

アルゴリズム入門(9) (オンラインアルゴリズム)

宮崎修一
京都大学 学術情報メディアセンター

オンラインアルゴリズム

これまでの問題は、入力が全て分かっているが、解の個数が多いのでしらみつぶしに探すのが難しかった。

例えNP完全問題でも、時間さえ掛ければ最適解が求まる。



オンラインアルゴリズム

入力の一部しか分からないことにより、計算が難しい。時刻とともに入力が次々に与えられる状況で、将来の入力を知らずにその場の判断をしなければならない。

- ・株の売買
- ・新幹線の座席予約
- ・コンピュータ上でのページング
- ・京都市バスの1日乗車券

- ・
- ・
- ・

オンラインアルゴリズムの性能は、**競合比**で表される。

入力 σ を最後まで読んだ後なら、最適解を計算できる
→ $\text{OPT}(\sigma)$

オンラインアルゴリズムAが入力 σ に対して得るコスト
→ $A(\sigma)$

「Aの競合比が c 」とは、全ての σ に対して、

$$\frac{A(\sigma)}{\text{OPT}(\sigma)} \leq c$$

(最小化問題の場合)

$$\frac{\text{OPT}(\sigma)}{A(\sigma)} \leq c$$

(最大化問題の場合)

が成り立つこと。つまり、入力を最後まで見た場合の c 倍以内に常に収めることができること。

例: レンタルスキー問題

これからスキーを始めるが、今後何回スキーに行くか分からない。
スキー板を買うべきか、レンタルすべきか？

- ・買うと5万円。
- ・レンタルすると、1回につき1万円。
- ・買ったスキーは、ずっと使い続けることができる(壊れない)。

戦略1: ずっとレンタルし続ける。

100回行ったとき、100万円。

最初に買っていれば、5万円で済んだ。

$100万/5万 = 20$ 倍悪い。

(つまり競合比は20以上。実際は無限大。)

戦略2: 2回目で買う。

2回しか行かなかったとき、 $1+5=6$ 万円。

レンタルしていれば、2万円で済んだ。

$6万/2万 = 3$ 倍悪い。

(つまり競合比は3以上。)

戦略3: 1~4回の間はレンタル。5回目に行くときに買う。

行く回数が4回以内のとき

行く回数が i 回だったとき

使うのは i 万円

最適解も i 万円 (買うより安い)

→ 全く損をしない。

行く回数が5回以上のとき

使うのは $4+5=9$ 万円

最適は、最初買って5万円

→ 比は $9/5=1.8$

戦略3の競合比は1.8

もっと良いアルゴリズムはあるか？

戦略3が最適アルゴリズムであることを示す。

アルゴリズムとしては、一度買ったならそれ以降それを使うのがまし。
なので、「何回目に買うか」でアルゴリズムは決まる。

$k-1$ 回目までレンタルして、 k 回目に買うとする。

すると、 k 回しか行かないという場合が最悪。

かかったお金は $(k-1)+5=k+4$ 万円

・ $1 \leq k \leq 4$ のとき、最適解は、毎回レンタルして k 万円

$$(k+4)/k = 1 + 4/k \geq 2$$

なので、比が1.8よりも悪くなる。

・ $k \geq 6$ のとき、最適解は、最初買って5万円。

$$(k+4)/5 \geq 2$$

なので、比が1.8よりも悪くなる。

よって $k=5$ が最適。


k サーバ問題

消防車が k 台ある。

火事の起こった場所に1台行かなければならない。

どこで火事が起こるか分からない。(同じ場所で複数回起こることもありうる。)

消防車の総移動距離を最小化する。



直感的に良さそうなもの。

最も近い消防車を行かせる。→ 貪欲アルゴリズム



問題: 貪欲アルゴリズムにとって都合の悪い入力はあるか？

最適解は

有名な予想 (k サーバ予想)

「 k サーバ問題の競合比は k 。」

現段階で知られていること。

k サーバ問題の競合比は $2k-1$ 以下。


k サーバ問題の競合比は k 以上。

2サーバ問題の競合比は2。

限られた要求点(火事になる家)の場合、

k サーバ問題の競合比は k 。

- ・ライン上
- ・木上
- ・要求点が $k+1$ 個しかない場合。
- ・要求点が $k+2$ 個しかない場合。




$k+1$ 個の要求点を用意

● 要求点

■ サーバ

$k=3$ の例



どんなアルゴリズムでも、比が k になってしまう入力列があることを示す。(つまり、要求点が $k+1$ 個しかなくても難しい。) アルゴリズムの動きに合わせて、「意地悪い」入力列を構築していく。

● 要求点
■ サーバ

サーバが k 個で、要求点が $k+1$ 個。
サーバがない要求点がある。
意地悪い入力列では、常にそこを要求する。



i 番目の要求の来た要求点を、 r_i とする。

今の例だと、 r_1 r_2 r_3 r_4 r_5 $d(x, y)$: x と y の距離

2 4 1 2 3

アルゴリズムのコスト \geq

$$d(r_1, r_2) + d(r_2, r_3) + d(r_3, r_4) + \dots + d(r_{n-1}, r_n)$$

これはそんなに自明ではないので、良く考えてみよう。

$$r_2 \rightarrow r_1$$

$$r_3 \rightarrow r_2$$

$$r_4 \rightarrow r_3$$

$$r_5 \rightarrow r_4$$

と動いている。

アルゴリズムに都合の悪い入力が出来たが、それにつられて最適解も悪くなってはダメ。

最適解は、これより少なくとも k 倍良いことを、これから示す。

複数(k 個)のアルゴリズムを同時に走らせる。
それらのうち最良のものは、上記の性質を満たす。

これら k 個のアルゴリズムは、**動作ルール**は皆同じ。
 k 個のサーバの初期配置が違うだけ。

i ステップ目で r_i が要求されたとき、
既にそこにサーバがあれば、何もしない。
なければ、 r_{i-1} から動かす。





※ただし、初期配置では、 r_1 にはサーバがあるものとする。

例

● 要求点

■ サーバ

要求: 2 4 1 2 3



サーバが k 個で、要求点が $k+1$ 個。
「状態」は、どこが空いているかで決まる。




初期配置は $k+1$ 通りあり得る。
しかし、 r_1 には必ずサーバがあることにしているので、
初期配置は k 通り。


■ は状態
(サーバのない場所)

要求: 2 4 1 2 3


アルゴリズム1



アルゴリズム2




アルゴリズム3




要求: 2 4 1 2 3


アルゴリズム1






アルゴリズム2



アルゴリズム3




要求2




要求: 2 (4) 1 2 3


アルゴリズム1






アルゴリズム2



アルゴリズム3




要求4




要求: 2 4 (1) 2 3


アルゴリズム1






アルゴリズム2



アルゴリズム3




↓ 要求1




要求: 2 4 1 (2) 3





アルゴリズム1



アルゴリズム2




アルゴリズム3




要求: 2 4 1 2 (3)


アルゴリズム1






アルゴリズム2



アルゴリズム3



要求3



補題

どの時点においても、アルゴリズムの状態は全て異なる。

(証明)

全てのアルゴリズムは、初期状態が違っている。



「初期状態が違う2つのアルゴリズムは、任意の時点において状態が違う」を示せば、補題の証明は完成する。

(その証明)


初期状態において違うので、第1リクエスト後も違う。

(初期状態において、第1リクエストの来るところには、必ずサーバがあるから。第1リクエスト後は初期状態と同じ。)


第 i リクエスト後に状態が違おうとしよう。
第 $i+1$ リクエスト後にも違おうということを、これから示す。

例えば、第 i リクエスト後が以下のようになっていたとしよう。
次のリクエストがどこに来るかで場合分けする。

アルゴリズムA




アルゴリズムB




- (1) AもBもサーバのある要求点(例えば上記の2)に来る。
AもBも動かさない。
→ $i+1$ 回目のリクエスト後も、状態は異なる。

アルゴリズムA




アルゴリズムB




(2) AもBもサーバのない要求点に来る。
そんな要求点はない。

アルゴリズムA




アルゴリズムB




(3) Aではサーバがないが、Bではサーバのある要求点
(上記の例では1)に来る。

→ Aは動かして、Bは動かさない。


困るのは、上記の例で、Aが3から1に動かす。



アルゴリズムA



アルゴリズムB




しかし、それなら、ルールより、第 i リクエストの要求は3だった。
しかし、Bは第 i リクエスト後には要求点3にサーバを置いていない。
→ 矛盾

(証明終わり)


これら k 個のアルゴリズムを同時に動かす。
そして、総移動距離を考える。

要求: (2) (4) (1) (2) (3)


アルゴリズム1



アルゴリズム2



アルゴリズム3



各ステップにおいて、全てのアルゴリズムの状態が異なるから、
サーバを動かすアルゴリズムは1つだけ。
しかもその距離は、ルールより、 $d(r_{i-1}, r_i)$

k 個のアルゴリズムのコストの総和:

$$d(r_1, r_2) + d(r_2, r_3) + d(r_3, r_4) + \dots + d(r_{n-1}, r_n)$$



少なくとも1つは、コストの総和が

$$\frac{1}{k} (d(r_1, r_2) + d(r_2, r_3) + d(r_3, r_4) + \dots + d(r_{n-1}, r_n))$$

以下。OPTは当然それ以下。

アルゴリズムのコスト \geq

$$d(r_1, r_2) + d(r_2, r_3) + d(r_3, r_4) + \dots + d(r_{n-1}, r_n)$$

したがって、最適解は今考えているアルゴリズムより、少なくとも k 倍は良い。

これで、任意のアルゴリズムの競合比が k 以上であることが示せた。

有名な予想 (k サーバ予想)

「 k サーバ問題の競合比は k 。」

現段階で知られていること。

k サーバ問題の競合比は $2k-1$ 以下。

k サーバ問題の競合比は k 以上。

2サーバ問題の競合比は2。

限られた要求点(火事になる家)の場合、

k サーバ問題の競合比は k 。

・ライン上

・木上

・要求点が $k+1$ 個しかない場合。

・要求点が $k+2$ 個しかない場合。

アルゴリズム Double Coverage (DC)

ルール: 左端のサーバより左に要求が来たら

→左端のサーバを動かす


右端のサーバより右に要求が来たら

→右端のサーバを動かす

2つのサーバの間に要求が来たら


→それら2つのサーバを同じ距離だけ動かす

$k=4$ の例




定理: DCの競合比は k 以下である。

貪欲アルゴリズムの競合比は、ライン上でも無限大



同じ入力にDouble Coverageだと



左のサーバがちょっとずつ近づいてくるので、
右のサーバが「無限に振らされる」ということにはならない。

定理: DCの競合比は k 以下である。

証明に入る前に

解析の基本的な考え方 ... **ならし解析 (Amortized Analysis)**

理想的な状況

1ステップで、

OPTのコストが c \rightarrow アルゴリズムのコストが kc 以下

これが言えれば、競合比が k 以下であることは言える。

しかし、この条件は強すぎる。

例えば

	OPT	アルゴリズム
ステップ1	5	8
ステップ2	2	12
・	11	6
・	9	10
・	2	2
ステップ6	7	10
	36	48

実際の比は $4/3$ なのに、解析では6になってしまう。
(つまり、解析で損をしている)

ならし解析

ならしコスト = アルゴリズムのコスト + ならし分

	OPT	アルゴリズム	ならし分	ならしコスト
ステップ1	5	8	-1	7
ステップ2	2	12	-10	2
・	11	6	10	16
・	9	10	2	12
・	2	2	0	2
ステップ6	7	10	0	10

もちろん、ならしコストをどう定義するかが難しい！

重要なポイント:

- ・ 毎ステップ ならしコスト $\leq 1.5 \times \text{OPT}$ のコスト
- ・ ならし分の合計 ≥ 0
 - アルゴリズムのコストの合計 \leq ならしコストの合計


これから、「アルゴリズムの競合比 ≤ 1.5 」が言える。

定理: DCの競合比は k 以下である。


(証明)

ある時点において、

DCの配置



OPTの配置




このとき、DCとOPT間のサーバ同士の、最小マッチングの重みを M とする。


最小重みマッチングは、左から順に対応させることにより、与えられる。

→ 線は交差しない。

DCの配置




OPTの配置



(見やすいように、上下で対応させているが、実際の「距離」は直線上で測る)

なぜなら、もし交差していたら、交差を解消することで、マッチングの重みは必ず減るから。

DCの配置




OPTの配置

ある時点でのポテンシャル関数 (OPTとDCの配置のみから決まる値) を $T = kM + \Sigma$ とする。

Σ は、DCにおける、2つのサーバ間の距離の総和。 $\rightarrow \binom{k}{2}$ 個の和

ポテンシャル関数の変化を解析する。

$$T = kM + \Sigma$$



(i) $T_{i,1} - T_{(i-1),2} \leq kd_i$ d_i はこの要求に対するOPTのコスト


OPTが動かす番なので、 Σ は変化しない。

M は、マッチングは元のままだとしても、OPTが d_i しか動かないので、 d_i しか増えない。よって全体で kd_i しか増えない。

(ポテンシャル関数は、 M に k が掛かっていることに注意！)

ポテンシャル関数の変化を解析する。

$$T = kM + \Sigma$$




(ii) $T_{i,2} - T_{i,1} \leq -s_i$ s_i はこの要求に対するDCのコスト

つまり、少なくとも s_i は減る

$$(ii) T_{i,2} - T_{i,1} \leq -s_i$$

s_i はこの要求に対するDCのコスト

場合1: 端っこに要求が来る



OPTはそこに既にサーバがある(OPTが動作した後の状態だから)


- ・ M は s_i 減る (DCの動かしたサーバは、一番右だった。
OPTは、少なくとも要求点にはサーバがいる。もしくは、それより右にもいるかもしれない。今動かしたDCのサーバは、
とにかく要求点より右の(OPTの)サーバとマッチしているはず。)
- ・ Σ は $(k-1)s_i$ 増加する。(自分以外の $k-1$ 個のサーバとの距離
が、それぞれ s_i ずつ増えるから。)

↓
全体として s_i 減る。

$$(ii) T_{i,2} - T_{i,1} \leq -s_i$$

s_i はこの要求に対するDCのコスト


場合2:間に要求が来る



$$(ii) T_{i,2} - T_{i,1} \leq -s_i$$

s_i はこの要求に対するDCのコスト

場合2:間に要求が来る

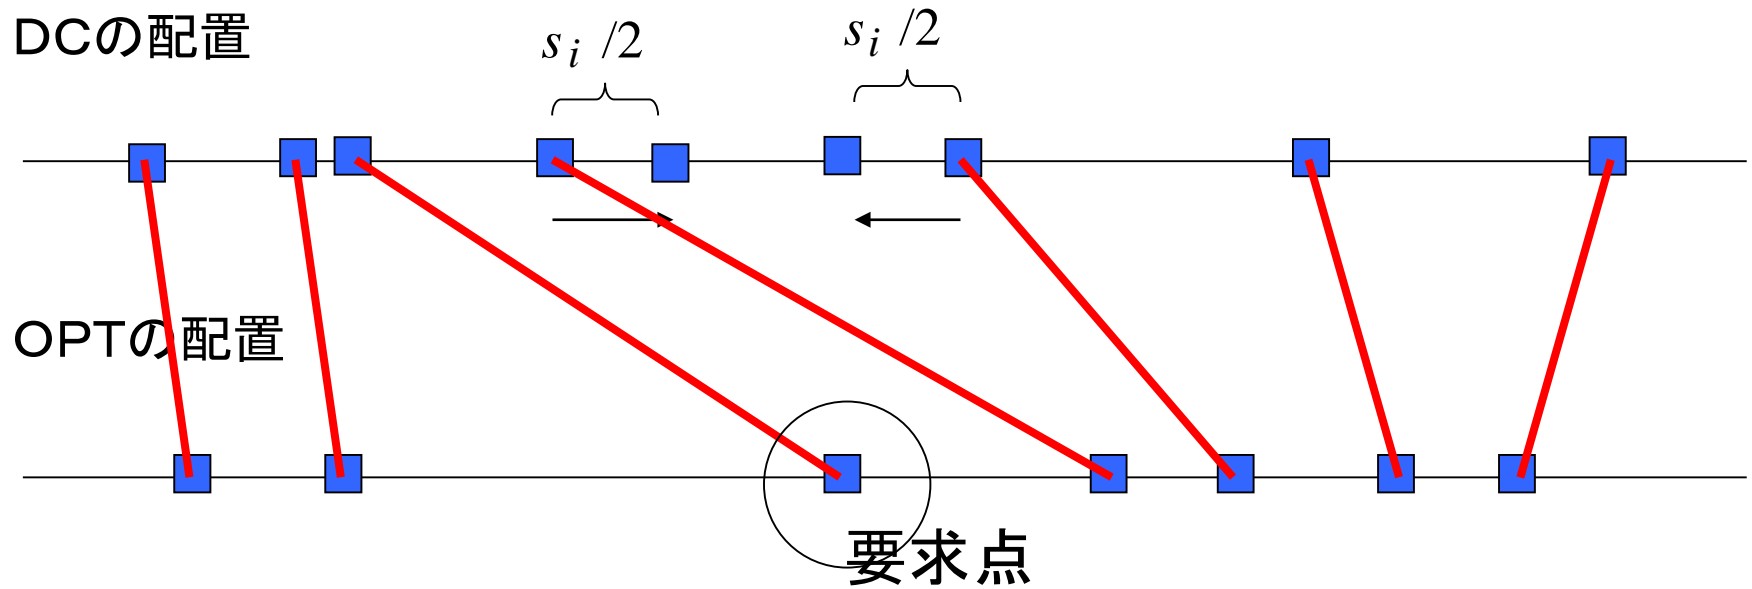


- Σ は、動いた2つのサーバ間は s_i 減る。
それ以外は増えも減りもしない。
(例えば、左にあるサーバだと、1個が $s_i/2$ 遠のいて、もう一個が $s_i/2$ 近づく。つまり、それ対他のサーバの距離の総和は変わらない。)

- M は、動かした2個のうち、1個に関連して必ず $s_i/2$ は減る。
もう1個に関連する分は、増えたとしても高々 $s_i/2$ 。


次ページで、もう少し詳しく見る。

DCの配置



- ・ M は、動かした2個のうち、1個に関連して必ず $s_i/2$ は減る。
もう1個に関連する分は、増えたとしても高々 $s_i/2$ 。

DCの配置




OPTの配置

逆に、両方とも増えらしたら、こんな感じ。
でも、OPTの方が要求点にサーバがないことになるので矛盾。

ここまで証明したことのまとめ

ポテンシャル: $T = kM + \Sigma$



$$(i) T_{i,1} - T_{(i-1),2} \leq kd_i$$

d_i はこの要求に対するOPTのコスト

$$(ii) T_{i,2} - T_{i,1} \leq -s_i$$

s_i はこの要求に対するDCのコスト

(i)と(ii)を足すと

$$T_{i,2} - T_{(i-1),2} \leq kd_i - s_i$$

$$s_i + \boxed{T_{i,2} - T_{(i-1),2}} \leq kd_i$$

↑
ならし分

$$s_i + T_{i,2} - T_{(i-1),2} \leq kd_i$$



i ステップ目でのならしコスト

i ステップ目でのOPTのコストの k 倍

ならしコストの総和

$$\begin{array}{r}
 \cancel{T_{n,2}} - \cancel{T_{(n-1),2}} \\
 \cancel{T_{(n-1),2}} - \cancel{T_{(n-2),2}} \\
 \cancel{T_{(n-2),2}} - \cancel{T_{(n-3),2}} \\
 \vdots \\
 \cancel{T_{2,2}} - \cancel{T_{1,2}} \\
 \cancel{T_{1,2}} - T_0
 \end{array}$$

$$T_{n,2} - T_0$$

$T_{n,2} - T_0$ は n によらない定数。

本当は「ならし分の合計 ≥ 0 」
を言わなければならないのだけど、
競合比の定義ではこれでOK. (省略)

よって、競合比 k が言えた。


(証明終わり)

直接的にやってみると、

$s_i + T_{i,2} - T_{(i-1),2} \leq kd_i$ を全ての*i*について足し合わせると



$$s_1 + s_2 + \cdots + s_n \leq k(d_1 + d_2 + \cdots + d_n) + T_0 - T_{n,2}$$



アルゴリズムの総コスト



OPTの総コスト