

# Задачи распределения в реальном времени

Сергей Николенко

Теория экономических механизмов — ИТМО, весна 2008

# Outline

- 1 **Задача распределения**
  - Постановка и верхняя оценка
  - Нижняя оценка, равная верхней
- 2 **Дизайн механизмов для задачи распределения**
  - Постановка
  - Механизм и его анализ

# Суть задачи

- Есть процессор (один), на вход ему потихоньку поступают задачи.
- Вопрос в том, чтобы последовательно выбирать, над какой задачей из доступных работать в настоящий момент.
- Очевидно, что все задачи выполнить не получится; надо выбирать при поступлении задачи, что с ней делать.

# Суть задачи

- Давайте пока безо всяких механизмов.
- Просто поступают задачи, их надо распределить.
- Задача — это пара  $(e, d)$ : время исполнения и дедлайн.
- Если задача поступила в момент  $t_0$ , мы можем получить  $e$  единиц «дохода», выделив  $e$  слотов процессорного времени внутри интервала  $t_0 \leq t \leq t_0 + d$ .

# Суть задачи

- Т.е. мы хотим максимизировать суммарное время полезной работы процессора.
- Для этого нужен онлайн-алгоритм, который будет реагировать на поступающие задачи.
- Мы будем сравнивать его с оптимальным ясновидящим алгоритмом, который всё знает заранее и может найти глобальный оптимум.
- Алгоритм  $r$ -оптимален, если он достигнет доли как минимум  $r$  от результата оптимального алгоритма.

## Пример и верхняя оценка

- Первая идея верхней оценки такая: давайте возьмём большую задачу  $S_i$  длиной  $L_i$ .
- А потом будем давать кучу мелких задач, каждая стоит  $\epsilon$ , начинаются следующая во время дедлайна предыдущей.
- Как только алгоритм откажется от большой задачи, мелкие закончатся, и он получит всего  $\epsilon$ .
- Если не откажется, получит большую задачу. Большая задача называется *приманкой*.

## Пример и верхняя оценка

- Обозначения: время делится на эпохи.
- В каждой эпохе противник сначала делает большую задачу  $T_0$  длины  $t_0 = 1$ .
- Потом, за  $\epsilon$  до конца большой задачи  $T_i$  длиной  $t_i$  запускает задачу  $T_{i+1}$  длиной  $t_{i+1}$ .
- Ни одна эпоха не продолжается дальше  $T_m$  для некоторого  $m$ .
- Все задачи, кроме  $T_m$ , приманки.

## Пример и верхняя оценка

- Во-первых, игрок ни разу не оставит приманку ради мелкой задачи, потому что она ему даст за всю эпоху не больше малого  $\epsilon$ .
- Во-вторых, это всё значит, что в течение одной эпохи игрок получит либо одну задачу  $T_i$ ,  $i < m$ , либо задачу  $T_m$ .
- А оптимальный алгоритм сможет выполнять все мелкие задачи, потому что в таком случае перекрывающиеся большие задачи ему не помешают. Т.е. он фактически берёт



## Пример и верхняя оценка

- Давайте теперь введём такие последовательности времён:

$$t_{i+1} = (ct_i - \sum_{j=0}^i t_j), \text{ с константа.}$$

- Тогда, если игрок только  $T_i$  берёт, то он получит  $t_i$ , а противник —  $\sum_{j=0}^{i+1} t_j$  ( $T_{i+1}$  успеет получиться).
- Отношение получается

$$\frac{t_i}{\sum_{j=0}^{i+1} t_j} = \frac{t_i}{ct_i - \sum_{j=0}^i t_j + \sum_{j=0}^i t_j} = \frac{1}{c}.$$

## Пример и верхняя оценка

- А если игрок выполнил  $T_m$ , то у него  $t_m$ , а у противника  $\sum_{j=0}^m t_j$ .
- Надо только выбрать  $c$  и  $m$  так, чтобы  $\frac{t_m}{\sum_{j=0}^m t_j}$  тоже было не больше  $\frac{1}{c}$ .
- Т.е. надо найти минимальное  $c$  такое, что функция  $t: \mathbb{N} \rightarrow \mathbb{N}$ , заданная рекуррентным соотношением

$$t_0 = 1, \quad t_{i+1} = (ct_i - \sum_{j=0}^i t_j),$$

удовлетворяла бы условию

$$\exists m \geq 0 : \frac{t_m}{\sum_{j=0}^m t_j} \leq \frac{1}{c}.$$

## Пример и верхняя оценка

- Тут есть простор для комбинаторных рассуждений.

**Упражнение.** Докажите, что  $\exists m \geq 0 : \frac{t_m}{\sum_{j=0}^m t_j} \leq \frac{1}{c}$

эквивалентно  $\exists l \geq 0 : t_{l+1} \leq t_l$ .

**Упражнение.** Докажите, что рекуррентное условие эквивалентно

$$t_0 = 1, \quad t_1 = c - 1, \quad t_{i+2} = c(t_{i+1} - t_i).$$

## Пример и верхняя оценка

- А если к последнему уравнению применить стандартную теорию рекуррентно заданных последовательностей, получится, что нужное условие выполняется для  $c < 4$ .

**Упражнение.** Изучите эту теорию и примените её.

# 1/4-оптимальный алгоритм $TD_1$

- Мы тут выяснили, что лучше  $\frac{1}{4}$  не бывает.
- Сейчас построим алгоритм, который достигает  $\frac{1}{4}$ -оптимальности.
- Сначала рассмотрим ситуацию, когда у задач нету laxity — т.е. если начинать, то начинать прямо сейчас.
- Это позволит нам резко упростить алгоритм.

# 1/4-оптимальный алгоритм $TD_1$

- Задача описывается как  $T_j = (a_j, c_j, d_j, v_j)$ :
  - $r_j$  — release, когда пришла;
  - $c_j$  — computation, сколько надо времени;
  - $d_j$  — deadline, когда должно быть сделано;
  - $v_j$  — value, сколько дадут.
- Обозначим  $l_j = d_j - c_j$  самое позднее время начала.

# 1/4-оптимальный алгоритм $TD_1$

- Введём понятие *интервала* в  $t$ . Интервал — это промежуток времени  $[t_b, t_e)$ , где есть занятый подпромежуток  $[t_b, t_f]$ , а за ним (если надо) подпромежуток простоя  $[t_f, t_e)$ , где  $t_b \leq t$  — это когда система начала работать,  $t_f$  — это когда система перейдёт (ожидается, что перейдёт) снова в нерабочее состояние, потому что задача закончится, и

$$t_e = \max(t_f, \max(d_{disc})),$$

где  $d_{disc}$  — дедлайны задач, от которых придётся отказаться на протяжении  $[t_b, t_f]$ .

- Интервал *замкнутый*, если на нём завершили задачу, *открытый* в противном случае.





# 1/4-оптимальный алгоритм $TD_1$

- Опишем алгоритм  $TD_1$ . Сначала предположим, что у всех нету laxity, т.е. надо сразу решать.
- Алгоритм такой: когда приходит новая задача  $T_{next}$ ,
  - проапдейтить  $\Delta_{run}$  (текущий интервал);
  - если  $v_{run} < \Delta_{run}/4$ , то  $T_{run} = T_{next}$ .
- Т.е. если новая стоимость вчетверо превышает текущий размер интервала, взять новую задачу.

# 1/4-оптимальный алгоритм $TD_1$

- Первая лемма:  $v_k > \frac{\Delta_k}{2}$ .
- Для  $k = 1$   $v_1 = \Delta_1 > \Delta_1/2$ .
- Поскольку  $T_i$  прекращается  $T_{i+1}$ ,  $v_i < \Delta_{i+1}/4$ ,  
 $\Delta_{i+1} < \Delta_i + v_{i+1}$ .

**Упражнение.** Докажите, что тогда  $2v_{i+1} > \Delta_{i+1}$  (по индукции).

# 1/4-оптимальный алгоритм $TD_1$

- Теперь докажем, что на каждом интервале получается не менее четверти от ясновидящего алгоритма.
- Первый случай:  $T_{a_n} = T_k$ , т.е. после  $T_k$  никаких задач не приходило. Тогда просто  $v_k > \frac{\Delta_k}{2} = \frac{\Delta}{2} > \frac{\Delta}{4}$ .
- Второй случай: после  $T_k$  ещё приходили задачи, но были отброшены. Раз были отброшены, значит,  $v_k \geq \frac{\Delta_{a_n}}{4} = \frac{\Delta}{4}$ .

# 1/4-оптимальный алгоритм $TD_1$

- Что делать, когда есть laxities?
- Нужно использовать очередь  $Q$ , в которой лежат ожидающие старта задачи, отсортированные по  $l_i$  (времени самого позднего старта).
- Приходит новая задача, помещается в  $Q$ . Если система свободна, она выполняет первую задачу из  $Q$ .
- Если несвободна, решение принимается, когда наступает самое раннее  $l_i$  из имеющихся.

# 1/4-оптимальный алгоритм $TD_1$

- То есть получается, что первая задача интервала может иметь laxity в момент начала, а остальные уже нет.
- Если алгоритм выполнит первую задачу с ненулевым laxity, а кое-что не выполнит из-за этого (а остальное с нулевым laxity ведь), то ясновидящий алгоритм, может, смог бы задержать первую, выполнить срочные, вернуться к первой...
- Поэтому введём переменную  $pl$  (potential loss) — значение первой задачи в каждом интервале.

# 1/4-оптимальный алгоритм $TD_1$

- Алгоритм теперь такой: когда приходит новая задача, она помещается в  $Q$ .
- Когда система освобождается и  $Q$  непуста,  
 $T_{run} = \text{dequeue}(Q)$ ,  $pl = v_{run}$ .
- Когда система работает и звучит сигнал (наступает  $l$ ; задачи из  $Q$ ):
  - $T_{next} = \text{dequeue}(Q)$ ;  $\text{update}(\Delta_{run})$ .
  - Если  $v_{run} < (\Delta_{run} + pl)/4$ , то  $T_{run} = T_{next}$ .

1/4-оптимальный алгоритм  $TD_1$ 

- Доказательство похоже на предыдущее. Рассмотрим такие же последовательности задач и интервалов  $T_i, T_{a_i}, \Delta_i, \Delta_{a_i}$ .
- Сначала такая же индукция.

**Упражнение.** Докажите, что  $v_k \geq \frac{\Delta_k + pI}{2}$ .

- А затем те же два случая, и так же гарантируется, что  $v_k \geq \frac{\Delta_{a_n} + pI}{4}$ .

# 1/4-оптимальный алгоритм $TD_1$

- Можно это дело немножко обобщить на случай, когда количество одновременных задач ограничено, но мы лучше перейдём к делу, то есть к дизайну механизмов.



# Outline

- 1 Задача распределения
  - Постановка и верхняя оценка
  - Нижняя оценка, равная верхней
  
- 2 **Дизайн механизмов для задачи распределения**
  - **Постановка**
  - **Механизм и его анализ**

# Зачем тут дизайн механизмов

- Вот интересный пример. Рассмотрим три задачи:
  - $r_1 = 0, d_1 = 0.9, c_1 = 0.9, v_1 = 0.9$ ;
  - $r_2 = 0.5, d_2 = 5.5, c_2 = 4, v_2 = 4$ ;
  - $r_3 = 4.8, d_3 = 17, c_3 = 12.2, v_3 = 12.2$ .
- Что делает  $TD_1$ ?

# Зачем тут дизайн механизмов

- Он выполнит  $T_1$ , потом начнёт выполнять  $T_2$ .
- А в момент 4.8, когда надо будет решать про  $T_3$ , он подсчитает, что

$$\frac{t_e - t_b + pl}{4} = \frac{17 - 0.9 + 4}{4} > 4 = v_2,$$

и начнёт выполнять третью задачу.

# Зачем тут дизайн механизмов

- Зачем дизайн механизмов? А вот зачем.
- Пусть тот, кто даёт вторую задачу, соврёт, что его дедлайн  $\hat{d}_2 = 4.7$ .
- Тогда алгоритм рассмотрит вторую задачу в момент 0.7 и предпочтёт её первой, т.к.  $\frac{4.7-0.0+1}{4} > 0.9 = v_1$ .
- И вторая задача успеет завершиться до начала третьей.

# Формулировка

- У нас есть центр и  $N$  агентов, центр не знает  $N$ , агент каждый владеет одной задачей  $i$ .
- Характеристики задачи — это тип агента  $\theta_i$ .
- Во время  $r_i$  агент  $i$  узнаёт свой тип  $\theta_i$  и, начиная с этого момента, может предлагать задачу процессору.
- Он это делает, объявляя  $\hat{\theta}_i = (\hat{r}_i, \hat{d}_i, \hat{c}_i, \hat{v}_i)$ , а затем функция  $g : \Theta \rightarrow \mathcal{O}$  выбирает исход, т.е. расписание.

# Формулировка

- Важно: мы не будем отдавать задачу обратно агенту до его объявленного дедлайна  $\hat{d}_i$ , даже если посчитали раньше
- Это нам поможет для правдивости потом.
- Полезность для каждого агента

$$u_i(g(\hat{\theta}), \theta_i) = v_i \mu(e_i(\hat{\theta}, d_i) \geq c_i) \mu(\hat{d}_i \leq d_i) - p_i(\hat{\theta}),$$

где  $\mu$  — индикатор своего аргумента,  $p_i$  — выплата, которую должен сделать агент,  $e_i$  — сколько процессор на данное время работал над задачей  $i$ .

# Формулировка

- Т.е. агенты квазилинейные.
- Ещё ограничение: агент не может дать длину меньше настоящей, т.к. центр заметит. И не может дать задачу центру до настоящего  $r_i$ , т.к. сам её ещё не знает.
- Т.е. агент даёт  $\hat{\theta}_i = (\hat{r}_i, \hat{d}_i, \hat{c}_i, \hat{v}_i)$ , где  $\hat{r}_i \geq r_i$ ,  $\hat{c}_i \geq c_i$ .

# Формулировка

- Ещё фишка — у нас теперь разные  $c_i$  и  $v_i$ .
- Поэтому надо знать верхнюю оценку на то, каким бывает отношение  $\frac{v_i}{c_i} = \rho$ .
- Отношение называется плотностью; пусть  $\rho_{\min} = 1$  (wlog), а  $\rho_{\max} = k$ .
- Наш механизм будет  $((1 + \sqrt{k})^2 + 1)$ -оптимальным.



# Механизм

- Теперь о механизме. Он не даёт предпочтений имеющейся работе ( $TD_1$  хотел, чтобы новая задача была аж вчетверо лучше).
- Он просто исполняет работу с максимальным приоритетом

$$\hat{v}_i + \sqrt{k}e_i(\hat{\theta}, t)\rho_{\min}.$$

- Когда чья-нибудь работа выполняется, мы с агента берём сумму по правилу «второй цены»: берём минимальное  $v$ , которое он мог бы заявить так, чтобы его работа всё же выполнялась.

# Механизм

- Тогда сразу, как в Викри-аукционах или VCG, автоматически получится рациональность и правдивость относительно стоимостей  $v_i$ .

**Упражнение.** Докажите это.

# Механизм

- Нужно только понять, почему он правдив относительно трёх других параметров:  $r_i$ ,  $c_i$  и  $d_i$ .
- Во-первых, улучшить (уменьшить)  $r_i$  и  $c_i$  мы уже запретили.
- Во-вторых, улучшить (увеличить)  $d_i$  тоже бессмысленно: тогда агенту отдадут работу, когда ему уже поздно.
- Именно для этого нужно было отдавать работу не сразу после выполнения.

**Упражнение.** Придумайте пример, в котором было бы выгодно отодвигать дедлайн, если бы работу выдавали сразу по выполнению.

# Механизм

- Нужно доказать, почему агенту невыгодно ухудшать параметры работы, делать её строже.
- Мы подробно доказывать не будем — много технических деталей, которые мы уже разбирали в других ситуациях.
- Идея такая.

# Механизм

- Если увеличивать длину работы, единственный эффект от этого — задержка выполнения или вообще отказ от выполнения работы (у неё приоритет ухудшается).
- Если приближать дедлайн, можно добиться, что работу раньше сделают, но от этого радости агенту в нашей постановке нет. Но больше шанс, что от работы откажутся.
- Не так очевидно, почему нехорошо отодвигать  $r_i$  (время объявления работы центру).
- Но тоже можно доказать.

# Механизм

- Осталось доказать про нужную степень оптимальности.
- Это делается примерно так же, как в анализе  $TD_1$ .
- Разобьём время на интервалы  $(t_i^o, t_i^c]$ , где во время  $t_i^c$  завершается работа  $i$ , а во время  $t_i^o$  завершается  $t_{i+1}^o$  ( $t_1^o = 0$ ).
- Пусть время  $t_i^b$  — это первое время, когда на интервале  $i$  процессор работает.

# Механизм

- Тогда практически такой же индукцией, как раньше, можно доказать требуемую оценку на интервалы.

**Упражнение.** Докажите по индукции, что

$$t_i^c - t_i^b \geq \left(1 + \frac{1}{\sqrt{k}}\right) v_i.$$

# Механизм

- А затем можно доказать, что в каждом интервале мы не отбрасываем слишком дорогие задачи.

**Упражнение.** Для каждого интервала  $I_i$  и задачи  $j$ , которая была тогда отброшена,


$$v_j \leq (1 + \sqrt{k})v_i.$$



# Механизм

- Дальнейший анализ совсем уж опустим, но в результате получится требуемая оптимальность. :)
- В общем, итог такой: дизайн механизмов помог разработать такую систему, в которой агенты заинтересованы в выполнении своих задач, но врать им при этом незачем.

## Спасибо за внимание!

- Lecture notes и слайды будут появляться на моей homepage:  
`http://logic.pdmi.ras.ru/~sergey/index.php?page=teaching`
- Присылайте любые замечания, решения упражнений, новые численные примеры и прочее по адресам:  
`sergey@logic.pdmi.ras.ru`, `snikolenko@gmail.com`
- Заходите в ЖЖ  [smartnik](#).