

# Введение в методы конкурентного предсказания

Ю. А. Калнишкан

Department of Computer Science  
and Computer Learning Research Centre  
Royal Holloway, University of London

2008

## План доклада

- в докладе будет рассказано о
  - задаче предсказания с использованием советов экспертов;
  - соединяющем алгоритме, предложенном для её решения;
  - универсальных методах предсказания, основанных на этом алгоритме.
- Литература:
  - Prediction, learning, and games, Nicolò Cesa-Bianchi and Gábor Lugosi, Cambridge University Press, 2006
  - Работы В. Вовка, С. Бусуттила, М. В. Вьюгина, В. В. Вьюгина, А. Гаммермана, Ф. Жданова, Ю. Калнишкана, К. Уоткинса и А. Чернова, доступные на сайте [vovk.net](http://vovk.net)

## Содержание

### 1. Предсказание последовательностей

Основные определения  
Примеры игр

### 2. Задача предсказания с использованием советов экспертов

Постановка задачи  
Соединяющий алгоритм Вовка  
Приложения  
Мотивировка

### 3. Универсальные алгоритмы

Основной принцип  
Коверовские универсальные портфели  
Аггрегированная регрессия  
Аггрегированная регрессия для меняющихся зависимостей

### 1. Предсказание последовательностей

Основные определения  
Примеры игр

### 2. Задача предсказания с использованием советов экспертов

Постановка задачи  
Соединяющий алгоритм Вовка  
Приложения  
Мотивировка

### 3. Универсальные алгоритмы

Основной принцип  
Коверовские универсальные портфели  
Аггрегированная регрессия  
Аггрегированная регрессия для меняющихся зависимостей

# Протокол

- мы наблюдаем элементы последовательности  $\omega_1, \omega_2, \omega_3, \dots \in \Omega$
- и выдаём предсказания  $\gamma_1, \gamma_2, \gamma_3, \dots \in \Gamma$
- протокол:
 

```
FOR  $t = 1, 2, \dots$ 
  (1)  $\mathcal{A}$  выдаёт предсказание  $\gamma_t \in \Gamma$ 
  (2)  $\mathcal{A}$  наблюдает исход  $\omega_t \in \Omega$ 
END FOR
```
- качество измеряется функцией потерь  $\lambda(\omega, \gamma)$ 
  - *накопленные потери* (Loss) это сумма потерь за  $T$  шагов:

$$\text{Loss}_{\mathcal{A}}(\omega_1, \omega_2, \dots, \omega_T) = \sum_{i=1}^T \lambda(\omega_i, \gamma_i)$$

# Формализация

- игра*  $\mathcal{G}$  это тройка  $\langle \Omega, \Gamma, \lambda \rangle$ , где
  - $\Omega$  это *пространство исходов*
  - $\Gamma$  это *пространство предсказаний*
  - $\lambda : \Omega \times \Gamma \rightarrow [0, +\infty]$  это *функция потерь*
- под эту схему подпадает много разных протоколов взаимодействия со средой, не обязательно связанных с предсказанием
  - $\gamma$  это действие, предпринятое в условиях неопределённости
  - $\omega$  это поведение среды
  - $\lambda$  показывает, какой эффект дало наше действие

# Двоичные игры

- в простейших *двоичных (бинарных) играх*  $\Omega = \{0, 1\}$  и  $\Gamma = [0, 1]$
- квадратичная игра:  $\lambda(\omega, \gamma) = (\omega - \gamma)^2$
- абсолютная игра:  $\lambda(\omega, \gamma) = |\omega - \gamma|$
- логарифмическая игра:

$$\lambda(\omega, \gamma) = \begin{cases} -\log_2(1 - \gamma) & \text{если } \omega = 0 \\ -\log_2 \gamma & \text{если } \omega = 1 \end{cases}$$

- потери могут принимать значение  $+\infty$
- простая предсказательная игра:  $\Omega = \Gamma = \{0, 1\}$

$$\lambda(\omega, \gamma) = \begin{cases} 0 & \text{if } \omega = \gamma \\ 1 & \text{if } \omega \neq \gamma \end{cases}$$

# Непрерывные игры

- у квадратичной и абсолютной игры есть *непрерывные* аналоги с  $\Omega = \Gamma = [0, 1]$  и теми же функциями потерь
- логарифмическая игра имеет любопытные расширения, которые мы сейчас рассмотрим

## Коверовская игра (1)

- рассмотрим  $N$  акций
- вектор  $(\omega_t[1], \omega_t[2], \dots, \omega_t[M])$  описывает изменение рыночной конъюнктуры между моментами  $t-1$  и  $t$ :
  - цена акции  $j$  меняется в  $\omega_t[j]$  раз
- пусть  $\gamma_t[j]$  это доля капитала, которую мы вкладываем в акцию  $j$  на  $j$ -м шаге
  - имеем  $\gamma_t[j] \in [0, 1]$  и  $\sum_{j=1}^K \gamma_t[j] = 1$
- предположим, что наш капитал до шага  $t$  составлял  $W_{t-1}$ 
  - в акцию  $j$  мы вкладываем  $W_{t-1}\gamma_t[j]$
  - после изменения её цены, вложенная сумма превращается в  $W_{t-1}\gamma_t[j]\omega_t[j]$
  - наш капитал меняется в  $\sum_{j=1}^N \gamma_t[j]\omega_t[j] = \langle \gamma_t, \omega_t \rangle$  раз
- если в начальный момент наш капитал составлял  $W_0 = 1$ , то после  $T$  шагов имеем  $W_T = \prod_{i=1}^T \langle \gamma_i, \omega_i \rangle$

## Коверовская игра (2)

- коверовскую игру можно рассмотреть в нашей общей схеме
  - $\Omega = [0, +\infty]^N$  «положительный квадрант»
  - $\Gamma = \{(\gamma[1], \gamma[2], \dots, \gamma[M]) \in [0, 1]^N \mid \sum_{j=1}^N \gamma[j] = 1\}$  симплекс
  - $\lambda(\omega, \gamma) = -\log_2 \langle \omega, \gamma \rangle$
- потери могут быть отрицательными; если это важно, и этот случай надо запретить, то вводят ограничение  $\|\omega\|_\infty \leq 1$  или меняют функцию потерь на  $\log \|\omega\|_\infty - \log \langle \omega, \gamma \rangle$
- взяв логарифм, можем рассматривать потери в аддитивной модели; имеем

$$\text{Loss}(\omega_1, \omega_2, \dots, \omega_T) = -\log_2 W_T$$

- капитал это экспонента от минус потерь

## Игра Фройнда-Шапиро

- у меня есть  $N$  друзей, играющих на скачках (или в какую-то другую рискованную игру)
  - друг  $i$  несёт потери  $\omega_t[i]$  на шаге  $t$
  - предполагаем, что потери ограничены; после перенормировки можем считать, что  $\omega_t[i] \in [0, 1]$
- я раздаю свои деньги друзьям и прошу их сыграть за меня
  - если другу  $j$  на  $t$ -м шаге дана доля  $\gamma_t[j]$ , так что  $\sum_{j=1}^N \gamma_t[j] = 1$ , то мои потери будут выпуклой комбинацией  $\lambda(\omega_t, \gamma_t) = \sum_{j=1}^N \omega_t[j]\gamma_t[j] = \langle \omega_j, \gamma_j \rangle$
- здесь  $\Omega = [0, 1]^N$ , а  $\Gamma$  это симплекс, как в коверовской игре

## Пример вне схемы: задача многорукого бандита

- заменим «друзей» из предыдущего примера на ручки игрового автомата
  - на каждом шаге я дёргаю за одну ручку и несу потери, соответствующие этой ручке
  - я не знаю, какие потери я бы понёс на другой ручке
  - обычно в этой игре разрешается рандомизация: я подбрасываю монетку, а от моих потерь берётся среднее
- это пример протокола с неполной информацией; он не покрывается нашей схемой непосредственно
- игру Фройнда-Шапиро можно рассматривать как вариант многорукого бандита с полной информацией и рандомизацией ( $\gamma_t[j]$  можно рассматривать как вероятность выбора  $j$ -й ручки; я вычисляю эти вероятности и потом случайным образом выбираю ручку)

## Протокол

### 1. Предсказание последовательностей

Основные определения  
Примеры игр

### 2. Задача предсказания с использованием советов экспертов

Постановка задачи  
Соединяющий алгоритм Вовка  
Приложения  
Мотивировка

### 3. Универсальные алгоритмы

Основной принцип  
Коверовские универсальные портфели  
Агрегированная регрессия  
Агрегированная регрессия для меняющихся зависимостей

- пусть  $N$  экспертов  $\mathcal{E}_1, \mathcal{E}_2, \dots, \mathcal{E}_N$  предсказывают ту же самую последовательность
  - мы узнаём их предсказания до того, как выдаём наше
  - наша цель – предсказывать (почти) так же успешно, как лучший эксперт, в терминах накопленных потерь
- расширенный протокол:

(1) FOR  $t = 1, 2, \dots$

(2)  $\mathfrak{M}$  считывает  $\gamma_t^{(1)}, \gamma_t^{(2)}, \dots, \gamma_t^{(N)} \in \Gamma$

(3)  $\mathfrak{M}$  выдаёт предсказание  $\gamma_t \in \Gamma$

(4)  $\mathfrak{M}$  наблюдает исход  $\omega_t \in \Omega$

(5) END FOR

## Обсуждение

- мы хотим найти смешивающую стратегию, несущую потери, которые удовлетворяют условию

$$\text{Loss}_{\mathfrak{M}} \leq f(\text{Loss}_{\mathcal{E}_i})$$

где  $\mathcal{E}_i$  это наиболее успешный на данный момент эксперт и  $f(x)$  не намного больше  $x$

- на экспертов не накладывается никаких ограничений
  - вычислительные возможности экспертов не ограничены
  - по сути «эксперт» это метафора последовательности предсказаний, подаваемых на вход протоколу
  - мы рассматриваем антагонистическую игру «предсказатель» против «природы и экспертов»
- эта проблема изучалась с конца 1980-х годов

## Веса

- соединяющий алгоритм (Aggregating Algorithm) предложен В. Вовком в работах 1991 и 1998 гг.; это один из самых общих методов для решения задачи
- мы поддерживаем набор весов  $(p_t^{(1)}, p_t^{(2)}, \dots, p_t^{(N)})$  для экспертов
- на каждом шаге веса меняются в соответствии с потерями:


$$p_t^{(j)} = e^{-\eta \lambda(\omega_t, \gamma_t^{(j)})} p_{t-1}^{(j)}$$

— параметр  $\eta \in (0, +\infty)$  называется *скоростью обучения*


# Обобщённые предсказания

- будем называть *обобщённым предсказанием* любую функцию на исходах, принимающую значения от 0 до  $+\infty$  включительно, т.е. элемент множества  $[0, +\infty]^\Omega$ 
  - для двоичных игр это множество можно отождествить с положительным квадрантом  $[0, +\infty]^2$
- задание множества предсказаний и функции потерь выделяет в множестве предсказаний допустимые
  - предсказание  $\gamma$  задаёт функцию  $\lambda(\cdot, \gamma) : \Omega \rightarrow [0, +\infty]$
- обобщённое предсказание, мажорирующее какое-либо предсказание, называется *суперпредсказанием*
  - иначе говоря,  $g : \Omega \rightarrow [0, +\infty]$  является суперпредсказанием, если найдётся предсказание  $\gamma \in \Gamma$ , такое что  $\lambda(\omega, \gamma) \leq g(\omega)$  для всех  $\omega$

# Примеры множеств суперпредсказаний (1)




квадратичная игра  
 $\lambda(\omega, \gamma) = (\omega - \gamma)^2$




абсолютная игра  
 $\lambda(\omega, \gamma) = |\omega - \gamma|$

# Примеры множеств суперпредсказаний (2)



логарифмическая игра

$$\lambda(\omega, \gamma) = \begin{cases} -\log_2(1 - \gamma), & \omega = 0 \\ -\log_2 \gamma, & \omega = 1 \end{cases}$$



простая предсказательная игра

$$\lambda(\omega, \gamma) = \begin{cases} 0, & \omega = \gamma \\ 1, & \omega \neq \gamma \end{cases}$$

# Смешивание

- получив предсказания экспертов, построим обобщённое предсказание  $g$  следующим образом

$$g(\omega) = -\log_\beta \sum_{j=1}^N \beta^{\lambda(\omega, \gamma_t^{(j)})} p_t^{(j)*}$$

- где  $\beta = e^{-\eta} \in (0, 1)$
- $p_t^{(j)*}$  это веса, нормированные так, чтобы суммироваться к единице
- теперь нам надо произвести подстановку, выбрав предсказание  $\gamma$ , несущее потери не (намного) больше  $g$ 
  - если  $g$  не суперпредсказание, нам придётся удовлетвориться неточной подстановкой

# Константа $c(\beta)$

- пусть  $\beta \in (0, 1)$ ; обозначим через  $c(\beta)$  наименьшее  $c$  со следующим свойством:  
 — для любого набора предсказаний  $\gamma^{(1)}, \gamma^{(2)}, \dots, \gamma^{(N)} \in \Gamma$  и весов  $p^{(1)}, p^{(2)}, \dots, p^{(N)} \in [0, 1]$ , суммирующихся к единице, найдётся предсказание  $\gamma$ , такое что

$$\lambda(\omega, \gamma) \leq -c \log_{\beta} \sum_{j=1}^N \beta^{\lambda(\omega, \gamma^{(j)})} p^{(j)}$$


- если  $c(\beta) = 1$  для какого-то  $\beta$ , то игра называется **смешиваемой** ( $\beta$ -смешиваемой)
- соединяющий алгоритм выдаёт  $\gamma_t$ , такое что  $\lambda(\omega, \gamma_t) \leq c(\beta)g(\omega)$  для любого  $\omega$   
 — иногда существует эффективная **функция подстановки**

# Геометрическая интерпретация $c(\beta)$ : смешиваемость

- рассмотрим преобразование  $\mathfrak{B}_{\beta}$  множества обобщённых предсказаний, заданное так:


$$(\mathfrak{B}_{\beta}g)(\omega) = \beta^{g(\omega)}$$

- игра является  $\beta$ -смешиваемой тогда и только тогда, когда образ множества суперпредсказаний  $S$  под действием  $\mathfrak{B}_{\beta}$  является выпуклым:



# Геометрическая интерпретация $c(\beta)$ : общий случай

- возьмём выпуклое замыкание образа  $\mathfrak{B}_{\beta}(S)$   
 — обозначим выпуклое замыкание буквой  $\mathfrak{C}$
- вообще говоря  $\mathfrak{C}(\mathfrak{B}_{\beta}(S))$  не совпадает с  $\mathfrak{B}_{\beta}(S)$   
 —  $c(\beta)$  это «толщина»  $\mathfrak{B}^{-1}(\mathfrak{C}(\mathfrak{B}_{\beta}(S))) \setminus S$



# Смешиваемость конкретных игр (1)

- квадратичная игра смешиваема:  $c(\beta) = 1$  для  $\beta \geq 1$
- логарифмическая игра смешиваема:  $c(\beta) = 1$  для  $\beta \geq 1/2$
- абсолютная игра не смешиваема:

$$c(\beta) = \left( \ln \frac{1}{\beta} \right) / \left( 2 \ln \frac{2}{1+\beta} \right)$$

- простая игра не смешиваема:

$$c(\beta) = \left( \ln \frac{1}{\beta} \right) / \left( \ln \frac{2}{1+\beta} \right)$$

— для смешиваемости необходима выпуклость множества суперпредсказаний

## Смешиваемость конкретных игр (2)

- коверовская игра смешиваема:  $c(\beta) = 1$  для  $\beta \geq 1/2$   
— и тогда не важно, что потери могут быть отрицательными
- игра Фройнда-Шапиро не смешиваема:

$$c(\beta) = \left( \ln \frac{1}{\beta} \right) / \left( N \ln \frac{N}{N + \beta - 1} \right)$$

## Верхняя оценка на потери

- дадим экспертам одинаковые начальные веса  $1/N$
- для любого эксперта  $\mathcal{E}_i$  из произвольного набора из  $N$  экспертов, на любом шаге  $T$  и при любых исходах, если только стратегия  $\mathfrak{M}$  пользуется соединяющим алгоритмом, то выполняется неравенство

$$\text{Loss}_{\mathfrak{M}}(T) \leq c(\beta) \text{Loss}_{\mathcal{E}_i}(T) + \frac{c(\beta)}{\ln(1/\beta)} \ln N$$

— для смешиваемых игр мультипликативный коэффициент можно сделать равным 1

- в этой оценке ни мультипликативный ни аддитивный коэффициенты не растут со временем

## Оптимальность верхней оценки

- предположим, для какого-либо алгоритма  $\mathfrak{M}$  выполняется оценка

$$\text{Loss}_{\mathfrak{M}}(T) \leq c \text{Loss}_{\mathcal{E}_i}(T) + \alpha \ln N$$

для любого эксперта  $\mathcal{E}_i$  из произвольного набора из  $N$  экспертов, на любом шаге  $T$  и при любых исходах  
— тогда найдётся  $\beta \in (0, 1)$ , такое что  $c(\beta) \leq c$  и  $c(\beta)/\ln(1/\beta) \leq \alpha$

- константы в оценке, даваемой соединяющим алгоритмом, нельзя улучшить

## Другие оценки

- оптимальность не запрещает построение оценок другого типа
- например, для абсолютной игры можно добиться оценки

$$\text{Loss}_{\mathfrak{M}}(T) \leq \text{Loss}_{\mathcal{E}_i}(T) + 2\sqrt{T \ln N}$$

— здесь мультипликативный коэффициент равен единице, зато аддитивный растёт со временем как  $\sqrt{T}$

## Коверовская игра

- для коверовской игры получаем

$$\text{Loss}_{\text{opt}}(T) \leq \text{Loss}_{\mathcal{E}_i} + \frac{\ln N}{\ln 2}$$

- экспоненцируя и переходя от потерь к капиталу, получаем

$$W_{\text{opt}}(T) \geq \frac{1}{N} W_{\mathcal{E}_i}(T)$$

- эта оценка совпадает с получаемой из тривиальных соображений:
  - пусть  $N$  экспертов хотят советовать нам, как вкладывать деньги; поделим деньги между ними поровну и дадим каждому распоряжаться своей долей; тогда в каждый момент наш совокупный капитал будет не меньше, чем у каждого из них

## Игра Фройнда-Шапиро

- обычно в игре Фройнда-Шапиро задача ставится так:
  - как делить деньги между друзьями так, чтобы нести потери примерно как у самого успешного?
- рассмотрим  $N$  экспертов следующего вида:
  - эксперт  $j$  даёт все деньги другу  $j$ , т.е. предсказывает  $(0, \dots, 0, 1, 0, \dots, 0)$ , где единица стоит на  $j$ -м месте
- соединяющий алгоритм может быть применён к задаче непосредственно
  - поскольку игра не смешиваема, в оценке будет присутствовать мультипликативная константа; оценку нельзя однозначно оптимизировать
  - но мультипликативная константа получается лучше, чем в оригинальной работе Фройнда и Шапиро [Вовк, 1998]

## Тотализатор (1)

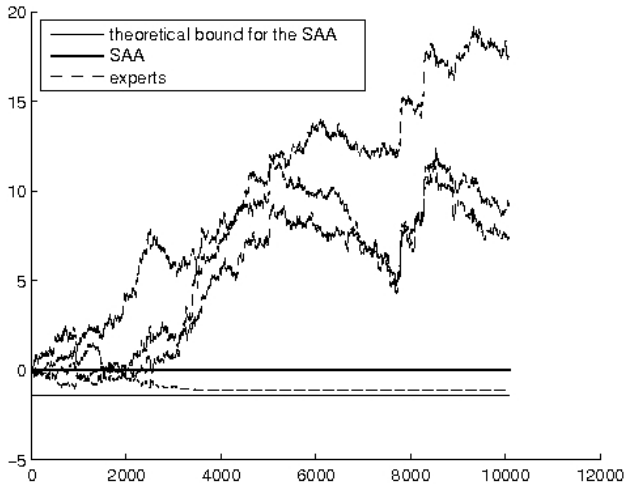
- букмекеры публикуют условия, на которых они принимают ставки
  - можно считать, что они выдают предсказание на результат матча
  - попробуем смешать предсказания разных букмекеров
- будем считать, что букмекер вычисляет распределение вероятностей и использует его, чтобы рассчитать условия приёма ставок
  - в условия закладывается маржа
- восстановим (гипотетическое) распределение по ставкам
  - будем считать, что букмекер выдаёт распределение вероятностей на исходы матча

## Тотализатор (2)

- наша игра такова:
  - у теннисного матча два исхода, победа одного или другого игрока; будем обозначать их векторами  $(1, 0)$  и  $(0, 1)$
  - предсказание в нашей модели это распределение вероятностей, т.е. точка  $(p_1, p_2)$  из симплекса  $p_1, p_2 \in [0, 1], p_1 + p_2 = 1$
  - будем мерить потери квадратичной функцией:
$$\lambda(\omega, \gamma) = \|\omega - \gamma\|^2$$
  - конечно, наша схема идеализирована
- можно показать, что эта игра (а также игры с 3-мя и более исходами) смешиваема
- ставки популярных букмекеров Великобритании доступны в Интернете; построим наши собственные предсказания



# Разности потерь



графики  $(Loss_{\mathcal{E}_i}(T) - Loss_{\text{opt}}(T))$  по [Жданов и Вовк, 2008]

# Капитал как экспонента потерь

- почему соединяющий алгоритм смешивает таким образом?
- одна из мотивировок – коверовская игра, рассмотренная выше
  - мы делим деньги между экспертами и даём им самостоятельно инвестировать
  - в случае произвольной игры «деньги» это  $e^{-\eta Loss}$
  - поскольку линейность коверовской игры у других игр отсутствует, подбор предсказания, соответствующего линейной комбинации, становится сложной задачей
  - появляется необходимость рассматривать коэффициент  $c(\beta)$

# Байесовской правило

- для логарифмической игры соединяющий алгоритм эквивалентен правилу Байеса

$$P(A_i | B) = \frac{P(A_i)P(B|A_i)}{\sum_i P(A_i)P(B|A_i)}$$

- $P(A_i)$  – нормированный вес эксперта  $i$  на шаге  $t$
- $P(A_i|B)$  – нормированный вес эксперта  $i$  на шаге  $t + 1$ , после того, как произошёл исход  $B$
- $P(B|A_i)$  это предсказание исхода  $B$  на шаге  $t$  (т.е.  $\gamma_t^{(i)}$  при исходе 1 и  $1 - \gamma_t^{(i)}$  при исходе 0)

## 1. Предсказание последовательностей

- Основные определения
- Примеры игр

## 2. Задача предсказания с использованием советов экспертов

- Постановка задачи
- Соединяющий алгоритм Вовка
- Приложения
- Мотивировка

## 3. Универсальные алгоритмы

- Основной принцип
- Коверовские универсальные портфели
- Агрегированная регрессия
- Агрегированная регрессия для меняющихся зависимостей

## Соединение больших семейств алгоритмов

- соединяющий алгоритм может применяться к счётным и континуальным семействам экспертов
- возьмём семейство методов предсказания с каким-либо параметром
  - каждое значение параметра можно считать «экспертом»
  - применив соединяющий алгоритм, получим универсальный непараметрический метод, несущий потери не намного хуже каждого исходного
- верхние оценки на потери носят особый характер
  - не накладывает никаких ограничений на механизм, порождающий данные
  - универсальный метод работает успешно, если только один из методов исходного класса работает успешно
  - оценки верны *при всех* возможных исходах

## Постоянные балансируемые портфели

- рассмотрим стратегию инвестирования, основанную на поддержке постоянных пропорций между вложениями в разные акции
  - в коверовской игре такая стратегия соответствует выдаче одного и того же предсказания  $(\gamma_t^{(1)}, \gamma_t^{(2)}, \dots, \gamma_t^{(N)})$
  - стратегия не является статической; поскольку цены акций меняются, мы должны на каждом шаге балансировать портфель, чтобы поддерживать постоянные пропорции между вложениями
  - если мы следуем постоянному балансируемому портфелю  $b$ , то наш капитал растёт с начального значения  $W_0$  до  $W_0 \prod_{i=1}^T \langle b, \omega_i \rangle$
- для каждого такого портфеля  $b$  рассмотрим эксперта, который им пользуется

## Построение универсального портфеля

- выдадим эксперту  $b$  долю  $d\mu(b)$  исходного капитала, и он будет ей распоряжаться
  - за время  $T$  капитал эксперта  $b$  вырастет в  $\prod_{i=1}^T \langle b, \omega_i \rangle$  раз
  - наш суммарный капитал вырастет в

$$\int_{S_{N-1}} \prod_{i=1}^T \langle b, \omega_i \rangle d\mu(b)$$

- раз, где  $S_{N-1}$  – симплекс в  $N$ -мерном пространстве
- каждый раз мы инвестируем в соответствии с формулой

$$\frac{\int_{S_{N-1}} b \prod_{i=1}^T \langle b, \omega_i \rangle d\mu(b)}{\int_{S_{N-1}} \prod_{i=1}^T \langle b, \omega_i \rangle d\mu(b)}$$

## Оценки

- при разных начальных распределениях  $\mu(b)$  мы получаем разные оценки
- равномерное распределение на симплексе даёт неравенство

$$W_b(T) \leq W(T)(T+1)^{N-1},$$

где  $W_b(T)$  – капитал произвольного постоянного балансируемого портфеля  $b$ , а  $W(T)$  – наш капитал

- выбор распределения Дирихле позволяет понизить показатель степени:

$$W_b(T) \leq W(T)2(T+1)^{(N-1)/2}$$

- в терминах потерь имеем добавочный член  $O(N \ln T)$

- коверовские универсальные портфели были построены независимо от соединяющего алгоритма в [Ковер и Ордентлих, 1996], но являются его частным случаем (для коверовской игры)
- для получения оценок на капитал не потребовалось никаких ограничений на изменение цен акций (вроде независимости или следования геометрическому броуновскому движению)
  - оценки остаются верными при любом поведении рынка

- внесём дополнение в наш протокол предсказания; пусть помимо исходов нам поступают *сигналы*  $x_i$
- протокол:
 

```
FOR  $t = 1, 2, \dots$ 
  (1)  $\mathcal{A}$  наблюдает сигнал  $x_t$ 
  (2)  $\mathcal{A}$  выдаёт предсказание  $\gamma_t \in \Gamma$ 
  (3)  $\mathcal{A}$  наблюдает исход  $y_t \in \Omega$ 
END FOR
```
- интуитивно, задача алгоритма состоит в том, чтобы выяснить зависимость  $y$  от  $x$  на лету; назовём эту задачу *регрессией на последовательностях* (on-line regression)
- в более традиционной постановке алгоритму сразу даётся набор пар  $(x, y)$  (обучающая выборка); эта постановка называется *пакетной* (batch)

- будем считать, что  $y_i \in \Omega = [-Y, Y]$ 
  - ограниченность множества существенна
- разрешим предсказания из отрезка  $\Gamma = [-Y, Y]$ 
  - расширение отрезка до всей числовой прямой ничего существенного не добавит; мы будем получать суперпредсказания, которые заведомо хуже предсказаний
- будем рассматривать квадратичные потери
 
$$\lambda(y, \gamma) = (y - \gamma)^2$$
- это непрерывная квадратичная игра; она смешиваема
- будем считать, что  $x_i \in \mathbb{R}^n$

- возьмём класс постоянных регрессоров
  - эксперт, пользующийся постоянным регрессором  $\theta$  на каждом шаге выдаёт предсказание  $\gamma_t = \theta^T x_t$
- введём на  $\mathbb{R}^n$  гауссовское распределение  $\left(\frac{a\eta}{\pi}\right)^{n/2} e^{-\eta a \|\theta\|^2}$  (здесь  $a > 0$  это произвольный параметр) и применим соединяющий алгоритм
  - для получения предсказаний и оценок необходимо подсчитать интеграл  $\int e^{-Q(x)} dx$ , где  $Q$  – положительно определённая квадратичная форма; его можно взять в явном виде, поэтому алгоритм получается простой
- назовём получившийся алгоритм *агрегированной регрессией* (AAR) [Вовк 1998, 2001]
  - альтернативное название – предсказатель Вовка-Азури-Вармута

- пусть  $\|x_t\|_\infty \leq X$  (т.е. все компоненты  $x_t$  ограничены  $X$ )
- тогда

$$\text{Loss}_{\text{AAR}}(T) \leq \inf_{\theta} (\text{Loss}(T) + a\|\theta\|^2) + nY^2 \ln\left(\frac{TX^2}{2} + 1\right)$$

- можно показать, что эта оценка точна

- сам алгоритм может быть выписан в дуальной форме:

$$\gamma_T = \tilde{Y}'_T (aI + \tilde{K}_T)^{-1} \tilde{k}_T$$

- где
- $\tilde{Y}'_T = (y_1, y_2, \dots, y_{T-1}, 0)$
  - $\tilde{K}_T = (\langle x_i, x_j \rangle)_{i,j=1}^T$
  - $\tilde{k}_T = (\langle x_i, x_T \rangle)_{i=1}^T$

- эта запись наводит на мысль о родстве с *гребневой регрессией* (ridge regression)

## Гребневая регрессия

## Сравнение двух типов регрессии (1)

- дуальная форма гребневой регрессии:

$$\gamma_T = Y_T (aI + K_T)^{-1} k_T$$

- где
- $Y'_T = (y_1, y_2, \dots, y_{T-1})$
  - $K_T = (\langle x_i, x_j \rangle)_{i,j=1}^{T-1}$
  - $k_T = (\langle x_i, x_T \rangle)_{i=1}^{T-1}$

- определение гребневой регрессии:
  - пусть дана обучающая выборка  $(x_1, y_1), \dots, (x_{T-1}, y_{T-1})$
  - выберем регрессор  $\theta$ , минимизирующий сумму

$$\sum_{i=1}^{T-1} (\theta' x_i - y_i)^2 + a\|\theta\|^2$$

- агрегированная регрессия – это гребневая регрессия, добавляющая к обучающей выборке фиктивный пример  $(x_T, 0)$ , где  $x_T$  это сигнал, для которого надо получить предсказание
- можно сказать, что агрегированная регрессия пользуется на  $x_T$  регрессором  $\theta$ , минимизирующим сумму

$$\sum_{i=1}^{T-1} (\theta' x_i - y_i)^2 + (\theta' x_T)^2 + a\|\theta\|^2$$

- предсказание гребневой регрессии прижимается к 0

## Сравнение двух типов регрессии (2)

- гребневая регрессия – байесовский метод; её предсказание минимизирует ожидаемые потери в предположении нормального распределения
- для агрегированной регрессии есть верхние оценки на потери в худшем случае
  - они выполняются при любых исходах

## Кернелизация

- агрегированная регрессия может быть кернелизована — скалярные произведения  $\langle x_i, x_j \rangle$  в дуальной форме заменяются на значения ядра  $\mathcal{K}(x_i, x_j)$
- ядро можно определить как скалярное произведение в гильбертовом пространстве:
$$\mathcal{K}(x_i, x_j) = \langle \Phi(x_i), \Phi(x_j) \rangle$$
  - где  $\Phi$  отображает  $x_i$  в гильбертово пространство  $H$
  - само отображение знать обычно не нужно; достаточно уметь вычислять ядро
- ядро задаёт функциональное пространство RKHS (reproducing kernel Hilbert space)
  - грубо говоря, оно состоит из функций вида  $\sum a_i \mathcal{K}(x_i, \cdot)$  и их пределов

## Оценки в ядерном случае

- пусть  $\mathcal{K}(x_i, x_j) \leq c_{\mathcal{F}}$
- если  $T$  и верхняя оценка  $d$  на норму  $f$  из RKHS известны заранее, можно подобрать  $a$  так, чтобы выполнялось неравенство

$$\text{Loss}_{\text{KAAR}} \leq \text{Loss}_f(T) + 2Yc_{\mathcal{F}}d\sqrt{T}$$

- применением соединяющего алгоритма можно устранить параметр  $a$  совсем и получить верхнюю оценку типа

$$\text{Loss}_{\text{KAAR}} \leq \text{Loss}_f(T) + O(\sqrt{T})$$

— но соответствующий алгоритм в явном виде не выписывается

## Практические применения

- численные эксперименты на модельных базах данных показывают, что дополнительная регуляризация, вносимая агрегированной регрессией (по сравнению с гребневой), по-видимому является слишком сильной
  - были сделаны попытки ослабить её, например, вместо

$$\sum_{i=1}^{T-1} (\theta' x_i - y_i)^2 + (\theta' x_t)^2 + a \|\theta\|^2 \rightarrow \min_{\theta}$$

рассмотреть

$$\sum_{i=1}^{T-1} (\theta' x_i - y_i)^2 + \beta (\theta' x_t)^2 + a \|\theta\|^2 \rightarrow \min_{\theta}$$

с  $\beta < 1$  [Бусуттил и Калнишкан, 2007]

# Меняющиеся регрессоры

- зависимость  $y$  от  $x$  может медленно меняться со временем
- рассмотрим класс регрессоров, которые меняются со временем
  - меняющийся регрессор это последовательность  $\theta_1, \theta_2, \dots$ , и на шаге  $T$  он предсказывает  $\gamma_T = (\theta_1 + \theta_2 + \dots + \theta_T)' x_T$
- на таких регрессорах тоже можно ввести нормальное распределение и применить соединяющий алгоритм [Бусуттил и Калнишкан, 2007]
- получаемый алгоритм кернелизуется

# Кернельная форма

$$\gamma_T = \tilde{Y}'_T (aI + \hat{K}_T)^{-1} \hat{k}_T$$

где  $\tilde{Y}'_T = (y_1, y_2, \dots, y_{T-1}, 0)$

$$\hat{K}_T = \begin{pmatrix} \mathcal{K}(x_1, x_1) & \mathcal{K}(x_1, x_2) & \mathcal{K}(x_1, x_3) & \dots & \mathcal{K}(x_1, x_T) \\ \mathcal{K}(x_2, x_1) & 2\mathcal{K}(x_2, x_2) & 2\mathcal{K}(x_2, x_3) & \dots & 2\mathcal{K}(x_2, x_T) \\ \mathcal{K}(x_3, x_1) & 2\mathcal{K}(x_3, x_2) & 3\mathcal{K}(x_3, x_3) & \dots & 3\mathcal{K}(x_3, x_T) \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ \mathcal{K}(x_T, x_1) & 2\mathcal{K}(x_T, x_2) & 3\mathcal{K}(x_T, x_3) & \dots & T\mathcal{K}(x_T, x_T) \end{pmatrix}$$

$$\hat{k}_T = (\mathcal{K}(x_T, x_1), 2\mathcal{K}(x_T, x_2), 3\mathcal{K}(x_T, x_3), \dots, T\mathcal{K}(x_T, x_T))'$$

— более старые сигналы входят с меньшими весами

# Верхняя оценка на потери

- если  $T$  известно заранее и для  $f_1, f_2, \dots, f_t$  из RKHS имеем оценку

$$\|f_i\| \leq \frac{d}{T^{0.5+\epsilon}}$$

то получаем оценку на потери

$$\text{Loss}_{\text{KAARCH}} \leq \text{Loss}_{f_1, f_2, \dots, f_T}(T) + O(T^{1-\epsilon})$$

- оценка не охватывает все меняющиеся регрессоры, а только медленно меняющиеся

# Применения

- алгоритм применялся для предсказания неявной волатильности (implied volatility)
- неявная волатильность представляет собой функцию от цены исполнения опциона  $\sigma(X)$ 
  - её часто называют улыбкой волатильности
  - она меняется по мере приближения к сроку исполнения опциона
- исход  $y_i$  соответствует цене сделки (или цене закрытия); сигнал  $X_i$  включает в себя цену исполнения, текущую цену актива и т.д.