y) > V_n$ . ■

Отметим, что

$$\begin{aligned} V_n &= \ln \sum_{u^n} \sup_{\varphi} \varphi(u^n) \leq \ln \sum_{u^n} \sum_{\varphi} \varphi(u^n) = \\ &= \ln \sum_{\varphi} \sum_{u^n} \varphi(u^n) = \ln \sum_{\varphi} 1 \leq \ln |\mathcal{F}|. \end{aligned}$$

### 9.2.2. Прогнозная стратегия Лапласа

**ПС Лапласа**, применяется в ситуации, когда  $\forall n \geq 1$   $y_n$  генерируется независимо, и  $\forall n \geq 1$   $\mathbf{P}\{y_n = 1\}$  равно одному и тому же числу  $p$ .

Ниже  $\forall n \geq 0$  и  $\forall y^n \in Y^n$   $n_1$  и  $n_2$  обозначают число единиц и нулей соответственно в последовательности  $y^n$ .

Нетрудно доказать, что вероятность того, что  $y^n$  является последовательностью первых  $n$  исходов, равна  $p^{n_1}(1-p)^{n_2}$ .

Определим класс ПС  $\mathcal{F}$  как класс функций, каждая из которых соответствует некоторому числу  $p \in [0, 1]$  и сопоставляет последовательности  $y^n \in Y^n$  вероятность  $p^{n_1}(1-p)^{n_2}$  того, что  $y^n$  – последовательность первых  $n$  исходов.

**ПС Лапласа**  $f$  имеет следующий вид:

$$f(y^n) \stackrel{\text{def}}{=} \int_0^1 p^{n_1}(1-p)^{n_2} dp, \quad (83)$$

т.е.  $f(y^n)$  равно мат. ожиданию вероятности того, что  $y^n$  является последовательностью первых  $n$  исходов. Нетрудно доказать, что данное значение равно  $\frac{1}{(n+1)C_n^{n_1}}$ . Это доказывается обратной индукцией по  $n_1$ :

- для  $n_1 = n$  имеем  $\int_0^1 p^n dp = \frac{1}{n+1}$ , что верно, и
- если верно

$$\int_0^1 p^{n_1+1}(1-p)^{n_2-1} dp = \frac{1}{(n+1)C_n^{n_1+1}} =: A$$

то, интегрируя по частям, получаем:

$$\int_0^1 p^{n_1}(1-p)^{n_2} dp = \frac{n-n_1}{n_1+1} A = \frac{1}{(n+1)C_n^{n_1}}.$$

Нетрудно видеть, что

$$\begin{aligned} f(y_{n+1} = 1 | y^n) &= \frac{f(y^{n+1})}{f(y^n)} = \frac{1}{(n+2)C_{n+1}^{n_1+1}} / \frac{1}{(n+1)C_n^{n_1}} = \frac{n_1+1}{n+2}, \\ f(y_{n+1} = 0 | y^n) &= \frac{n_2+1}{n+2}. \end{aligned}$$

$$\forall y \quad R_n^f(y) = \ln \frac{\sup_{0 \leq p \leq 1} p^{n_1}(1-p)^{n_2}}{\int_0^1 p^{n_1}(1-p)^{n_2} dp} = \ln \frac{\binom{n_1}{n}^{n_1} \binom{n_2}{n}^{n_2}}{\frac{1}{(n+1)C_n^{n_1}}} \leq \ln(n+1).$$

Для оптимальной ПС оценка  $V_n$  имеет следующий вид:

$$V_n = \frac{1}{2} \ln n + \frac{1}{2} \ln \frac{\pi}{2} + \varepsilon_n \quad (\text{где } \varepsilon_n \rightarrow 0). \quad (84)$$

Действительно,

$$\begin{aligned}
 V_n &= \ln \sum_{u^n} \sup_{\varphi} \varphi(u^n) = \\
 &= \ln \sum_{u^n} \sup_{0 \leq p \leq 1} p^{n_1} (1-p)^{n_2} = \\
 &= \ln \sum_{u^n} \binom{n_1}{n}^{n_1} \binom{n_2}{n}^{n_2} = \\
 &= \ln \sum_{n_1=0}^n C_n^{n_1} \binom{n_1}{n}^{n_1} \binom{n_2}{n}^{n_2}.
 \end{aligned} \tag{85}$$

Из формулы Стирлинга

$$\sqrt{2\pi n} \left(\frac{n}{e}\right)^n e^{\frac{1}{12n}} \leq n! \leq \sqrt{2\pi n} \left(\frac{n}{e}\right)^n e^{\frac{1}{12n+\varepsilon}}$$

(где  $\varepsilon \in (0, 1)$  – некоторая константа) следует неравенство

$$\frac{1}{\sqrt{2\pi}} \sqrt{\frac{n}{n_1 n_2}} e^{\frac{1}{12n}} \leq C_n^{n_1} \binom{n_1}{n}^{n_1} \binom{n_2}{n}^{n_2} \leq \frac{1}{\sqrt{2\pi}} \sqrt{\frac{n}{n_1 n_2}} e^{\frac{1}{12n+1}}$$

из которого, учитывая (85), получаем верхнюю оценку

$$V_n \leq \ln \left( (1 + o(1)) \sqrt{\frac{n}{2\pi}} e^{\frac{1}{12n+1}} \sum_{n_1=1}^{n-1} \frac{1}{\sqrt{n_1 n_2}} \right)$$

Однако

$$\sum_{n_1=1}^{n-1} \frac{1}{\sqrt{n_1 n_2}} = \sum_{n_1=1}^{n-1} \frac{1}{n} \frac{1}{\sqrt{\frac{n_1}{n} (1 - \frac{n_1}{n})}} \approx \int_0^1 \frac{dx}{\sqrt{x(1-x)}} = \pi,$$

поэтому  $V_n \leq \ln((1 + o(1)) \sqrt{\frac{n\pi}{2}}) =$  правая часть (84).

Нижняя оценка для  $n$  устанавливается аналогично. ■

Из (84) следует, что для оптимальной ПС  $f$ , т.е. такой ПС  $f$ , что  $V_n = V_n^f$ , будет выполнено свойство

$$\forall y L_n^f(y) - \inf_{\varphi} L_n^{\varphi}(y) \leq \text{Пр.Ч. (84)},$$

или:  $\forall y, \forall \varphi \in \mathcal{F} L_n^f(y) \leq L_n^{\varphi}(y) + \text{Пр.Ч. (84)}$ .

### 9.3. Детерминированное прогнозирование

В этом и следующем пунктах мы рассмотрим задачу прогнозирования временного ряда в условиях, когда эксперты отсутствуют. Мы рассмотрим детерминированный и вероятностный алгоритмы прогнозирования.

Ниже используется следующее обозначение: если  $a$  – некоторый объект, и  $m$  – сообщение, то запись  $a!m$  обозначает действие, которое заключается в том, что объект  $a$  посылает в окружающую среду сообщение  $m$ .

**Алгоритм детерминированного прогнозирования (АДП)** заключается в выполнении следующих действий:

$$\forall n \geq 1 \begin{cases} \text{прогнозист ! } \gamma_n \in [0, 1] \\ \text{природа ! } y_n \in [0, 1] \end{cases}$$

Будем говорить, что АДП **калибруется**, если для каждой последовательности исходов  $(y_1, y_2, \dots)$  и каждого связного подмножества  $I \subseteq [0, 1]$  последовательность прогнозов  $(\gamma_1, \gamma_2, \dots)$  обладает следующим свойством:

$$\frac{\sum_{i=1}^n \mathbb{I}[\gamma_i \in I](y_i - \gamma_i)}{\sum_{i=1}^n \mathbb{I}[\gamma_i \in I]} \rightarrow 0 \text{ при } \sum_{i=1}^n \mathbb{I}[\gamma_i \in I] \rightarrow \infty. \quad (86)$$

АДП не калибруется, для обоснования этого определим

$$I_1 = [0, \frac{1}{2}], \quad I_2 = [\frac{1}{2}, 1], \quad \forall n \geq 1 \quad y_n = \mathbb{I}[\gamma_n < \frac{1}{2}]$$

откуда следует, что  $\forall n \geq 1 \quad |y_n - \gamma_n| \geq \frac{1}{2}$ .

Нетрудно установить, что (86) нарушается когда  $I = I_1$  или  $I = I_2$ . Действительно, в один из отрезков  $I_1, I_2$  попадает бесконечное число точек  $\gamma_i$ , и свойство  $\sum_{i=1}^n \mathbb{I}[\gamma_i \in I] \rightarrow \infty$  для этого отрезка верно, однако модуль дроби в (86) больше или равен  $\frac{1}{2}$ .

## 9.4. Вероятностное прогнозирование

**Алгоритм вероятностного прогнозирования (АВП)** имеет следующий вид:

$$\forall n \geq 1 \quad \left\{ \begin{array}{l} \text{прогнозист ! } p_n \in [0, 1]^\Delta \\ \text{природа ! } y_n \in \{0, 1\} \\ \text{ГСЧ ! } \gamma_n \sim p_n \end{array} \right. \quad (87)$$

где ГСЧ – генератор случайных чисел, третье действие в (87) заключается в случайном порождении значения  $\gamma_n \in [0, 1]$  в соответствии с распределением  $p_n$ .

Свойство **калибруемости** АВП имеет следующий вид:

- для каждого  $\delta > 0$ , и
- для каждой последовательности исходов  $(y_1, y_2, \dots)$

последовательность прогнозов  $(\gamma_1, \gamma_2, \dots)$ , которую порождает АВП, удовлетворяет условию:  $\forall I \subseteq [0, 1]$

$$\models \left( \lim_{n \rightarrow \infty} \sup \left| \frac{1}{n} \sum_{i=1}^n \mathbb{I}[\gamma_i \in I](y_i - \gamma_i) \right| \right) \leq \delta \quad (88)$$

где обозначение  $\models A$  имеет следующий смысл: событие  $A$  выполняется с вероятностью 1.

### Теорема 8.

Существует калибруемый АВП.

### Доказательство.

Представим доказательство в виде последовательности этапов.

1)  $\forall k \geq 1$  обозначим  $V_k = \{v_0, \dots, v_k\}$ , где  $v_i = \frac{i}{k}$ .

$\forall c \in [0, 1]$  определён отрезок  $[v_{i-1}, v_i]$ , который содержит  $c$ .

Число  $c$  можно представить в виде суммы

$$c = \lambda v_{i-1} + (1 - \lambda)v_i, \quad \text{где } \lambda \in [0, 1].$$

$$\forall v \in V_k \text{ определим } w_v(c) \stackrel{\text{def}}{=} \begin{cases} \lambda & \text{при } v = v_{i-1}, \\ 1 - \lambda & \text{при } v = v_i, \\ 0, & \text{иначе.} \end{cases}$$

Таким образом,  $c = \sum_{v \in V_k} w_v(c)v$ .

2) Определим индуктивно последовательность  $c_1, c_2, \dots$  чисел из  $[0, 1]$  следующим образом. Полагаем  $c_1 = 0$ .

Пусть для некоторого  $n$  определены числа

$$c_1, \dots, c_{n-1}. \quad (89)$$

$\forall v \in V_k$  будем использовать обозначение

$$\mu_n(v) = \sum_{i=1}^n w_v(c_i)(y_i - c_i), \quad (90)$$

где  $c_1, \dots, c_{n-1}$  — числа из (89), и  $y_n, c_n$  — переменные.

Из (90) следует, что

$$\begin{aligned} \mu_n(v)^2 &= \mu_{n-1}(v) + w_v(c_n)(y_n - c_n)^2 = \\ &= \mu_{n-1}(v)^2 + 2\mu_{n-1}(v)w_v(c_n)(y_n - c_n) + w_v(c_n)^2(y_n - c_n)^2, \end{aligned}$$

поэтому  $\sum_{v \in V_k} \mu_n(v)^2 = A + 2(y_n - c_n)B + C$ , где

$$\begin{cases} A = \sum_{v \in V_k} \mu_{n-1}(v)^2 \\ B = \sum_{v \in V_k} w_v(c_n)\mu_{n-1}(v) \\ C = (y_n - c_n)^2 \sum_{v \in V_k} w_v(c_n)^2 \end{cases}$$

Заметим:

$$\begin{aligned} B &= \sum_{v \in V_k} w_v(c_n) \sum_{i=1}^{n-1} w_v(c_i)(y_i - c_i) = \\ &= \sum_{i=1}^{n-1} \left( \sum_{v \in V_k} w_v(c_n)w_v(c_i) \right) (y_i - c_i) = \\ &= \sum_{i=1}^{n-1} \langle \vec{w}(c_n), \vec{w}(c_i) \rangle (y_i - c_i) = \\ &= \sum_{i=1}^{n-1} K(c_n, c_i)(y_i - c_i), \end{aligned}$$

где  $\vec{w}(c) = (w_{v_0}(c), \dots, w_{v_k}(c))$ ,  $K(c_n, c_i) = \langle \vec{w}(c_n), \vec{w}(c_i) \rangle$ .

Определяем  $c_n$  следующим образом:

- если уравнение

$$B(c) = \sum_{i=1}^{n-1} K(c, c_i)(y_i - c_i) = 0$$

имеет корень в  $[0, 1]$ , то полагаем  $c_n$  равным этому корню,

- иначе  $c_n = 1$  или  $0$ , если  $\forall c \in [0, 1] B(c) > 0$  или  $B(c) < 0$  соответственно.

3) Отметим, что  $2(y_n - c_n)B \leq 0$  и  $C \leq \sum_{v \in V_k} w_v(c_n) = 1$ .

Таким образом,

$$\begin{aligned} \sum_{v \in V_k} \mu_n(v)^2 &= A + 2(y_n - c_n)B + C \leq \\ &\leq \sum_{v \in V_k} \mu_{n-1}(v)^2 + 1, \end{aligned}$$

откуда, учитывая равенство  $\mu_0(v) = 0$ , получаем:

$$\sum_{v \in V_k} \mu_n(v)^2 \leq n. \quad (91)$$

4) Определим  $p_n \in V_k^\Delta : \forall v \in V_k p_n(v) = w_v(c_n)$ .

$\forall i = 1, \dots, n$  рассмотрим СВ

$$\xi_i = \llbracket p_i \in I \rrbracket (y_i - p_i),$$

где  $I \subseteq [0, 1]$  – заданное подмножество. Используя  $\xi_i$ , перепишем условие (88) в виде

$$\models \left( \lim_{n \rightarrow \infty} \sup \left| \frac{1}{n} \sum_{i=1}^n \xi_i \right| \right) \leq \delta. \quad (92)$$

Нетрудно видеть, что

$$\mathbf{E}\xi_i = \sum_{v \in V_k} w_v(c_i) \llbracket v \in I \rrbracket (y_i - v). \quad (93)$$

По усиленному закону больших чисел,

$$\models \lim_{n \rightarrow \infty} \left( \frac{1}{n} \sum_{i=1}^n \xi_i - \frac{1}{n} \sum_{i=1}^n \mathbf{E}\xi_i \right) = 0. \quad (94)$$

Поскольку  $\forall i = 1, \dots, n$

$$\begin{aligned} |\mathbf{E}\xi_i - \sum_{v \in V_k} w_v(c_i) \llbracket v \in I \rrbracket (y_i - c_i)| &= \\ = \left| \sum_{v \in V_k} w_v(c_i) \llbracket v \in I \rrbracket (y_i - v) - \right. & \\ \left. - \sum_{v \in V_k} w_v(c_i) \llbracket v \in I \rrbracket (y_i - c_i) \right| &= \\ = \left| \sum_{v \in V_k} w_v(c_i) \llbracket v \in I \rrbracket (c_i - v) \right| < \delta & \end{aligned} \quad (95)$$

то

$$\left| \sum_{i=1}^n \mathbf{E}\xi_i \right| \leq \left| \sum_{i=1}^n \sum_{v \in V_k} w_v(c_i) \llbracket v \in I \rrbracket (y_i - c_i) \right| + \delta n. \quad (96)$$

Обозначим записями  $\vec{\mu}_n$  и  $\vec{I}$  вектора

$$(\mu_n(v_0), \dots, \mu_n(v_k)) \text{ и } (\llbracket v_0 \in I \rrbracket, \dots, \llbracket v_k \in I \rrbracket)$$

соответственно. Из (91) следует, что  $\|\vec{\mu}_n\| \leq \sqrt{n}$ .

Используя неравенство Коши-Буняковского, оценим первое слагаемое в правой части (96):

$$\begin{aligned} & \left| \sum_{i=1}^n \sum_{v \in V_k} w_v(c_i) \llbracket v \in I \rrbracket (y_i - c_i) \right| = \\ & = \left| \sum_{v \in V_k} \left( \sum_{i=1}^n w_v(c_i) (y_i - c_i) \llbracket v \in I \rrbracket \right) \right| = \\ & = \left| \sum_{v \in V_k} \mu_n(v) \llbracket v \in I \rrbracket \right| = \\ & = |\langle \vec{\mu}_n, \vec{I} \rangle| \leq \|\vec{\mu}_n\| \cdot \|\vec{I}\| \leq \sqrt{n} \sqrt{k+1} \end{aligned} \quad (97)$$

Из (4.15) и (4.16) следует:

$$\left| \sum_{i=1}^n \mathbf{E} \xi_i \right| \leq \sqrt{n} \sqrt{k+1} + \delta n. \quad (98)$$

Из (98) и (94) получаем соотношение (92). ■

Нетрудно доказать более сильное утверждение: существует АВП, такой, что для каждой последовательности исходов  $(y_1, y_2, \dots)$  последовательность прогнозов  $(\gamma_1, \gamma_2, \dots)$  обладает свойством:

$$\forall I \subseteq [0, 1] \quad \lim_{n \rightarrow \infty} \frac{1}{n} \sum_{i=1}^n \xi_i = 0.$$

Для обоснования этого утверждения в процессе конструирования чисел  $c_n$  нужно в определенные моменты времени  $n_s$  ( $s \geq 1$ ) изменять  $\delta$ , т.е. вместо фиксированного  $\delta$  рассматривать последовательность  $\delta_s$  ( $s \geq 1$ ), стремящуюся к 0.

## 10. Заключение

В работе были изложены основные понятия смешивающего прогнозирования, и приведены доказательства основных свойств изложенных алгоритмов смешивающего прогнозирования. Развитие изложенных результатов может заключаться, например, путем нового определения меры качества алгоритма прогнозирования, и построения алгоритма смешивающего прогнозирования, оптимального относительно новой меры качества. Например, в качестве такой меры качества можно выбрать долю ошибочных предсказаний алгоритма смешивающего прогнозирования не на всём периоде наблюдения, а на некоторой его части, на которой предсказания экспертов имеют высокую точность.

## Список литературы

- [1] Вьюгин В.В., *Математические основы машинного обучения и прогнозирования*, МЦНМО, Москва, 2018, 384 pp.
- [2] Littlestone N., Warmuth M., “The weighted majority algorithm”, *Information and Computation*, **108** (1994), 212–261
- [3] Freund Y., Schapire R.E., “A Decision-Theoretic Generalization of On-Line Learning and an Application to Boosting”, *Journal of Computer and System Sciences*, **55** (1997), 119–139
- [4] Hannan J., “Approximation to Bayes risk in repeated plays”, *Contributions to the Theory of Games (ed. by M.Dresher, A.W.Tucker, and P. Wolfe)*, **3** (1957), 97–139
- [5] Kalai A., Vempala S., “Efficient algorithms for online decisions”, *Journal of Computer and System Sciences*, **71** (2005), 291–307
- [6] G. Lugosi, N. Cesa-Bianchi, *Prediction, Learning and Games*, Cambridge University Press, New York, 2006
- [7] M. Hutter, J. Poland, “Adaptive online prediction by following the perturbed leader”, *Journal of Machine Learning Research*, **6** (2005), 639–660
- [8] V. Vovk, “Aggregating strategies”, *Proceedings of the 3rd Annual Workshop on Computational Learning Theory (M. Fulk and J. Case, editors)*, 1990, 371–383
- [9] Cover Thomas M., Thomas Joy A., *Elements of Information Theory*, 2nd ed., John Wiley and Sons, Inc., 2006, 748 pp.
- [10] A.P. Dawid, “Calibration-based empirical probability”, *Ann. Statist.*, **13** (1985), 1251–1285
- [11] A. Chernov, Y. Kalnishkan, F. Zhdanov, V. Vovk, “Supermartingales in Prediction with Expert Advice”, *Theoretical Computer Science*, **411**:29-30 (2010), 2647–2669

### **Mathematical foundations of time series prediction** **Mironov A.M.**

The article outlines the basic concepts and methods of prediction time series. Various mixing prediction algorithms are considered and assessments of the quality of these algorithms are provided.

*Keywords:* time series, prediction algorithms, mixing prediction

## References

- [1] Vyugin V.V., *Mathematical foundations of machine learning and prediction*, MCNMO, Moskva, 2018 (In Russian), 384 pp.
- [2] Littlestone N., Warmuth M., “The weighted majority algorithm”, *Information and Computation*, **108** (1994), 212–261
- [3] Freund Y., Schapire R.E., “A Decision-Theoretic Generalization of On-Line Learning and an Application to Boosting”, *Journal of Computer and System Sciences*, **55** (1997), 119–139
- [4] Hannan J., “Approximation to Bayes risk in repeated plays”, *Contributions to the Theory of Games (ed. by M.Dresher, A.W.Tucker, and P. Wolfe)*, **3** (1957), 97–139
- [5] Kalai A., Vempala S., “Efficient algorithms for online decisions”, *Journal of Computer and System Sciences*, **71** (2005), 291–307
- [6] G. Lugosi, N. Cesa-Bianchi, *Prediction, Learning and Games*, Cambridge University Press, New York, 2006
- [7] M. Hutter, J. Poland, “Adaptive online prediction by following the perturbed leader”, *Journal of Machine Learning Research*, **6** (2005), 639–660
- [8] V. Vovk, “Aggregating strategies”, *Proceedings of the 3rd Annual Workshop on Computational Learning Theory (M. Fulk and J. Case, editors)*, 1990, 371–383
- [9] Cover Thomas M., Thomas Joy A., *Elements of Information Theory*, 2nd ed., John Wiley and Sons, Inc., 2006, 748 pp.
- [10] A.P. Dawid, “Calibration-based empirical probability”, *Ann. Statist.*, **13** (1985), 1251–1285
- [11] A. Chernov, Y. Kalnishkan, F. Zhdanov, V. Vovk, “Supermartingales in Prediction with Expert Advice”, *Theoretical Computer Science*, **411**:29–30 (2010), 2647–2669