

Poravnanje nizova

Seminar iz kolegija *Oblikovanje i analiza algoritama*

Goran Flegar

Prirodoslovno-matematički fakultet
Sveučilište u Zagrebu

20. siječnja 2015.

Sadržaj

Definicija problema

Algoritam za optimalno poravnanje

Algoritam prostorne složenosti $O(n + m)$

Sadržaj

Definicija problema

Algoritam za optimalno poravnanje

Algoritam prostorne složenosti $O(n + m)$

Motivacija

- ▶ Ispravljanje pogrešnog unosa korisnika
 - ▶ Potrebno je u bazi riječi pronaći onu "najsličniju" zadanoj



The image shows a Google search interface. At the top left is the Google logo. To its right is a search bar containing the text "pravnsnje". Below the search bar are navigation tabs: "Web" (highlighted with a red underline), "Karte", "Slike", "Videozapisi", "Više", and "Alati za pretraživanje". Below the tabs, the search results are displayed. The first line of results says "Oko 314.000 rezultata (0,25 sek)". The main part of the results shows a suggestion: "Prikazuju se rezultati za **poravnanje**" where "poravnanje" is in blue and bold. Below this, it says "Umjesto toga pretražite **pravnsnje**".

Motivacija (2)

- ▶ Primjene u bioinformatiči
 - ▶ Određivanje srodstva između dvije vrste na temelju sličnosti njihovih DNA
 - ▶ *Needleman-Wunsch* algoritam

GAATTCAG

| | || |

GGA-TC-G

GAATTCAG

| || | |

GCAT-C-G

GAATTC-A

| | || |

GGA-TCGA

GAATTC-A

| || | |

GCAT-CGA

Definicija poravnanja

- ▶ Zašto su "pravsne" i "poravnanje" slični?
 - ▶ Možemo ih "poravnati" na sljedeći način uz mali broj "razlika"

$$P = \begin{array}{c} p \\ p \end{array} \left| \begin{array}{c} - \\ o \end{array} \right| \begin{array}{c} r \\ r \end{array} \begin{array}{c} a \\ a \end{array} \begin{array}{c} v \\ v \end{array} \begin{array}{c} n \\ n \end{array} \left| \begin{array}{c} s \\ a \end{array} \right| \begin{array}{c} n \\ n \end{array} \begin{array}{c} j \\ j \end{array} \begin{array}{c} e \\ e \end{array}$$

Definicija

Neka su zadani nizovi $x = x_1x_2 \dots x_n$ i $y = y_1y_2 \dots y_m$, ($x_i, y_j \in A$, A je zadani alfabet). Definiramo skupove indeksa $I := \{1 \dots n\}$, $J := \{1 \dots m\}$. Za skup $P \subseteq I \times J$ kažemo da je poravnanje nizova x i y ako vrijedi sljedeće:

1. $\forall (i, j), (i', j') \in P \quad i = i' \Leftrightarrow j = j'$
 - ▶ svaki element jednog niza poravnat je s najviše jednim elementom drugog niza
2. $\forall (i, j), (i', j') \in P \quad i < i' \Leftrightarrow j < j'$
 - ▶ nema "unakrsnog" poravnavanja, tj. zamjene poretka elemenata u nizovima

- ▶ $P = \{(1, 1), (2, 3), (3, 4), (4, 5), (5, 6), (6, 7), \dots, (9, 10)\}$

Definicija poravnanja (2)

- Promotrimo sljedeća dva poravnanja

$$P_1 = \begin{array}{cccccccc} p & - & r & a & v & n & s & n & j & e \\ p & o & r & a & v & n & a & n & j & e \end{array}$$

$$P_2 = \begin{array}{cccccccc} p & r & a & v & n & s & - & n & j & e \\ p & o & r & a & v & n & a & n & j & e \end{array}$$

- 1. poravnanje izgleda bolje
 - Treba nam neka mjera "dobrote" poravnanja

Definicija

Neka je zadana cijena nepodudaranja $\alpha : A \times A \rightarrow \mathbb{R}$ (uobičajeno je $\alpha_{pp} = 0$) i kazna praznine $\delta > 0$. Definiramo cijenu poravnanja P s

$$c(P) = \sum_{(i,j) \in P} \alpha_{x_i y_j} + \delta(n + m - 2|P|).$$

- Ako su zadani $\alpha_{pq} = 1 - \delta_{pq}$ (δ_{ij} je Kroneckerov simbol) i $\delta = 1$ tada je $c(P_1) = 2$ i $c(P_2) = 6$

Problem poravnanja nizova

- ▶ Za zadane nizove x i y , cijenu nepodudaranja α i kaznu praznine δ potrebno je u skupu svih poravnanja \mathcal{P} nizova x i y pronaći optimalno poravnanje P , tj. poravnanje za koje vrijedi $c(P) = \min\{c(P') \mid P' \in \mathcal{P}\}$.

Sadržaj

Definicija problema

Algoritam za optimalno poravnanje

Algoritam prostorne složenosti $O(n + m)$

Svojstva poravnanja

Lema

Neka je $P \subseteq I \times J$ poravnanje nizova $x = x_1x_2 \dots x_n$ i $y = y_1y_2 \dots y_m$. Tada vrijedi barem jedno od sljedećeg:

1. $(n, m) \in P$
2. $(\{n\} \times J) \cap P = \emptyset$
3. $(I \times \{m\}) \cap P = \emptyset$.

Dokaz.

Jedina preostala mogućnost je $(n, j), (i, m) \in P$ za neke $j < m$ i $i < n$, što je kontradikcija s drugim svojstvom iz definicije poravnanja. □

Svojstva poravnanja (2)

Teorem

Neka je zadan problem poravnanja nizova $(x_1 \dots x_n, y_1 \dots y_m, \alpha, \delta)$,
Neka P_{ij} rješenje problema $(x_1 \dots x_i, y_1 \dots y_j, \alpha, \delta)$ i
 $o(i, j) := c(P_{ij})$, $i = 0 \dots n$, $j = 0 \dots m$. Tada je

$$o(i, j) = \min\{o(i-1, j) + \delta, o(i, j-1) + \delta, o(i-1, j-1) + \alpha_{x_i y_j}\}$$
$$o(i, 0) = i\delta, \quad o(0, j) = j\delta$$

za sve $i = 1 \dots n$, $j = 1 \dots m$.

Nadalje, vrijedi sljedeće:

1. Ako je $(i, j) \in P_{ij}$ onda je $P_{ij} \setminus \{(i, j)\}$ rješenje za $(x_1 \dots x_{i-1}, y_1 \dots y_{j-1}, \alpha, \delta)$.
2. Ako je $(\{i\} \times J) \cap P_{ij} = \emptyset$ onda je P_{ij} rješenje za $(x_1 \dots x_{i-1}, y_1 \dots y_j, \alpha, \delta)$.
3. Ako je $(I \times \{j\}) \cap P_{ij} = \emptyset$ onda je P_{ij} rješenje za $(x_1 \dots x_i, y_1 \dots y_{j-1}, \alpha, \delta)$.

Svojstva poravnanja (3)

Ideja dokaza.

1. Kada bi postojalo poravnanje $Q_{i-1,j-1}$ nizova $x_1 \dots x_{i-1}$ i $y_1 \dots y_{j-1}$ takvo da je $c(Q_{i-1,j-1}) < c(P_{ij} \setminus \{(i,j)\})$, vrijedilo bi

$$c(Q_{i-1,j-1} \cup \{(i,j)\}) < c(P_{ij})$$

što je kontradikcija s činjenicom da je P_{ij} optimalno poravnanje. Sada iz $c(P_{ij}) = c(P_{ij} \setminus \{(i,j)\}) + \alpha_{x_i y_j}$ slijedi $o(i,j) = o(i-1, j-1) + \alpha_{x_i y_j}$.

Analogno se pokažu tvrdnje 2. i 3. te da u tom slučaju vrijedi formula $o(i,j) = o(i-1, j) + \delta$, odnosno $o(i,j) = o(i, j-1) + \delta$. Kako je svaki od tih izraza cijena nekog poravnanja, a optimalno poravnanje zadovoljava barem jedan od tih izraza, vrijedi rekurzija iz iskaza teorema. □

Algoritam

- ▶ Na temelju rekurzije iz teorema možemo sastaviti algoritam za računanje $o(i, j)$.
 - ▶ Napravimo $(n + 1) \times (m + 1)$ tablicu u koju ćemo na ij -to mjesto zapisati vrijednost $o(i, j)$
 - ▶ Popunimo prvi redak i prvi stupac tablice koristeći početne uvjete rekurzije
 - ▶ Popunimo ostatak tablice redak po redak (ili stupac po stupac) koristeći rekurziju
 - ▶ Kada računamo $o(i, j)$ u tablici su već izračunati $o(i, j - 1)$, $o(i - 1, j)$ i $o(i - 1, j - 1)$.
- ▶ Složenost?
 - ▶ Vremenska: $\Theta(nm)$
 - ▶ Prostorna: $\Theta(nm)$

Primjer

Pronađite optimalno poravnanje nizova "nizovi" i "izkvui" uz parametre $\alpha_{pq} = 1 - \delta_{pq}$ i $\delta = 1$.

Primjer

$$o(i, 0) = i\delta = i$$

$$o(0, j) = j\delta = j$$

		0	1	2	3	4	5	6
			i	z	k	v	u	i
0		0	1	2	3	4	5	6
1	n	1	?	?	?	?	?	?
2	i	2	?	?	?	?	?	?
3	z	3	?	?	?	?	?	?
4	o	4	?	?	?	?	?	?
5	v	5	?	?	?	?	?	?
6	i	6	?	?	?	?	?	?

Primjer

$$\begin{aligned}o(1, 1) &= \min\{o(1, 0) + \delta, o(0, 1) + \delta, o(0, 0) + \alpha_{ni}\} \\ &= \min\{1 + 1, 1 + 1, 0 + 1\} = 1\end{aligned}$$

		0	1	2	3	4	5	6
			i	z	k	v	u	i
0		0	1	2	3	4	5	6
1	n	1	1	?	?	?	?	?
2	i	2	?	?	?	?	?	?
3	z	3	?	?	?	?	?	?
4	o	4	?	?	?	?	?	?
5	v	5	?	?	?	?	?	?
6	i	6	?	?	?	?	?	?

Primjer

$$\begin{aligned}o(1, 2) &= \min\{o(1, 1) + \delta, o(0, 2) + \delta, o(0, 1) + \alpha_{nz}\} \\ &= \min\{1 + 1, 2 + 1, 1 + 1\} = 2\end{aligned}$$

		0	1	2	3	4	5	6
			i	z	k	v	u	i
0		0	1	2	3	4	5	6
1	n	1	1	2	?	?	?	?
2	i	2	?	?	?	?	?	?
3	z	3	?	?	?	?	?	?
4	o	4	?	?	?	?	?	?
5	v	5	?	?	?	?	?	?
6	i	6	?	?	?	?	?	?

Primjer

$$\begin{aligned}o(1, 3) &= \min\{o(1, 2) + \delta, o(0, 3) + \delta, o(0, 2) + \alpha_{nk}\} \\ &= \min\{2 + 1, 3 + 1, 2 + 1\} = 3\end{aligned}$$

		0	1	2	3	4	5	6
			i	z	k	v	u	i
0		0	1	2	3	4	5	6
1	n	1	1	2	3	?	?	?
2	i	2	?	?	?	?	?	?
3	z	3	?	?	?	?	?	?
4	o	4	?	?	?	?	?	?
5	v	5	?	?	?	?	?	?
6	i	6	?	?	?	?	?	?

Primjer

$$o(1, 4) = \min\{o(1, 3) + \delta, o(0, 4) + \delta, o(0, 3) + \alpha_{nv}\}$$
$$= \min\{3 + 1, 4 + 1, 3 + 1\} = 4$$

		0	1	2	3	4	5	6
			i	z	k	v	u	i
0		0	1	2	3	4	5	6
1	n	1	1	2	3	4	?	?
2	i	2	?	?	?	?	?	?
3	z	3	?	?	?	?	?	?
4	o	4	?	?	?	?	?	?
5	v	5	?	?	?	?	?	?
6	i	6	?	?	?	?	?	?

Primjer

$$\begin{aligned}o(1, 5) &= \min\{o(1, 4) + \delta, o(0, 5) + \delta, o(0, 4) + \alpha_{nu}\} \\ &= \min\{4 + 1, 5 + 1, 4 + 1\} = 5\end{aligned}$$

		0	1	2	3	4	5	6
			i	z	k	v	u	i
0		0	1	2	3	4	5	6
1	n	1	1	2	3	4	5	?
2	i	2	?	?	?	?	?	?
3	z	3	?	?	?	?	?	?
4	o	4	?	?	?	?	?	?
5	v	5	?	?	?	?	?	?
6	i	6	?	?	?	?	?	?

Primjer

$$\begin{aligned}o(1, 6) &= \min\{o(1, 5) + \delta, o(0, 6) + \delta, o(0, 5) + \alpha_{ni}\} \\ &= \min\{5 + 1, 6 + 1, 5 + 1\} = 6\end{aligned}$$

		0	1	2	3	4	5	6
			i	z	k	v	u	i
0		0	1	2	3	4	5	6
1	n	1	1	2	3	4	5	6
2	i	2	?	?	?	?	?	?
3	z	3	?	?	?	?	?	?
4	o	4	?	?	?	?	?	?
5	v	5	?	?	?	?	?	?
6	i	6	?	?	?	?	?	?

Primjer

$$o(2, 1) = \min\{o(2, 0) + \delta, o(1, 1) + \delta, o(1, 0) + \alpha_{ij}\} \\ = \min\{2 + 1, 1 + 1, 1 + 0\} = 1$$

		0	1	2	3	4	5	6
			i	z	k	v	u	i
0		0	1	2	3	4	5	6
1	n	1	1	2	3	4	5	6
2	i	2	1	?	?	?	?	?
3	z	3	?	?	?	?	?	?
4	o	4	?	?	?	?	?	?
5	v	5	?	?	?	?	?	?
6	i	6	?	?	?	?	?	?

Primjer

$$o(2,2) = \min\{o(2,1) + \delta, o(1,2) + \delta, o(1,1) + \alpha_{iz}\}$$
$$= \min\{1 + 1, 2 + 1, 1 + 1\} = 2$$

		0	1	2	3	4	5	6
			i	z	k	v	u	i
0		0	1	2	3	4	5	6
1	n	1	1	2	3	4	5	6
2	i	2	1	2	?	?	?	?
3	z	3	?	?	?	?	?	?
4	o	4	?	?	?	?	?	?
5	v	5	?	?	?	?	?	?
6	i	6	?	?	?	?	?	?

Primjer

$$\begin{aligned}o(2, 3) &= \min\{o(2, 2) + \delta, o(1, 3) + \delta, o(1, 2) + \alpha_{ik}\} \\ &= \min\{2 + 1, 3 + 1, 2 + 1\} = 3\end{aligned}$$

		0	1	2	3	4	5	6
			i	z	k	v	u	i
0		0	1	2	3	4	5	6
1	n	1	1	2	3	4	5	6
2	i	2	1	2	3	?	?	?
3	z	3	?	?	?	?	?	?
4	o	4	?	?	?	?	?	?
5	v	5	?	?	?	?	?	?
6	i	6	?	?	?	?	?	?

Primjer

$$\begin{aligned}o(2, 4) &= \min\{o(2, 3) + \delta, o(1, 4) + \delta, o(1, 3) + \alpha_{iv}\} \\ &= \min\{3 + 1, 4 + 1, 3 + 1\} = 4\end{aligned}$$

		0	1	2	3	4	5	6
			i	z	k	v	u	i
0		0	1	2	3	4	5	6
1	n	1	1	2	3	4	5	6
2	i	2	1	2	3	4	?	?
3	z	3	?	?	?	?	?	?
4	o	4	?	?	?	?	?	?
5	v	5	?	?	?	?	?	?
6	i	6	?	?	?	?	?	?

Primjer

$$\begin{aligned}o(2, 5) &= \min\{o(2, 4) + \delta, o(1, 5) + \delta, o(1, 4) + \alpha_{iu}\} \\ &= \min\{4 + 1, 5 + 1, 4 + 1\} = 5\end{aligned}$$

		0	1	2	3	4	5	6
			i	z	k	v	u	i
0		0	1	2	3	4	5	6
1	n	1	1	2	3	4	5	6
2	i	2	1	2	3	4	5	?
3	z	3	?	?	?	?	?	?
4	o	4	?	?	?	?	?	?
5	v	5	?	?	?	?	?	?
6	i	6	?	?	?	?	?	?

Primjer

$$o(2, 6) = \min\{o(2, 5) + \delta, o(1, 6) + \delta, o(1, 5) + \alpha_{ij}\}$$
$$= \min\{5 + 1, 6 + 1, 5 + 0\} = 5$$

		0	1	2	3	4	5	6
			i	z	k	v	u	i
0		0	1	2	3	4	5	6
1	n	1	1	2	3	4	5	6
2	i	2	1	2	3	4	5	5
3	z	3	?	?	?	?	?	?
4	o	4	?	?	?	?	?	?
5	v	5	?	?	?	?	?	?
6	i	6	?	?	?	?	?	?

Primjer

$$\begin{aligned}o(3, 1) &= \min\{o(3, 0) + \delta, o(2, 1) + \delta, o(2, 0) + \alpha_{zi}\} \\ &= \min\{3 + 1, 1 + 1, 2 + 1\} = 2\end{aligned}$$

		0	1	2	3	4	5	6
			i	z	k	v	u	i
0		0	1	2	3	4	5	6
1	n	1	1	2	3	4	5	6
2	i	2	1	2	3	4	5	5
3	z	3	2	?	?	?	?	?
4	o	4	?	?	?	?	?	?
5	v	5	?	?	?	?	?	?
6	i	6	?	?	?	?	?	?

Primjer

$$\begin{aligned}o(3, 2) &= \min\{o(3, 1) + \delta, o(2, 2) + \delta, o(2, 1) + \alpha_{zz}\} \\ &= \min\{2 + 1, 2 + 1, 1 + 0\} = 1\end{aligned}$$

		0	1	2	3	4	5	6
			i	z	k	v	u	i
0		0	1	2	3	4	5	6
1	n	1	1	2	3	4	5	6
2	i	2	1	2	3	4	5	5
3	z	3	2	1	?	?	?	?
4	o	4	?	?	?	?	?	?
5	v	5	?	?	?	?	?	?
6	i	6	?	?	?	?	?	?

Primjer

$$o(3,3) = \min\{o(3,2) + \delta, o(2,3) + \delta, o(2,2) + \alpha_{zk}\} \\ = \min\{1 + 1, 3 + 1, 2 + 1\} = 2$$

		0	1	2	3	4	5	6
			i	z	k	v	u	i
0		0	1	2	3	4	5	6
1	n	1	1	2	3	4	5	6
2	i	2	1	2	3	4	5	5
3	z	3	2	1	2	?	?	?
4	o	4	?	?	?	?	?	?
5	v	5	?	?	?	?	?	?
6	i	6	?	?	?	?	?	?

Primjer

$$o(3, 4) = \min\{o(3, 3) + \delta, o(2, 4) + \delta, o(2, 3) + \alpha_{zv}\}$$
$$= \min\{2 + 1, 4 + 1, 3 + 1\} = 3$$

		0	1	2	3	4	5	6
			i	z	k	v	u	i
0		0	1	2	3	4	5	6
1	n	1	1	2	3	4	5	6
2	i	2	1	2	3	4	5	5
3	z	3	2	1	2	3	?	?
4	o	4	?	?	?	?	?	?
5	v	5	?	?	?	?	?	?
6	i	6	?	?	?	?	?	?

Primjer

$$o(3, 5) = \min\{o(3, 4) + \delta, o(2, 5) + \delta, o(2, 4) + \alpha_{zu}\}$$
$$= \min\{3 + 1, 5 + 1, 4 + 1\} = 4$$

		0	1	2	3	4	5	6
			i	z	k	v	u	i
0		0	1	2	3	4	5	6
1	n	1	1	2	3	4	5	6
2	i	2	1	2	3	4	5	5
3	z	3	2	1	2	3	4	?
4	o	4	?	?	?	?	?	?
5	v	5	?	?	?	?	?	?
6	i	6	?	?	?	?	?	?

Primjer

$$\begin{aligned}o(3, 6) &= \min\{o(3, 5) + \delta, o(2, 6) + \delta, o(2, 5) + \alpha_{zi}\} \\ &= \min\{4 + 1, 5 + 1, 5 + 1\} = 5\end{aligned}$$

		0	1	2	3	4	5	6
			i	z	k	v	u	i
0		0	1	2	3	4	5	6
1	n	1	1	2	3	4	5	6
2	i	2	1	2	3	4	5	5
3	z	3	2	1	2	3	4	5
4	o	4	?	?	?	?	?	?
5	v	5	?	?	?	?	?	?
6	i	6	?	?	?	?	?	?

Primjer

$$\begin{aligned}o(4, 1) &= \min\{o(4, 0) + \delta, o(3, 1) + \delta, o(3, 0) + \alpha_{oi}\} \\ &= \min\{4 + 1, 2 + 1, 3 + 1\} = 3\end{aligned}$$

		0	1	2	3	4	5	6
			i	z	k	v	u	i
0		0	1	2	3	4	5	6
1	n	1	1	2	3	4	5	6
2	i	2	1	2	3	4	5	5
3	z	3	2	1	2	3	4	5
4	o	4	3	?	?	?	?	?
5	v	5	?	?	?	?	?	?
6	i	6	?	?	?	?	?	?

Primjer

$$\begin{aligned}o(4, 2) &= \min\{o(4, 1) + \delta, o(3, 2) + \delta, o(3, 1) + \alpha_{oz}\} \\ &= \min\{3 + 1, 1 + 1, 2 + 1\} = 2\end{aligned}$$

		0	1	2	3	4	5	6
			i	z	k	v	u	i
0		0	1	2	3	4	5	6
1	n	1	1	2	3	4	5	6
2	i	2	1	2	3	4	5	5
3	z	3	2	1	2	3	4	5
4	o	4	3	2	?	?	?	?
5	v	5	?	?	?	?	?	?
6	i	6	?	?	?	?	?	?

Primjer

$$\begin{aligned}o(4, 3) &= \min\{o(4, 2) + \delta, o(3, 3) + \delta, o(3, 2) + \alpha_{ok}\} \\ &= \min\{2 + 1, 2 + 1, 1 + 1\} = 2\end{aligned}$$

		0	1	2	3	4	5	6
			i	z	k	v	u	i
0		0	1	2	3	4	5	6
1	n	1	1	2	3	4	5	6
2	i	2	1	2	3	4	5	5
3	z	3	2	1	2	3	4	5
4	o	4	3	2	2	?	?	?
5	v	5	?	?	?	?	?	?
6	i	6	?	?	?	?	?	?

Primjer

$$\begin{aligned}o(4, 4) &= \min\{o(4, 3) + \delta, o(3, 4) + \delta, o(3, 3) + \alpha_{ov}\} \\ &= \min\{2 + 1, 3 + 1, 2 + 1\} = 3\end{aligned}$$

		0	1	2	3	4	5	6
			i	z	k	v	u	i
0		0	1	2	3	4	5	6
1	n	1	1	2	3	4	5	6
2	i	2	1	2	3	4	5	5
3	z	3	2	1	2	3	4	5
4	o	4	3	2	2	3	?	?
5	v	5	?	?	?	?	?	?
6	i	6	?	?	?	?	?	?

Primjer

$$\begin{aligned}o(4, 5) &= \min\{o(4, 4) + \delta, o(3, 5) + \delta, o(3, 4) + \alpha_{ou}\} \\ &= \min\{3 + 1, 4 + 1, 3 + 1\} = 4\end{aligned}$$

		0	1	2	3	4	5	6
			i	z	k	v	u	i
0		0	1	2	3	4	5	6
1	n	1	1	2	3	4	5	6
2	i	2	1	2	3	4	5	5
3	z	3	2	1	2	3	4	5
4	o	4	3	2	2	3	4	?
5	v	5	?	?	?	?	?	?
6	i	6	?	?	?	?	?	?

Primjer

$$\begin{aligned}o(4, 6) &= \min\{o(4, 5) + \delta, o(3, 6) + \delta, o(3, 5) + \alpha_{oi}\} \\ &= \min\{4 + 1, 5 + 1, 4 + 1\} = 5\end{aligned}$$

		0	1	2	3	4	5	6
			i	z	k	v	u	i
0		0	1	2	3	4	5	6
1	n	1	1	2	3	4	5	6
2	i	2	1	2	3	4	5	5
3	z	3	2	1	2	3	4	5
4	o	4	3	2	2	3	4	5
5	v	5	?	?	?	?	?	?
6	i	6	?	?	?	?	?	?

Primjer

$$\begin{aligned}o(5, 1) &= \min\{o(5, 0) + \delta, o(4, 1) + \delta, o(4, 0) + \alpha_{vi}\} \\ &= \min\{5 + 1, 3 + 1, 4 + 1\} = 4\end{aligned}$$

		0	1	2	3	4	5	6
			i	z	k	v	u	i
0		0	1	2	3	4	5	6
1	n	1	1	2	3	4	5	6
2	i	2	1	2	3	4	5	5
3	z	3	2	1	2	3	4	5
4	o	4	3	2	2	3	4	5
5	v	5	4	?	?	?	?	?
6	i	6	?	?	?	?	?	?

Primjer

$$\begin{aligned}o(5, 2) &= \min\{o(5, 1) + \delta, o(4, 2) + \delta, o(4, 1) + \alpha_{vz}\} \\ &= \min\{4 + 1, 2 + 1, 3 + 1\} = 3\end{aligned}$$

		0	1	2	3	4	5	6
			i	z	k	v	u	i
0		0	1	2	3	4	5	6
1	n	1	1	2	3	4	5	6
2	i	2	1	2	3	4	5	5
3	z	3	2	1	2	3	4	5
4	o	4	3	2	2	3	4	5
5	v	5	4	3	?	?	?	?
6	i	6	?	?	?	?	?	?

Primjer

$$\begin{aligned}o(5, 3) &= \min\{o(5, 2) + \delta, o(4, 3) + \delta, o(4, 2) + \alpha_{vk}\} \\ &= \min\{3 + 1, 2 + 1, 2 + 1\} = 3\end{aligned}$$

		0	1	2	3	4	5	6
			i	z	k	v	u	i
0		0	1	2	3	4	5	6
1	n	1	1	2	3	4	5	6
2	i	2	1	2	3	4	5	5
3	z	3	2	1	2	3	4	5
4	o	4	3	2	2	3	4	5
5	v	5	4	3	3	?	?	?
6	i	6	?	?	?	?	?	?

Primjer

$$\begin{aligned}o(5, 4) &= \min\{o(5, 3) + \delta, o(4, 4) + \delta, o(4, 3) + \alpha_{vw}\} \\ &= \min\{3 + 1, 3 + 1, 2 + 0\} = 2\end{aligned}$$

		0	1	2	3	4	5	6
			i	z	k	v	u	i
0		0	1	2	3	4	5	6
1	n	1	1	2	3	4	5	6
2	i	2	1	2	3	4	5	5
3	z	3	2	1	2	3	4	5
4	o	4	3	2	2	3	4	5
5	v	5	4	3	3	2	?	?
6	i	6	?	?	?	?	?	?

Primjer

$$\begin{aligned}o(5, 5) &= \min\{o(5, 4) + \delta, o(4, 5) + \delta, o(4, 4) + \alpha_{vu}\} \\ &= \min\{2 + 1, 4 + 1, 3 + 1\} = 3\end{aligned}$$

		0	1	2	3	4	5	6
			i	z	k	v	u	i
0		0	1	2	3	4	5	6
1	n	1	1	2	3	4	5	6
2	i	2	1	2	3	4	5	5
3	z	3	2	1	2	3	4	5
4	o	4	3	2	2	3	4	5
5	v	5	4	3	3	2	3	?
6	i	6	?	?	?	?	?	?

Primjer

$$\begin{aligned}o(5, 6) &= \min\{o(5, 5) + \delta, o(4, 6) + \delta, o(4, 5) + \alpha_{vi}\} \\ &= \min\{3 + 1, 5 + 1, 4 + 1\} = 4\end{aligned}$$

		0	1	2	3	4	5	6
			i	z	k	v	u	i
0		0	1	2	3	4	5	6
1	n	1	1	2	3	4	5	6
2	i	2	1	2	3	4	5	5
3	z	3	2	1	2	3	4	5
4	o	4	3	2	2	3	4	5
5	v	5	4	3	3	2	3	4
6	i	6	?	?	?	?	?	?

Primjer

$$\begin{aligned}o(6, 1) &= \min\{o(6, 0) + \delta, o(5, 1) + \delta, o(5, 0) + \alpha_{ij}\} \\ &= \min\{6 + 1, 4 + 1, 5 + 0\} = 5\end{aligned}$$

		0	1	2	3	4	5	6
			i	z	k	v	u	i
0		0	1	2	3	4	5	6
1	n	1	1	2	3	4	5	6
2	i	2	1	2	3	4	5	5
3	z	3	2	1	2	3	4	5
4	o	4	3	2	2	3	4	5
5	v	5	4	3	3	2	3	4
6	i	6	5	?	?	?	?	?

Primjer

$$\begin{aligned}o(6, 2) &= \min\{o(6, 1) + \delta, o(5, 2) + \delta, o(5, 1) + \alpha_{iz}\} \\ &= \min\{5 + 1, 3 + 1, 4 + 1\} = 4\end{aligned}$$

		0	1	2	3	4	5	6
			i	z	k	v	u	i
0		0	1	2	3	4	5	6
1	n	1	1	2	3	4	5	6
2	i	2	1	2	3	4	5	5
3	z	3	2	1	2	3	4	5
4	o	4	3	2	2	3	4	5
5	v	5	4	3	3	2	3	4
6	i	6	5	4	?	?	?	?

Primjer

$$\begin{aligned}o(6, 3) &= \min\{o(6, 2) + \delta, o(5, 3) + \delta, o(5, 2) + \alpha_{ik}\} \\ &= \min\{4 + 1, 3 + 1, 3 + 1\} = 4\end{aligned}$$

		0	1	2	3	4	5	6
			i	z	k	v	u	i
0		0	1	2	3	4	5	6
1	n	1	1	2	3	4	5	6
2	i	2	1	2	3	4	5	5
3	z	3	2	1	2	3	4	5
4	o	4	3	2	2	3	4	5
5	v	5	4	3	3	2	3	4
6	i	6	5	4	4	?	?	?

Primjer

$$\begin{aligned}o(6, 4) &= \min\{o(6, 3) + \delta, o(5, 4) + \delta, o(5, 3) + \alpha_{iv}\} \\ &= \min\{4 + 1, 2 + 1, 3 + 1\} = 3\end{aligned}$$

		0	1	2	3	4	5	6
			i	z	k	v	u	i
0		0	1	2	3	4	5	6
1	n	1	1	2	3	4	5	6
2	i	2	1	2	3	4	5	5
3	z	3	2	1	2	3	4	5
4	o	4	3	2	2	3	4	5
5	v	5	4	3	3	2	3	4
6	i	6	5	4	4	3	?	?

Primjer

$$\begin{aligned}o(6, 5) &= \min\{o(6, 4) + \delta, o(5, 5) + \delta, o(5, 4) + \alpha_{iu}\} \\ &= \min\{3 + 1, 3 + 1, 2 + 1\} = 3\end{aligned}$$

		0	1	2	3	4	5	6
			i	z	k	v	u	i
0		0	1	2	3	4	5	6
1	n	1	1	2	3	4	5	6
2	i	2	1	2	3	4	5	5
3	z	3	2	1	2	3	4	5
4	o	4	3	2	2	3	4	5
5	v	5	4	3	3	2	3	4
6	i	6	5	4	4	3	3	?

Primjer

$$\begin{aligned}o(6, 6) &= \min\{o(6, 5) + \delta, o(5, 6) + \delta, o(5, 5) + \alpha_{ij}\} \\ &= \min\{3 + 1, 4 + 1, 3 + 0\} = 3\end{aligned}$$

		0	1	2	3	4	5	6
			i	z	k	v	u	i
0		0	1	2	3	4	5	6
1	n	1	1	2	3	4	5	6
2	i	2	1	2	3	4	5	5
3	z	3	2	1	2	3	4	5
4	o	4	3	2	2	3	4	5
5	v	5	4	3	3	2	3	4
6	i	6	5	4	4	3	3	3

Primjer

$$P = \{\}$$

$$3 = \min\{4, 5, \textcircled{3}\}$$

		0	1	2	3	4	5	6
			i	z	k	v	u	i
0		0	1	2	3	4	5	6
1	n	1	1	2	3	4	5	6
2	i	2	1	2	3	4	5	5
3	z	3	2	1	2	3	4	5
4	o	4	3	2	2	3	4	5
5	v	5	4	3	3	2	$\textcircled{3}$	$\textcircled{4}$
6	i	6	5	4	4	3	$\textcircled{3}$	$\textcircled{3}$

Primjer

$$P = \{(6,6)\}$$

$$3 = \min\{\textcircled{3}, 5, 4\}$$

		0	1	2	3	4	5	6
			i	z	k	v	u	i
0		0	1	2	3	4	5	6
1	n	1	1	2	3	4	5	6
2	i	2	1	2	3	4	5	5
3	z	3	2	1	2	3	4	5
4	o	4	3	2	2	$\textcircled{3}$	$\textcircled{4}$	5
5	v	5	4	3	3	$\textcircled{2}$	$\textcircled{3}$	4
6	i	6	5	4	4	3	3	$\textcircled{3}$

Primjer

$$P = \{(6,6)\}$$

$$2 = \min\{4, 4, \textcircled{2}\}$$

		0	1	2	3	4	5	6
			i	z	k	v	u	i
0		0	1	2	3	4	5	6
1	n	1	1	2	3	4	5	6
2	i	2	1	2	3	4	5	5
3	z	3	2	1	2	3	4	5
4	o	4	3	2	$\textcircled{2}$	$\textcircled{3}$	4	5
5	v	5	4	3	$\textcircled{3}$	$\textcircled{2}$	$\textcircled{3}$	4
6	i	6	5	4	4	3	3	$\textcircled{3}$

Primjer

$$P = \{(5, 4), (6, 6)\}$$

$$2 = \min\{3, 3, \textcircled{2}\}$$

		0	1	2	3	4	5	6
			i	z	k	v	u	i
0		0	1	2	3	4	5	6
1	n	1	1	2	3	4	5	6
2	i	2	1	2	3	4	5	5
3	z	3	2	$\textcircled{1}$	$\textcircled{2}$	3	4	5
4	o	4	3	$\textcircled{2}$	$\textcircled{2}$	3	4	5
5	v	5	4	3	3	$\textcircled{2}$	$\textcircled{3}$	4
6	i	6	5	4	4	3	3	$\textcircled{3}$

Primjer

$$P = \{(4, 3), (5, 4), (6, 6)\}$$

$$1 = \min\{3, 3, \textcircled{1}\}$$

		0	1	2	3	4	5	6
			i	z	k	v	u	i
0		0	1	2	3	4	5	6
1	n	1	1	2	3	4	5	6
2	i	2	$\textcircled{1}$	$\textcircled{2}$	3	4	5	5
3	z	3	$\textcircled{2}$	$\textcircled{1}$	2	3	4	5
4	o	4	3	2	$\textcircled{2}$	3	4	5
5	v	5	4	3	3	$\textcircled{2}$	$\textcircled{3}$	4
6	i	6	5	4	4	3	3	$\textcircled{3}$

Primjer

$$P = \{(3, 2), (4, 3), (5, 4), (6, 6)\}$$

$$1 = \min\{3, 2, \textcircled{1}\}$$

		0	1	2	3	4	5	6
			i	z	k	v	u	i
0		0	1	2	3	4	5	6
1	n	$\textcircled{1}$	$\textcircled{1}$	2	3	4	5	6
2	i	$\textcircled{2}$	$\textcircled{1}$	2	3	4	5	5
3	z	3	2	$\textcircled{1}$	2	3	4	5
4	o	4	3	2	$\textcircled{2}$	3	4	5
5	v	5	4	3	3	$\textcircled{2}$	$\textcircled{3}$	4
6	i	6	5	4	4	3	3	$\textcircled{3}$

Primjer

$$P = \{(2, 1), (3, 2), (4, 3), (5, 4), (6, 6)\}$$

		0	1	2	3	4	5	6
			i	z	k	v	u	i
0		0	1	2	3	4	5	6
1	n	1	1	2	3	4	5	6
2	i	2	1	2	3	4	5	5
3	z	3	2	1	2	3	4	5
4	o	4	3	2	2	3	4	5
5	v	5	4	3	3	2	3	4
6	i	6	5	4	4	3	3	3

Primjer

Primjer (nastavak)

Optimalno poravnanje je $P = \{(2, 1), (3, 2), (4, 3), (5, 4), (6, 6)\}$ i $c(6, 6) = c(P) = 3$.

$$\begin{array}{c|c|c|c|c|c|c} n & i & z & o & v & - & i \\ - & i & z & k & v & u & i \end{array}$$

Može i s manje memorije!

- ▶ Cijenu optimalnog poravnanja možemo naći s $\Theta(m)$ memorije
 - ▶ Računanje i -tog retka matrice ovisi samo o $(i - 1)$ -vom retku
 - ▶ Trebamo spremati samo dva retka matrice – trenutni i prethodni
- ▶ Problem
 - ▶ Nemamo dovoljno informacija da rekonstruiramo samo poravnanje

Sadržaj

Definicija problema

Algoritam za optimalno poravnanje

Algoritam prostorne složenosti $O(n + m)$

Još malo teorije

- ▶ Problemu poravnanja nizova (x, y, α, δ) pridružujemo usmjeren utežen graf $G = (V, E, \omega)$

- ▶ $V = (I \cup \{0\}) \times (J \cup \{0\})$

- ▶ $E = E_1 \cup E_2 \cup E_3$

- ▶ $E_1 = \{((i-1, j-1), (i, j)) \mid i \in I, j \in J\}$

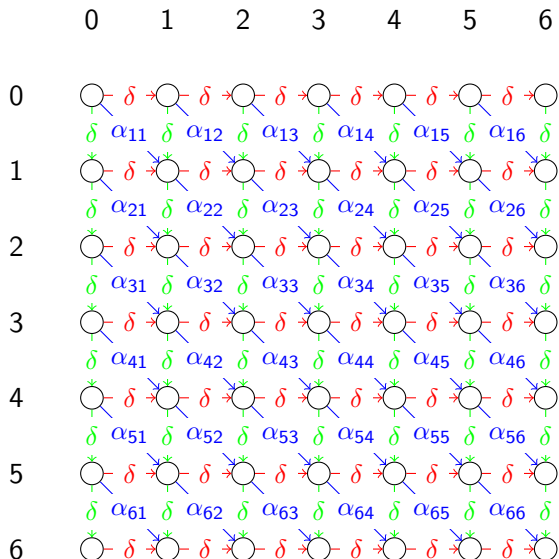
- ▶ $E_2 = \{((i, j-1), (i, j)) \mid i \in I, j \in J\}$

- ▶ $E_3 = \{((i-1, j), (i, j)) \mid i \in I, j \in J\}$

- ▶ $\omega : E \rightarrow \mathbb{R}$

$$\omega(x) = \begin{cases} \delta & , x \in E_2 \cup E_3 \\ \alpha_{x_i y_j} & , x = ((i-1, j-1), (i, j)) \end{cases}$$

Pridružení graf



Veza poravnanja i pridruženog grafa

Teorem

Označimo s $f(i, j)$ najkraći put od čvora $(0, 0)$ do (i, j) . Tada vrijedi

$$f(i, j) = o(i, j), \quad i = 0, \dots, n, j = 0, \dots, m.$$

Posebno, cijena optimalnog poravnanja jednaka je duljini najkraćeg puta od $(0, 0)$ do (n, m) .

Ideja dokaza.

Zadnji brid na najkraćem putu do (i, j) je brid iz jednog od vrhova $(i - 1, j)$, $(i, j - 1)$, $(i - 1, j - 1)$, pa je duljina najkraćeg puta $f(i, j) = \min\{f(i - 1, j) + \delta, f(i, j - 1) + \delta, f(i - 1, j - 1) + \alpha_{x_i y_j}\}$, $(i, j) \in I \times J$. Očito je $f(i, 0) = i\delta$, $i = 0, \dots, n$ i $f(0, j) = j\delta$, $j = 0, \dots, m$, pa f zadovoljava istu rekurziju i iste početne uvjete kao i o . Indukcijom po $i + j$ se pokaže da vrijedi $f(i, j) = o(i, j)$. □

Možemo okrenuti problem

- ▶ Označimo s $g(i, j)$ najkraći put od (i, j) do (n, m)
 - ▶ Prvi brid na tom putu je brid do jednog od vrhova $(i + 1, j), (i, j + 1), (i + 1, j + 1)$
 - ▶ Vrijedi rekurzija:
$$g(i, j) = \min\{g(i+1, j)+\delta, g(i, j+1)+\delta, g(i+1, j+1)+\alpha_{x_{i+1}y_{j+1}}\}$$
 - ▶ Početni uvjeti: $g(i, m) = (n - i)\delta, \quad g(n, j) = (m - j)\delta$
- ▶ Možemo sastaviti algoritam za računanje $g(i, j)$ analogan onom za računanje $o(i, j)$
 - ▶ Verziju koja koristi $\Theta(m)$ memorije

Svojstva f i g

Teorem

Najkraći put od $(0, 0)$ do (n, m) koji prolazi kroz (i, j) ima duljinu $l_{ij} = f(i, j) + g(i, j)$.

Dokaz.

Svaki put od $(0, 0)$ do (n, m) koji prolazi kroz (i, j) se sastoji od nekog puta iz $(0, 0)$ do (i, j) i nekog puta od (i, j) do (n, m) pa je $l_{ij} \geq f(i, j) + g(i, j)$. S druge strane, put koji se sastoji od najkraćeg puta iz $(0, 0)$ do (i, j) i najkraćeg puta od (i, j) do (n, m) je jedan takav put pa je $l_{ij} \leq f(i, j) + g(i, j)$. \square

Svojstva f i g (2)

Teorem

Za svaki $i \in I \cup \{0\}$ postoji $q \in J \cup \{0\}$ takav da najkraći put od $(0, 0)$ do (n, m) prolazi kroz (i, q) .

Posebno, vrijedi $f(n, m) = \min\{f(i, q) + g(i, q) \mid q \in J \cup \{0\}\}$.


Ideja dokaza.

Iz definicije pridruženog grafa vidimo da svaki put od $(0, 0)$ do (n, m) prolazi kroz barem jedan čvor u svakom retku grafa (jedini način da dođemo u i -ti redak je iz $(i - 1)$ -vog retka, formalnije – indukcijom), pa tada i najkraći put prolazi kroz neki čvor i -tog retka grafa. Dakle, q iz teorema postoji. Najkraći put u cijelom grafu je ujedno i najkraći put koji prolazi kroz (i, q) pa vrijedi $f(n, m) = f(i, q) + g(i, q)$ (za q iz tvrdnje teorema). Opet, jer je $f(n, m)$ duljina najkraćeg puta, a $f(i, q') + g(i, q')$ duljina nekog puta, vrijedi $f(n, m) \leq f(i, q') + g(i, q')$, $q \in J \cup \{0\}$, iz čega slijedi druga tvrdnja teorema. □

Ideja algoritma za optimalno poravnanje

- ▶ Promatramo problem

$$A = A(x_1 \dots x_n, y_1 \dots y_m) = (x_1 \dots x_n, y_1 \dots y_m, \alpha, \delta)$$




Ideja algoritma za optimalno poravnanje

- ▶ Promatramo problem

$$A = A(x_1 \dots x_n, y_1 \dots y_m) = (x_1 \dots x_n, y_1 \dots y_m, \alpha, \delta)$$

- ▶ Izaberemo redak i




Ideja algoritma za optimalno poravnanje

- ▶ Promatramo problem

$$A = A(x_1 \dots x_n, y_1 \dots y_m) = (x_1 \dots x_n, y_1 \dots y_m, \alpha, \delta)$$

- ▶ Izaberemo redak i
- ▶ Pronađemo q iz teorema




Ideja algoritma za optimalno poravnanje

- ▶ Promatramo problem

$$A = A(x_1 \dots x_n, y_1 \dots y_m) = (x_1 \dots x_n, y_1 \dots y_m, \alpha, \delta)$$

- ▶ Izaberemo redak i
- ▶ Pronađemo q iz teorema
- ▶ $o(n, m) = f(i, q) + g(i, q)$
- ▶ Podgraf induciran s $(i', j') \leq (i, q)$ – graf za $A_1 = A(x_1 \dots x_i, y_1 \dots y_q)$
- ▶ Podgraf induciran s $(i', j') \geq (i, q)$ – graf za $A_2 = A(x_{i+1} \dots x_n, y_{q+1} \dots y_m)$



Ideja algoritma za optimalno poravnanje (2)

- ▶ Neka je P_1 optimalno poravnanje za A_1 , a P_2 optimalno poravnanje za A_2 .
- ▶ Zbog veze poravnanja i najkraćeg puta u pridruženom grafu je $c(P_1) = f(i, q)$, $c(P_2) = g(i, q)$
- ▶ Definiramo
$$P'_2 = P_2 + (i, q) = \{(i' + i, j' + q) \mid (i', j') \in P_2\}$$
- ▶ $P_1 \cup P'_2$ je poravnanje za A i
$$c_A(P_1 \cup P'_2) = c_{A_1}(P_1) + c_{A_2}(P_2) = f(i, q) + g(i, q) = o(n, m)$$
 - ▶ $P_1 \cup P'_2$ je optimalno poravnanje za A
- ▶ Možemo sastaviti "podijeli pa vladaj" algoritam za računanje poravnanja
- ▶ Oznake
 - ▶ ALIGNDP – algoritam za poravnanje koji već znamo
 - ▶ ALIGNDPM – algoritam koji koristi $\Theta(m)$ memorije
 - ▶ ALIGNDPMR – "okrenuti" algoritam koji koristi $\Theta(m)$ memorije (računa g)

Algoritam za optimalno poravnanje

Algoritam

```
funkcija ALIGNDC( $x, y$ )  
  ako  $\text{LEN}(x) \leq 2$  ili  $\text{LEN}(y) \leq 2$  tada  
    vрати ALIGNDP( $x, y$ )  
  inače  
     $i \leftarrow \lfloor \text{LEN}(x)/2 \rfloor$   
     $f \leftarrow \text{ALIGNDPM}(x[:i], y)$   
     $g \leftarrow \text{ALIGNDPMR}(x[i+1:], y)$   
     $q \leftarrow \text{ARGMIN}(f + g)$   
     $P_1 \leftarrow \text{ALIGNDC}(x[:i], y[:q])$   
     $P_2 \leftarrow \text{ALIGNDC}(x[i+1:], y[q+1:])$   
    vрати  $P_1 \cup (P_2 + (i, q))$   
  
  kraj  
kraj
```


Analiza složenosti

▶ Prostorna složenost

- ▶ Za $n \leq 2$ ili $m \leq 2$ ALIGNDP treba $(2 + 1)(m + 1)$, odnosno $(n + 1)(2 + 1)$ matricu, dakle $3(\max(n, m) + 1)$ brojeva
- ▶ U rekurzivnom slučaju, potrebno je $2(m + 1)$ brojeva za ALIGNDPM, a istu memoriju može koristiti i ALIGNDPMR s time da treba dodatnih $m + 1$ brojeva za pamtiiti potrebne vrijednosti od f
- ▶ Nakon što izračunamo q tih $3(m + 1)$ brojeva nam više ne treba pa tu memoriju mogu koristiti rekurzivni pozivi algoritma
- ▶ Dakle, ukupno nam treba $3(\max(n, m) + 1) \in O(n + m)$ brojeva

Analiza složenosti

- ▶ Vremenska složenost
 - ▶ Iz algoritma se vidi da potrebno vrijeme za $T(n, m)$ zadovoljava sljedeću rekurziju


$$T(n, m) \leq cnm + T\left(\left\lfloor \frac{n}{2} \right\rfloor, q\right) + T\left(n - \left\lfloor \frac{n}{2} \right\rfloor, m - q\right), \quad n, m \geq 2$$

$$T(2, m) \leq cm$$

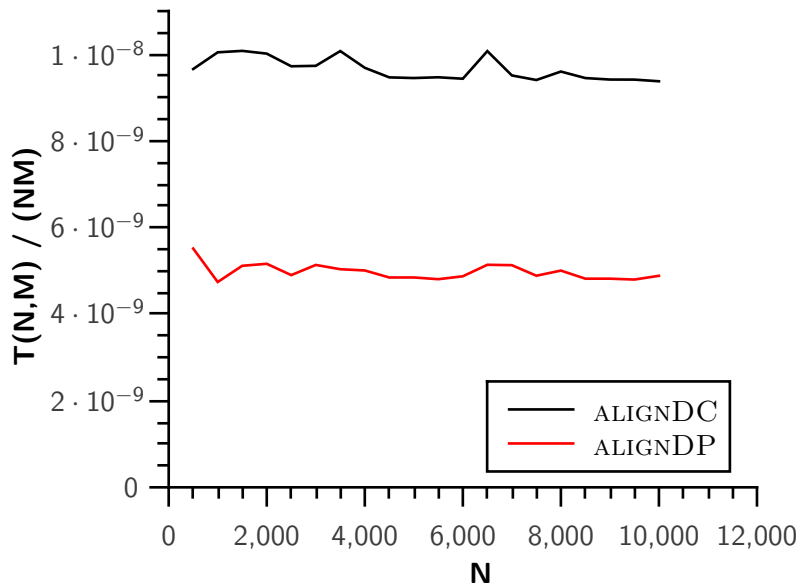
$$T(n, 2) \leq cn$$

- ▶ Konstruktivnom indukcijom po nm se može pronaći k takav da vrijedi $T(n, m) \leq knm$ pa je $T(n, m) \in \Theta(nm)$ – vrijedi za $k \geq 2c$

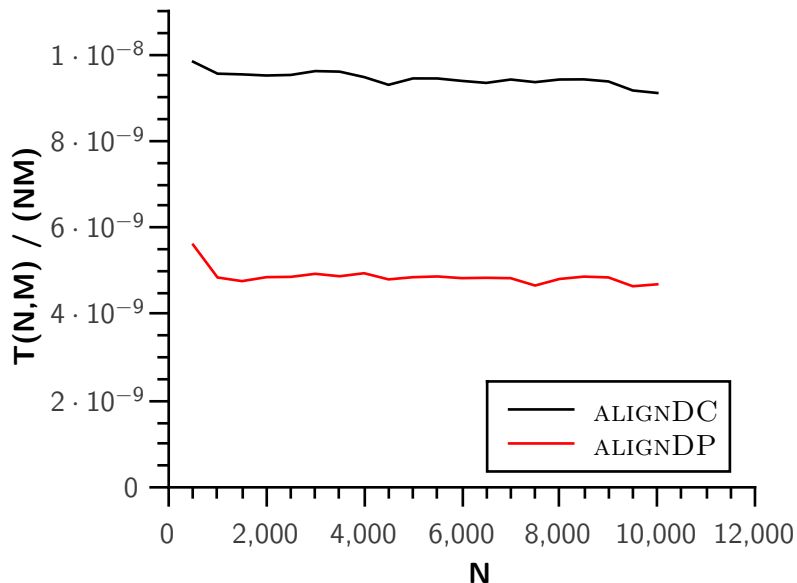
Usporedba algoritama, $M = N$




Usporedba algoritama, $M = N/2$



Usporedba algoritama, $M = N/3$



Literatura

 J. Kleinberg, É. Tardos
Algorithm design
Addison-Wesley, 2006.



Sequence alignment.
Wikipedia, 12.01.2015.