

3. Operaatiojono

TTPPPTLTMP
 indust-ry--
 in---terest

4. Operaatioiden luettelo

industry	$d \rightarrow \epsilon$	intery	$\epsilon \rightarrow e$
inustry	$u \rightarrow \epsilon$	interey	$y \rightarrow s$
instry	$s \rightarrow \epsilon$	interes	$\epsilon \rightarrow t$
intry	$\epsilon \rightarrow e$	interest	

2.2 Editointietäisyyden laskeminen

Määritellään arvot d_{ij} , $0 \leq i \leq m$, $0 \leq j \leq n$, seuraavalla palautuskaavalla:

$$\begin{aligned} d_{00} &= 0, \\ d_{i0} &= i, \quad 1 \leq i \leq m, \\ d_{0j} &= j, \quad 1 \leq j \leq n, \text{ ja} \\ d_{ij} &= \min\{d_{i-1,j-1} + (\text{if } a_i = b_j \text{ then } 0 \text{ else } 1), d_{i-1,j} + 1, d_{i,j-1} + 1\}, \\ &\quad 1 \leq i \leq m, 1 \leq j \leq n. \end{aligned}$$

Lause 2.2.1 $d_{ij} = D(a_1 \cdots a_i, b_1 \cdots b_j)$, kaikilla $0 \leq i \leq m$, $0 \leq j \leq n$.
 Erityisesti $d_{mn} = D(A, B)$.

Todistus. Induktio.

1. Alustus on oikein:

$$\begin{aligned} d_{00} &= D(\epsilon, \epsilon) = 0, \\ d_{i0} &= D(a_1 a_2 \cdots a_i, \epsilon) = |(a_1 \rightarrow \epsilon)(a_2 \rightarrow \epsilon) \cdots (a_i \rightarrow \epsilon)| = i, \\ d_{0j} &= D(\epsilon, b_1 b_2 \cdots b_j) = |(\epsilon \rightarrow b_1)(\epsilon \rightarrow b_2) \cdots (\epsilon \rightarrow b_j)| = j. \end{aligned}$$

2. Induktioaskel:

- Oletetaan, että $d_{i',j'}$ on oikein, kun $i' + j' < i + j$. Tarkastellaan $a_1 a_2 \cdots a_i$:n ja $b_1 b_2 \cdots b_j$:n viimeisten merkkien mahdollisia editointeja. Tapauksia on kolme:

- (i) $a_i \rightarrow b_j$ (muutos tai täsmäys): Lyhimmän tällaisen editointijonon pituus on $d_{i-1,j-1} + (\text{if } a_i = b_j \text{ then } 0 \text{ else } 1)$.
- (ii) $a_i \rightarrow \epsilon$ ja b_j :hin kohdistuu muutos tai täsmäys: Lyhimmän tällaisen editointijonon pituus on $d_{i-1,j} + 1$.
- (iii) $\epsilon \rightarrow b_j$ ja a_i :hin kohdistuu muutos tai täsmäys: Lyhimmän tällaisen editointijonon pituus on $d_{i,j-1} + 1$.
- Tapausta, jossa samanaikaisesti $a_i \rightarrow \epsilon$ ja $\epsilon \rightarrow b_j$ ei tarvitse ottaa huomioon, koska sen pituus on $d_{i-1,j-1} + 2 > d_{i-1,j-1} + 1$.
- Lyhin editointijono $a_1 a_2 \cdots a_i \rightarrow b_1 b_2 \cdots b_j$ on pituudeltaan kohtien (i), (ii) ja (iii) minimi, joten kaava pätee. $\square$

Esimerkki 2.2.2 $A = \text{ballad}, B = \text{handball}$

d		h	a	n	d	b	a	l	l
	0	1	2	3	4	5	6	7	8
b	1	1	2	3	4	4	5	6	7
a	2	2	1	2	3	4	4	5	6
l	3	3	2	2	3	4	5	4	5
l	4	4	3	3	3	4	5	5	4
a	5	5	4	4	4	4	4	5	5
d	6	6	5	5	4	5	5	5	6

$$D(A, B) = d_{mn} = d_{6,8} = 6.$$

Arvojen (d_{ij}) , $0 \leq i \leq m$, $0 \leq j \leq n$, laskenta voidaan toteuttaa *taulukointina* eli käyttämällä ns. *dynaamista ohjelmointia*:

Algoritmi 2.2.3 $D(A, B)$:n laskenta dynaamisella ohjelmoinnilla, perusversio.

Syöte: $A = a_1 a_2 \cdots a_m$, $B = b_1 b_2 \cdots b_n$

Tuloste: Matriisi (d_{ij}) , $0 \leq i \leq m$, $0 \leq j \leq n$, $d_{mn} = D(A, B)$


- (1) **for** $i := 0$ **to** m **do** $d_{i0} := i$ (* alustukset *)
- (2) **for** $j := 1$ **to** n **do** $d_{0j} := j$
- (3) **for** $j := 1$ **to** n **do**
- (4) **for** $i := 1$ **to** m **do**
- (5) $d_{ij} := \min\{d_{i-1,j-1} + (\text{if } a_i = b_j \text{ then } 0 \text{ else } 1), d_{i-1,j} + 1, d_{i,j-1} + 1\}$

- Aikavaatimus on $\Theta(mn)$.


- Suoraviivaisen ratkaisun tilavaatimus on $\Theta(mn)$ (eli matriisin (d_{ij}) vaatima tila).

Tilavaatimus tarkemmin:

- d_{ij} :t riippuvat toisistaan seuraavasti:



- Sarakkeen j arvojen d_{ij} , $1 \leq i \leq m$, laskemiseksi riittää tuntea edellisen sarakkeen $j-1$ arvot $d_{i,j-1}$, $1 \leq i \leq m$. Alustuksen perusteella tiedetään $d_{0j} = j$, josta alaspäin laskenta sujuu edellisen sarakkeen arvojen avulla.
- Tarvitaan työtilaksi taulu $C[0 \dots m]$ ja yksi apumuuttuja C , jotka esittävät vuorossa olevan sarakkeen jo laskettua osaa ja edellisen sarakkeen vielä tarvittavaa osaa:



- $C[0 \dots i-1]$ on sarakkeen j jo laskettu osuus.
- C ja $C[i \dots m]$ muodostavat sarakkeen $j-1$ vielä tarvittavan osuuden.

Algoritmi 2.2.4 $D(A, B)$:n laskenta tilassa $\Theta(m)$.

Syöte: $A = a_1a_2 \cdots a_m$, $B = b_1b_2 \cdots b_n$

Tuloste: $d_{mn} = D(A, B)$

Huom. Kaikki matriisin (d_{ij}) alkiot lasketaan, mutta niitä ei talleteta.

```

(1) for  $i := 0$  to  $m$  do  $C[i] := i$       (* alustus  $j = 0$  *)
(2) for  $j := 1$  to  $n$  do
(3)    $C := C[0]$ ;  $C[0] := j$       (* alustus ( $i = 0$ ) *)
(4)   for  $i := 1$  to  $m$  do
      (* invariantti:  $C = d_{i-1,j-1}$ ,  $C[i-1] = d_{i-1,j}$ ,  $C[i] = d_{i,j-1}$  *)
(5)      $tmp := \min(C + (\text{if } a_i = b_j \text{ then } 0 \text{ else } 1), C[i-1] + 1, C[i] + 1)$ 
(6)      $C := C[i]$       (*  $d_{i,j-1}$  talteen *)
(7)      $C[i] := tmp$ 
(8) write  $C[m]$ 

```

- Aikavaatimus on $\Theta(mn)$, koska $C[0 \dots m]$ täytetään n kertaa. Tilavaatimus on $\Theta(m)$.
- Huomaa, että koska $D(A, B) = D(B, A)$, voidaan Alg. 2.2.4:ssä aina valita jonoksi A lyhyempi verrattavista jonoista, joten $m \leq n$ pätee aina.

Editointietäisyyttä vastaavan operaatiojonon jäljittäminen

- Kuten yleensäkin dynaamisessa ohjelmoinnissa, voidaan haetun optimiratkaisun (tässä: d_{mn}) antavat alkeisaskleet (tässä: editointioperaatiot) selvittää jälkikäteen, kun tulos on laskettu. Tuloksesta d_{mn} peruutetaan kohti alkupistettä d_{00} ja tutkitaan mitä reittiä pitkin minimointi eteni (d_{ij}) :ssä.
- Tämän helpottamiseksi voidaan d_{ij} :hin liittää tieto siitä, mistä alkioista $(d_{i-1,j-1}$, $d_{i-1,j}$ tai $d_{i,j-1}$) siihen päästiin minimoinnissa. Alkion d_{ij} arvo on yksi tai useampi seuraavista:

- (1) $d_{i-1,j-1} + (\text{if } a_i = b_j \text{ then } 0 \text{ else } 1)$
- (2) $d_{i-1,j} + 1$
- (3) $d_{i,j-1} + 1$

- Vastaavat operaatiot ovat

- (1) muutos tai täsmäys: $a_i \rightarrow b_j$,
 - (2) poisto: $a_i \rightarrow \epsilon$ ja
 - (3) lisäys: $\epsilon \rightarrow b_j$.
- Ratkaisun jäljittäminen:
 1. Kun d_{ij} on laskettu (Algoritmissa 2.2.3), talleta kaikilla i, j joukkoon $pred_{ij}$
 - alkio $(i-1, j-1)$, jos (1) pätee,
 - alkio $(i-1, j)$, jos (2) pätee, ja
 - alkio $(i, j-1)$, jos (3) pätee.
 2. Kun d_{mn} on laskettu, seuraa $pred$ -linkkejä d_{00} :aan.

Esimerkki 2.2.5

d	h	a	n	d	b	a	l	l
	$0 \leftarrow 1 \leftarrow 2 \leftarrow 3 \leftarrow 4 \leftarrow 5 \leftarrow 6 \leftarrow 7 \leftarrow 8$							
b	$1 \swarrow$	$1 \leftarrow 2 \leftarrow 3 \leftarrow 4$	$4 \swarrow$	$4 \leftarrow 5 \leftarrow 6 \leftarrow 7$				
a	$2 \swarrow$	$2 \swarrow$	$1 \leftarrow 2 \leftarrow 3 \leftarrow 4$	$4 \swarrow$	$4 \leftarrow 5 \leftarrow 6$			
l	$3 \swarrow$	$3 \swarrow$	$2 \swarrow$	$2 \leftarrow 3 \leftarrow 4 \leftarrow 5$	$4 \swarrow$	$4 \leftarrow 5$		
l	$4 \swarrow$	$4 \swarrow$	$3 \swarrow$	$3 \leftarrow 4 \leftarrow 5$	$5 \swarrow$	$5 \leftarrow 4$	$4 \swarrow$	
a	$5 \swarrow$	$5 \swarrow$	$4 \swarrow$	$4 \leftarrow 4 \leftarrow 4$	$4 \swarrow$	$4 \leftarrow 5 \leftarrow 5$	$5 \swarrow$	$5 \leftarrow 4$
d	$6 \swarrow$	$6 \swarrow$	$5 \swarrow$	$5 \leftarrow 4 \leftarrow 5$	$5 \swarrow$	$5 \leftarrow 5 \leftarrow 6$		

Löydetään 7 ratkaisua (polkua d_{mn} :stä d_{00} :aan), esim.:

LLLLTTTTTPP	MTLMMTLM	MTMMLTML
----ballad	ba-lla-d	ball-ad-
handball--	handball	handball

- Ratkaisuja voi olla siis useita. Sovelluksesta riipuen näillä saattaa vielä olla jokin arvojärjestys.
- Koska Alg. 2.2.4 ei talleta matriisia (d_{ij}), sitä käytettäessä ratkaisua ei voida jäljittää. Usein kuitenkin pelkkä d_{mn} -arvo riittää.

2.3 Hahmon likimääräisten esiintymien etsiminen

G. Navarro. A guided tour to approximate string matching. *ACM Computing Surveys* 33(1):31–88, 2001.

- Olkoon $S = s_1 s_2 \cdots s_n \in \Sigma^*$ *teksti* ja $P = p_1 p_2 \cdots p_m \in \Sigma^*$ *hahmo*.
- Olkoon k jokin kokonaisluku, $0 \leq k \leq m$.

Määritelmä 2.3.1 *Hahmon P likimääräinen esiintymä k virheellä (k differences) on tekstin S osajono X , jolla $D(P, X) \leq k$.*

- Käytännössä usein halutaan vain kaikki esiintymien loppukohdat. Kunkin loppukohtaan voi päättyä useita esiintymiä.

2.3.1 Dynaaminen ohjelmointi

Määritellään arvot g_{ij} , $0 \leq i \leq m, 0 \leq j \leq n$, seuraavasti:

$$\begin{aligned} g_{0j} &= 0, & 0 \leq j \leq n, \\ g_{i0} &= i, & 1 \leq i \leq m, \text{ ja} \\ g_{ij} &= \min\{g_{i-1,j-1} + (\text{if } p_i = s_j \text{ then } 0 \text{ else } 1), g_{i-1,j} + 1, g_{i,j-1} + 1\}, \\ & & 1 \leq i \leq m, 1 \leq j \leq n. \end{aligned}$$

Lause 2.3.2 $g_{ij} = \min\{D(p_1 \cdots p_i, s_\ell \cdots s_j) \mid 1 \leq \ell \leq j+1\}$, kaikilla $0 \leq i \leq m, 0 \leq j \leq n$. Erityisesti j on esiintymän loppukohta, jos ja vain jos $g_{mj} \leq k$.

Todistus. Induktio.

1. Alustus on oikein:

$$\begin{aligned} g_{00} &= D(\epsilon, \epsilon) = 0, \\ g_{0j} &= D(\epsilon, s_{j+1} \cdots s_j) = D(\epsilon, \epsilon) = 0, \\ g_{i0} &= D(p_1 \cdots p_i, \epsilon) = i. \end{aligned}$$

2. Induktioaskel: Kuten lauseessa 2.2.1. □

g_{ij}	r	e	m	a	c	h	i	n	e
	0	0	0	0	0	0	0	0	0
m	1	1	1	0	1	1	1	1	1
a	2	2	2	1	0	1	2	2	2
t	3	3	3	2	1	1	2	3	3
c	4	4	4	3	2	1	2	3	4
h	5	5	5	4	3	2	1	2	3

Algoritmi 2.3.3 *Likimääräinen hahmon sovitus, k virhettä*

Syöte: P, S, k .

Tuloste: P :n likimääräiset esiintymäkohdat k virheellä S :ssä

- (1) **for** $i = 0$ **to** m **do** $g_{i0} := i$
- (2) **for** $j = 1$ **to** n **do**
- (3) $g_{0j} := 0$
- (4) **for** $i := 1$ **to** m **do**
- (5) $g_{ij} := \min\{g_{i-1,j-1} + (\text{if } p_i = s_j \text{ then } 0 \text{ else } 1), g_{i-1,j} + 1, g_{i,j-1} + 1\}$
- (6) **if** $g_{mj} \leq k$ **then** write(j)

- Algoritmin 2.3.3 aikavaatimus on $\mathcal{O}(mn)$ ja tilavaatimus $\mathcal{O}(mn)$.
- Tilavaatimus voidaan pienentää $\mathcal{O}(m)$:ään pitämällä vain yksi sarake muistissa kuten algoritmissa 2.2.4.

Lause 2.3.4 *Likimääräisen hahmonsovitus k virheellä -ongelma voidaan ratkaista Algoritmilla 2.3.3 ajassa $\mathcal{O}(mn)$ ja tilassa $\mathcal{O}(m)$.*

Algoritmi voidaan muuttaa tulostamaan kullekin loppukohdalle myös siihen päättyvän esiintymän alkukohta samassa ajassa ja tilassa.

- Jos $g_{ij} = d$, niin $D(p_1 \cdots p_i, s_t \cdots s_j) = d$ jollakin $t = t_{ij}$. Talletetaan t_{ij} yhdessä g_{ij} :n kanssa.
- t_{ij} on helppo laskea minimoinnin yhteydessä. Esimerkiksi, jos $g_{ij} = g_{i,j-1} + 1$, niin $t_{ij} = t_{i,j-1}$.
- Kaikkia esiintymiä ei kuitenkaan näin löydetä. Ensinnäkin, t_{ij} ei ole välttämättä yksikäsitteinen. Toiseksi, jos $g_{mj} < d \leq k$, algoritmi ei löydä j :hin päättyviä esiintymiä, joiden editointietäisyys hahmosta on d .

2.3.2 Rajoitettu dynaaminen ohjelmointi

E. Ukkonen: Finding approximate pattern in strings. *J. Algorithms* 6:132–137, 1985.

- Matriisin (g_{ij}) rakenteessa on säännönmukaisuus, joka johtaa perusalgoritmeja tehokkaampaan ratkaisuun.
- Matriisin (g_{ij}) *lävistäjään* k , $-m \leq k \leq n$, kuuluvat ne alkiot g_{ij} joilla $j - i = k$.

g_{ij}	r	e	m	a	c	h	i	n	e
	0	0	0	0	0	0	0	0	0
m	1	1	1	0	1	1	1	1	1
a	2	2	2	1	0	1	2	2	2
t	3	3	3	2	1	1	2	3	3
c	4	4	4	3	2	1	2	3	4
h	5	5	5	4	3	2	1	2	3

- Matriisin (g_{ij}) alkioiden arvot voivat ainoastaan pysyä ennallaan tai kasvaa, kun edetään jotakin lävistäjää pitkin. Kun arvo kasvaa, lisäys on aina yksi.
- Editointietäisyyden laskemisessa käytettävällä matriisilla (d_{ij}) on sama ominaisuus.

Lemma 2.3.5 Jokaisella g_{ij} , $1 \leq i \leq m$, $1 \leq j \leq n$: $g_{ij} = g_{i-1,j-1}$ tai $g_{ij} = g_{i-1,j-1} + 1$. (Huomaa, että g_{ij} ja $g_{i-1,j-1}$ ovat samalla lävistäjällä.)

Todistus. Koska g_{ij} on kokonaisluku, ja koska määritelmän mukaan $g_{ij} \leq g_{i-1,j-1} + 1$, riittää osoittaa, että

$$g_{i-1,j-1} \leq g_{ij}.$$

Tämä todistetaan induktiolla $i + j$:n suhteen.

Ainakin yksi seuraavista pätee:

- $g_{ij} = g_{i-1,j-1} + (\text{if } p_i = s_j \text{ then } 0 \text{ else } 1)$. Tällöin $g_{ij} \geq g_{i-1,j-1}$.
- $i = 1$. Tällöin $g_{0,j-1} = 0 \leq g_{1j}$.

(c) $i > 1$ ja $g_{ij} = g_{i-1,j} + 1$. Tällöin pätee

$$g_{ij} = g_{i-1,j} + 1 \geq g_{i-2,j-1} + 1 \geq g_{i-1,j-1}$$

induktio-oletuksen (ensimmäinen $\geq$) ja määritelmän (toinen $\geq$) nojalla. Huomaa, että induktio-oletusta voitiin käyttää, koska $i > 1$.

(d) $g_{ij} = g_{i,j-1} + 1$. Tämä voi tapahtua vain, jos $j > 1$, koska $g_{i,1} \leq g_{i-1,0} + 1 < g_{i,0} + 1$. Tällöin pätee

$$g_{ij} = g_{i,j-1} + 1 \geq g_{i-1,j-2} + 1 \geq g_{i-1,j-1}.$$

□

Tämän ominaisuuden avulla (g_{ij}) :n laskentaa voidaan rajoittaa k virhettä -ongelmassa:

- Pidetään kirjaa siitä, missä kullakin sarakkeella $g_{*,j}$ on viimeinen g_{ij} , joka on korkeintaan k . Silloin sarakkeella $g_{*,j+1}$ voi olla arvoja, jotka ovat korkeintaan k , vain riveillä $0, \dots, i+1$. Niitä pitemmälle ei kannata laskea.
- Merkataan $top[j] = \max\{i \mid i \leq m \text{ ja } g_{i,j} = k\}$. Tällöin $top[j+1] \leq top[j] + 1$.

Algoritmi 2.3.6 *Likimääräinen hahmon sovitus, rajoitettu versio*

Syöte: P, S, k .

Tuloste: P :n likimääräiset esiintymäkohdat k virheellä S :ssä.

```

(1) for  $i = 0$  to  $\min(k+1, m)$  do  $g_{i0} := i$ 
(2)  $top := \min(k+1, m)$       (*  $top[0] = \min(k, m)$  *)
(3) for  $j = 1$  to  $n$  do
(4)    $g_{0j} := 0$ 
(5)   for  $i := 1$  to  $top$  do
(6)      $g_{ij} := \min\{g_{i-1,j-1} + (\text{if } p_i = s_j \text{ then } 0 \text{ else } 1), g_{i-1,j} + 1, g_{i,j-1} + 1\}$ 
(7)   while  $g_{top,j} > k$  do  $top := top - 1$       (* löydetään  $top[j]$  *)
(8)   if  $top = m$  then  $write(j)$ 
(9)   else
(10)     $top := top + 1$ 
(11)     $g_{top,j} := \infty$       (* alustus seuraavaa saraketta varten *)
```

$k = 1$	g_{ij}	r e m a c h i n e									
		0	0	0	0	0	0	0	0	0	0
	m	1	1	1	0	1	1	1	1	1	1
	a	2	2	2	1	0	1	2	2	2	2
	t	3	3	3	2	1	1	2	3	3	3
	c	4	4	4	3	2	1	2	3	4	4
	h	5	5	5	4	3	2	1	2	3	4

- Algoritmin 2.3.6 aikavaatimus on verrannollinen lasketun (g_{ij}) :n osan pinta-alaan.
- Jos S ja P ovat satunnaisia, voidaan osoittaa, että keskimääräinen aikavaatimus on $\mathcal{O}(kn)$.
- Tilavaatimus $\mathcal{O}(m)$ saavutetaan pitämällä vain yksi sarake muistissa.

Lause 2.3.7 *Likimääräinen hahmonsovitus k virheellä -ongelma voidaan ratkaista Algoritmillä 2.3.6 keskimäärin ajassa $\mathcal{O}(kn)$ ja tilassa $\mathcal{O}(m)$.*

Todistus. Katso

W. Chang & J. Lampe: Theoretical and empirical comparisons of approximate string matching algorithms. Proc. 3rd Symposium on Combinatorial Pattern Matching (CPM), LNCS 644, Springer, 1992, 175–184.

□

- Algoritmi 2.3.6 toimii hyvin käytännössä, jos k on pieni.
- Chang & Lampe esittävät toisenlaisen algoritmin, joka toimii keskimäärin ajassa $\mathcal{O}(kn)$.
- Lävistäjälemmaan perustuen on kehitetty useita likimääräisen hahmonsovituksen algoritmeja, joiden aikavaatimus on $\mathcal{O}(kn)$ pahimmasakin tapauksessa (eikä vain keskimäärin), esim.

G. Landau & U. Vishkin: Fast string matching with k differences. *J. Comput. Syst. Sci.* 37:63–78, 1988.

2.4 Myersin bittirinnakkainen algoritmi

G. Myers. A fast bit-vector algorithm for approximate pattern matching based on dynamic programming. *JACM* 46(3):395–415, 1999.

- Nopeutetaan matriisin (g_{ij}) laskentaa soveltamalla bittirinnakkaisuutta. Rajoitumme lyhyisiin hahmoihin, joilla matriisin sarake voidaan käsitellä yhdessä sanassa.
- Matriisi (g_{ij}) esitetään muodossa, jossa talletetaan solujen arvojen sijasta kahden vierekkäisen solun erotus.
- Määritellään *vaakaero* (horizontal delta) $\Delta h_{ij} = g_{ij} - g_{i,j-1}$ ja *pystyero* (vertical delta) $\Delta v_{ij} = g_{ij} - g_{i-1,j}$.
- Koska $g_{i0} = i$ ja $g_{0j} = 0$, pätee

$$\begin{aligned} g_{ij} &= \Delta v_{1j} + \Delta v_{2j} + \cdots + \Delta v_{ij} \\ &= i + \Delta h_{i1} + \Delta h_{i2} + \cdots + \Delta h_{ij} \end{aligned}$$

- Kaikki arvot Δh_{ij} ja Δv_{ij} voidaan esittää kahdella bitillä, mikä seuraa Lemmasta 2.4.1.

Lemma 2.4.1 *Kaikilla i, j on voimassa $\Delta h_{ij}, \Delta v_{ij} \in \{-1, 0, 1\}$.*

- Laskenta etenee sarakkeittain


$$\Delta v_{*0} \rightarrow \Delta h_{*1} \rightarrow \Delta v_{*1} \rightarrow \Delta h_{*2} \rightarrow \cdots$$

- Lisäksi lasketaan viimeisen rivin arvot $sc_j = g_{mj}$, $0 \leq j \leq n$, kaavoilla $sc_0 = m$ ja $sc_j = sc_{j-1} + \Delta h_{mj}$.

Esimerkki 2.4.2 Vaaka- ja pystyerot hahmolle *match* ja tekstille *remachine* (-1 ja 1 on korvattu symboleilla $-$ ja $+$).

		r	e	m	a	c	h	i	n	e
m	0	0	0	0	0	0	0	0	0	0
	+		+		0		+		+	
a	1	0	1	0	1	-	0	1	0	1
	+		+		+		-		0	
t	2	0	2	0	2	-	1	-	0	2
	+		+		+		+		0	
c	3	0	3	0	3	-	2	-	1	0
	+		+		+		+		0	
h	4	0	4	0	4	-	3	-	2	1
	+		+		+		+		+	
	5	0	5	0	5	-	4	-	3	2

- Dynaamisen ohjelmoinnin matriisin solun g_{ij} laskemiseen tarvitaan soluja $g_{i-1,j}$, $g_{i-1,j-1}$ ja $g_{i,j-1}$. Näihin liittyy kaksi pystyeroa $\Delta v^{\text{in}} = \Delta v_{i,j-1}$ ja $\Delta v^{\text{out}} = \Delta v_{i,j}$ sekä kaksi vaakaeroa $\Delta h^{\text{in}} = \Delta h_{i,j-1}$ ja $\Delta h^{\text{out}} = \Delta h_{i,j}$.
- Todistuksessa (mutta ei laskennassa) käytetään lisäksi arvoa $\Delta d = g_{ij} - g_{i-1,j-1}$.



- Lisäksi määritellään, että $Eq = Eq_{ij}$ on 1 , jos $p_i = s_j$, muutoin 0 .
- Kuvataan laskenta funktiona, jonka argumentteina ovat $\Delta v^{\text{in}}, \Delta h^{\text{in}}$ ja Eq sekä tuloksina $\Delta d, \Delta v^{\text{out}}$ ja Δh^{out} .

Lemma 2.4.3 Jos $Eq = 1$ tai $\Delta v^{\text{in}} = -1$ tai $\Delta h^{\text{in}} = -1$, niin pätee $\Delta d = 0$, $\Delta v^{\text{out}} = -\Delta h^{\text{in}}$ ja $\Delta h^{\text{out}} = -\Delta v^{\text{in}}$. Muuten $\Delta d = 1$, $\Delta v^{\text{out}} = 1 - \Delta h^{\text{in}}$ ja $\Delta h^{\text{out}} = 1 - \Delta v^{\text{in}}$.

Todistus.

- g_{ij} :n palautuskaava voidaan kirjoittaa muotoon:

$$\begin{aligned} g_{ij} &= \min\{g_{i-1,j-1} + (\text{if } p_i = s_j \text{ then } 0 \text{ else } 1), g_{i,j-1} + 1, g_{i-1,j} + 1\} \\ &= g_{i-1,j-1} + \min\{1 - Eq, \Delta v^{\text{in}} + 1, \Delta h^{\text{in}} + 1\}. \end{aligned}$$

- Merkitään $\Delta d = g_{ij} - g_{i-1,j-1} = \min\{1 - Eq, \Delta v^{\text{in}} + 1, \Delta h^{\text{in}} + 1\}$. Siis $\Delta d = 0$, jos $Eq = 1$ tai $\Delta v^{\text{in}} = -1$ tai $\Delta h^{\text{in}} = -1$. Muuten $\Delta d = 1$.
- Selvästi $\Delta d = \Delta v^{\text{in}} + \Delta h^{\text{out}} = \Delta h^{\text{in}} + \Delta v^{\text{out}}$, mistä saadaan $\Delta v^{\text{out}} = \Delta d - \Delta h^{\text{in}}$ ja $\Delta h^{\text{out}} = \Delta d - \Delta v^{\text{in}}$.

□

Arvot Eq_{ij} ja Δd ovat bittejä mutta Δv_{ij} ja Δh_{ij} ovat "trittejä". Siirrytään nyt laskemaan kokonaan biteillä. Samalla siirrytään aritmeettisista loogisiin operaatioihin tulkinalla 0 on epätosi ja 1 on tosi.

- Esitetään Δv_{ij} kahdella bitillä Pv_{ij} ja Mv_{ij} , joista edellinen on 1, jos $\Delta v_{ij} = 1$, ja vastaavasti jälkimmäinen on 1, jos $\Delta v_{ij} = -1$. Esitetään Δh_{ij} vastaavasti kahdella bitillä Ph_{ij} ja Mh_{ij} . Tällöin

$$\begin{aligned} \Delta v_{ij} &= Pv_{ij} - Mv_{ij} \\ \Delta h_{ij} &= Ph_{ij} - Mh_{ij} \end{aligned}$$

Lemma 2.4.4

$$\begin{aligned} Pv^{\text{out}} &= Mh^{\text{in}} \vee \neg(Xv \vee Ph^{\text{in}}) \\ Mv^{\text{out}} &= Ph^{\text{in}} \wedge Xv \\ Ph^{\text{out}} &= Mv^{\text{in}} \vee \neg(Xh \vee Pv^{\text{in}}) \\ Mh^{\text{out}} &= Pv^{\text{in}} \wedge Xh \end{aligned}$$

missä $Xv = Eq \vee Mv^{\text{in}}$ ja $Xh = Eq \vee Mh^{\text{in}}$.

Todistus. Symmetrian vuoksi riittää osoittaa väite Pv :lle ja Mv :lle.

- Lemman 2.4.3 mukaan

$$\begin{aligned} Pv^{\text{out}} &= (\neg \Delta d \wedge Mh^{\text{in}}) \vee (\Delta d \wedge \neg Ph^{\text{in}}) \\ Mv^{\text{out}} &= (\neg \Delta d \wedge Ph^{\text{in}}) \vee (\Delta d \wedge 0) = \neg \Delta d \wedge Ph^{\text{in}} \end{aligned}$$

- Koska $\Delta d = \neg(Eq \vee Mv^{\text{in}} \vee Mh^{\text{in}}) = \neg(Xv \vee Mh^{\text{in}}) = \neg Xv \wedge \neg Mh^{\text{in}}$, pätee

$$\begin{aligned}
Pv^{\text{out}} &= ((Xv \vee Mh^{\text{in}}) \wedge Mh^{\text{in}}) \vee (\neg Xv \wedge \neg Mh^{\text{in}} \wedge \neg Ph^{\text{in}}) \\
&= Mh^{\text{in}} \vee \neg(Xv \vee Mh^{\text{in}} \vee Ph^{\text{in}}) \\
&= Mh^{\text{in}} \vee \neg(Xv \vee Ph^{\text{in}}) \\
Mv^{\text{out}} &= (Xv \vee Mh^{\text{in}}) \wedge Ph^{\text{in}} \\
&= Xv \wedge Ph^{\text{in}}
\end{aligned}$$

Viimeisessä askeleessa on hyödynnetty tietoa, että Mh^{in} ja Ph^{in} eivät voi olla 1 samanaikaisesti.

□

Lemman perusteella koko matriisin bittiesitys voidaan laskea seuraavalla algoritmilla:

```

for  $i := 1$  to  $m$  do
   $Pv_{i0} := 1$ ;  $Mv_{i0} := 0$ 
for  $j := 1$  to  $n$  do
   $Ph_{0j} := 0$ ;  $Mh_{0j} := 0$ 
  for  $i := 1$  to  $m$  do
     $Xh_{ij} := Eq_{ij} \vee Mh_{i-1,j}$ 
     $Ph_{ij} := Mv_{i,j-1} \vee \neg(Xh_{ij} \vee Pv_{i,j-1})$ 
     $Mh_{ij} := Pv_{i,j-1} \wedge Xh_{ij}$ 
  for  $i := 1$  to  $m$  do
     $Xv_{ij} := Eq_{ij} \vee Mv_{i,j-1}$ 
     $Pv_{ij} := Mh_{i-1,j} \vee \neg(Xv_{ij} \vee Ph_{i-1,j})$ 
     $Mv_{ij} := Ph_{i-1,j} \wedge Xv_{ij}$ 

```

Tämä algoritmi ei ole vielä aiempaa tehokkaampi, mutta sen sisäilmukat voidaan bittirinnakkaistaa.

- Talletetaan sarakkeet Pv_{*j} , Mv_{*j} , Ph_{*j} , Mh_{*j} ja Eq_{*j} kukin yhteen bittivektoriin. Oletetaan, että $m \leq w$ ja vektoreissa on bitit positioissa $1, \dots, m$.¹
- Jälkimmäinen sisäilmukka voidaan nyt suorittaa seuraavasti:

¹ Algoritmissa viitataan Ph - ja Mh -vektoreiden 0-bittiin, mutta niiden arvo on aina 0, mikä tulee siirto-operaatiossa oikein huomioonotetuksi.

$$\begin{aligned}
Xv_{*j} &:= Eq_{*j} \vee Mv_{*,j-1} \\
Pv_{*j} &:= (Mh_{*,j} << 1) \vee \neg(Xv_{*j} \vee (Ph_{*j} << 1)) \\
Mv_{*j} &:= (Ph_{*j} << 1) \wedge Xv_{*j}
\end{aligned}$$

Tässä on käytetty siirto-operaatiota $B << 1$, joka siirtää bittivektorissa B bitin kohdasta $i-1$ kohtaan i kaikilla $1 < i \leq |B|$ (ja asettaa $B_1 = 0$).

- Ensimmäisen silmukan bittirinnakkaistus aiheuttaa kuitenkin ongelman:

$$\begin{aligned}
Xh_{*j} &:= Eq_{*j} \vee (Mh_{*j} << 1) \\
Ph_{*j} &:= Mv_{*,j-1} \vee \neg(Xh_{*j} \vee Pv_{*,j-1}) \\
Mh_{*j} &:= Pv_{*,j-1} \wedge Xh_{*j}
\end{aligned}$$

Nyt vektoria Mh_{*j} käytetään Xh_{*j} :n laskemiseen ennen kuin se on laskettu. Laskentajärjestyksen muutos ei auta, koska Xh_{*j} :tä käytetään puolestaan Mh_{*j} :n laskemiseen.

- Kehästä päästään ulos laskemalla Xh_{*j} ilman Mh_{*j} :tä tai muita vasta myöhemmin arvonsa saavia bittivektoreita. Seuraava lemma määrittelee Xh_{*j} :n vektoreiden Eq_{*j} ja $Pv_{*,j-1}$ avulla.

Lemma 2.4.5

$$Xh_{ij} = \exists \ell \in [1, i] : Eq_{\ell j} \wedge (\forall x \in [\ell, i-1] : Pv_{x,j-1}).$$

Todistus. Todistetaan väite induktiolla i :n suhteen.

- Lemman 2.4.4 mukaan

$$\begin{aligned}
Xh_{ij} &= Eq_{ij} \vee Mh_{i-1,j} \\
Mh_{ij} &= Pv_{i,j-1} \wedge Xh_{ij}
\end{aligned}$$

- Alustus $i = 1$: Oikea puoli kutistuu muotoon Eq_{1j} . Koska $Mh_{0j} = 0$ kaikilla j , pätee $Xh_{1j} = Eq_{1j} \vee Mh_{0j} = Eq_{1j}$.
- Induktioaskel: Oletetaan, että $Xh_{i-1,j}$ on väitteen mukainen.

$$\begin{aligned}
Xh_{ij} &= Eq_{ij} \vee Mh_{i-1,j} \\
&= Eq_{ij} \vee (Pv_{i-1,j-1} \wedge Xh_{i-1,j})
\end{aligned}$$

Toisaalta

$$\begin{aligned} & \exists \ell \in [1, i] : Eq_{\ell j} \wedge (\forall x \in [\ell, i-1] : Pv_{x,j-1}) \\ &= Eq_{ij} \vee \exists \ell \in [1, i-1] : Eq_{\ell j} \wedge (\forall x \in [\ell, i-1] : Pv_{x,j-1}) \\ &= Eq_{ij} \vee (Pv_{i-1,j-1} \wedge \exists \ell \in [1, i-1] : Eq_{\ell j} \wedge (\forall x \in [\ell, i-2] : Pv_{x,j-1})) \end{aligned}$$

Väite seuraa nyt induktio-oletuksesta.

□

Lemman 2.4.5 kaava näyttää mahdottomalta laskea vakioajassa edes yhdelle bitille, saati sitten bittirinnakkaisesti koko vektorille Xh_{*j} . Se on kuitenkin mahdollista, mutta bittioperaatioita tarvitaan lisää:

- Merkitään xor-operaatiota symbolilla $\vee$: $0 \vee 1 = 1 \vee 0 = 1$ ja $0 \vee 0 = 1 \vee 1 = 0$.
- Tulkitaan bittivektorit kokonaislukujen bittiesitykseksi siten, että vähiten merkitsevä bitti on positiossa 1. Bitit listataan eniten merkitsevästä alkaen. Esimerkiksi $B_{1\dots m} = B_m B_{m-1} \dots B_1$.
- Käytetään yhteenlaskua bittioperaationa. Esim. $0001 + 0111 = 1000$.

Lemma 2.4.6 *Merkitään $X = Xh_{*j}$, $E = Eq_{*j}$, $P = Pv_{*,j-1}$ ja olkoon $Y = (((E \wedge P) + P) \vee P) \vee E$. Tällöin $X = Y$.*

Todistus. Kirjoitetaan X_i :n määritelmä ensin toiseen muotoon:

- $X_i = 1$, jos ja vain jos
 - $E_i = 1$ tai
 - $\exists \ell \in [1, i] : E_{\ell\dots i} = 00\dots 01 \wedge P_{\ell\dots i-1} = 11\dots 1$.
- $X_i = 0$, jos ja vain jos
 - $E_{1\dots i} = 00\dots 0$ tai
 - $\exists \ell \in [1, i] : E_{\ell\dots i} = 00\dots 01 \wedge P_{\ell\dots i-1} \neq 11\dots 1$.

Osoitetaan tapauskohtaisesti, että $Y_i = X_i$:

- Y :n määritelmän loppu “ $\vee E$ ” takaa, että $Y_i = 1$.

- b) Olkoon $\mathbf{b}$ bitti P_i eli $P_{\ell \dots i} = \mathbf{b}11 \dots 1$ ja $\mathbf{c}$ bittien $1 \dots, \ell - 1$ yhteenlaskusta mahdollisesti tuleva muistibitti.

$$\begin{array}{rcl}
 & i & \ell \\
 E_{\ell \dots i} & = & 00 \dots 01 \\
 P_{\ell \dots i} & = & \mathbf{b}1 \dots 11 \\
 (E \wedge P)_{\ell \dots i} & = & 00 \dots 01 \\
 ((E \wedge P) + P)_{\ell \dots i} & = & \bar{\mathbf{b}}0 \dots 0\mathbf{c} \\
 (((E \wedge P) + P) \vee P)_{\ell \dots i} & = & 11 \dots 1\bar{\mathbf{c}} \\
 Y = (((E \wedge P) + P) \vee P) \vee E)_{\ell \dots i} & = & 11 \dots 11
 \end{array}$$

missä $\bar{\mathbf{b}}$ on $\mathbf{b}$:n negaatio.

- c) Koska kaikilla bittivektoreilla B , $0 \wedge B = 0$ ja $0 + B = B$, saadaan $Y = (((0 \wedge P) + P) \vee P) \vee 0 = (P \vee P) \vee 0 = 0$.
- d) Tarkastellaan kohdan b) laskentaa. Sen ideana on, että yhteenlaskussa positiossa ℓ syntyvä muistibitti kantautuu aina positioon i asti ja tuottaa sinne bitin $\bar{\mathbf{b}}$. Erona on nyt, että ainakin yksi bitti P_k , $\ell \leq k < i$, on 0. Jos $k = \ell$, niin $P_\ell = (E \wedge P)_\ell = 0$ ja muistibittiä ei synny (riippumatta bitistä $\mathbf{c}$). Jos taas $k > \ell$, muistibitti pysähtyy positioon k . Kummassakin tapauksessa $((E \wedge P) + P)_i = \mathbf{b}$ ja siten $Y_i = 0$.

□

- Määritellään $Peq[a]$, $a \in \Sigma$, on bittivektori, jossa on 1 positiossa i jos ja vain jos $p_i = a$. Tällöin $Eq_{*j} = Peq[s_j]$.

Algoritmi 2.4.7 *Myers*

Syöte: $P, S, k, |P| \leq w$, missä w on tietokoneen sanan pituus

Tuloste: P :n likimääräiset esiintymäkohdat k virheellä S :ssä

- (1) Laske $Peq[a]$ jokaiselle $a \in \Sigma$
- (2) $Pv := 1^m$; $Mv := 0$; $Sc := m$
- (3) **for** $j := 1$ **to** n **do**
- (4) $Eq := Peq[S_j]$
- (5) $Xh := (((Eq \wedge Pv) + Pv) \vee Pv) \vee Eq$;
- (6) $Ph := Mv \vee \neg(Xh \vee Pv)$
- (7) $Mh := Pv \wedge Xh$;
- (8) $Xv := Eq \vee Mv$
- (9) $Pv := (Mh << 1) \vee \neg(Xv \vee (Ph << 1))$
- (10) $Mv := (Ph << 1) \wedge Xv$
- (11) $Sc := Sc + Ph(m) - Mh(m)$
- (12) **if** $Sc \leq k$ **then write** j


Lause 2.4.8 Olkoon hahmo $P = p_1 \cdots p_m$ ja teksti $S = s_1 \cdots s_n$. Likimääräinen hahmonsovitus k virheellä voidaan ratkaista Algoritmilla 2.4.7 ajassa $\mathcal{O}(\lceil m/w \rceil n)$, missä w on tietokoneen sananpituus bitteinä.

Todistus. On selvää, että Algoritmi 2.4.7 toimii ajassa $\mathcal{O}(n)$ kun $m \leq w$. Algoritmia voidaan helposti simuloida pidemmillä hahmoilla käyttäen useaa tietokonesanaa vektorien Pv, Eq , jne., esittämiseen. $\square$

Huomautus 2.4.9 Rajoittamalla laskenta kullakin sarakkeella viimeiseen arvoon k asti (kuten Algoritmossa 2.3.6), voidaan Algoritmia 2.4.7 tehostaa toimimaan odotusarvoisesti $\mathcal{O}(\lceil k/w \rceil n)$ ajassa.

Huomautus 2.4.10 Monessa laskennan mallissa oletetaan, että $w = \Omega(\log n)$ (jotta muistiosoite mahtuu vakiomäärään sanoja). Tällöin siis Algoritmin 2.4.7 aikavaatimus on oikeastaan $\mathcal{O}(mn/\log n)$. Muitakin samanlaisia algoritmeja on. Masekin ja Patersonin (*J. Comput. Syst. Sci.* 20:18–31, 1980) ”neljän venäläisen” menetelmään perustuvalla algoritmilla aikavaatimus on jopa $\mathcal{O}(mn/\log_\sigma^2 n)$.

- On olemassa myös muita bittirinnakkaisuuteen perustuvia algoritmeja likimääräiseen hahmonsovitukseen.
- Kaksi eri algoritmia perustuu seuraavan epädeterministisen automaatin simulointiin:



- Wun ja Manberin (CACM 35(10):83–91, 1992) algoritmi, joka koodaa kunkin automaatin rivin erillisellä bittivektorilla, voidaan nähdä shift-or-algoritmin yleistysenä. Sen aikavaatimus on $\mathcal{O}(k \lceil m/w \rceil n)$.
- Baeza-Yatesin ja Navarron (Algorithmica 23(2):127–158, 1999) algoritmi koodaa automaatin lävistäjät bittivektoreilla, jotka voi pakata yhdeksi pitkäksi vektoriksi. Aikavaatimus on $\mathcal{O}(\lceil km/w \rceil n)$.