

Algorithmes vectoriels pour la recherche approchée

Nadia El-Mabrouk

Problème

- INPUT:
 - Un mot P de taille m
 - Un texte T de taille $n \gg m$
 - Un nombre d'erreurs autorisées $k \ll m$
- OUTPUT: Toutes les occurrences de P dans T à k erreurs près.
- Programmation dynamique: $O(mn)$
- Différentes améliorations: $O(kn)$

Méthodes numériques – Algorithmes vectoriels

Basées sur une représentation en bits des états de la recherche.

Dans ce cas, une approche naive est considérée, et rendue rapide grâce à la capacité des langages de programmation à manipuler les mots machine (opérations logiques et arithmétiques simples)

Algorithme vectoriel: Algorithme qui trouve un vecteur de sortie en appliquant un nb d'opérations sur les vecteurs d'entrée, indépendant de la longueur des vecteurs.

Mot machine: Vecteur binaire de 16, 32, 64 bits

0110001101001110

Opérations unitaires sur les mots machine: $x \vee y$, $x \wedge y$, $\neg x$, $x \ll a$ (déplacement vers la gauche), $x \gg a$ (déplacement vers la droite).

Algorithme Shift-Or pour la recherche exacte

Recherche exacte d'un mot P de taille m dans un texte T de taille n .

Pour toute position j dans T , E_j est un vecteur de taille m tel que:

$$\text{Pour tout } i, 1 \leq i \leq m, \quad E_j[i] = \begin{cases} 0 & \text{si } P[1:i] = T[j-i+1:j] \\ 1 & \text{sinon} \end{cases}$$

Occurrence de P dans T se terminant à la position j ssi $E_j[m] = 0$

Algorithme Shift-Or pour la recherche exacte

Phase de prétraitement: Pour tout $a \in \Sigma$, calculer le vecteur S_a :

$$\text{Pour tout } i, 1 \leq i \leq m, \quad S_a[i] = \begin{cases} 0 & \text{si } a = p_i \\ 1 & \text{sinon} \end{cases}$$

Alors: $E_{j+1} = (E_j \ll b) \vee S_{t_{j+1}}$ Ici $b=1$

Si $m \leq w$ (32 ou 63), complexité $O(n)$ en temps et $O(1)$ en espace.

a	b	d	a	b	b
1	1	1	0	1	

a

a b

a b b

a b b a

a b b a c

a	b	d	a	b	b	
	1	1	0	1	0	
				a	a	1
				a	b	0
		a	b	b	b	0
		a	b	b	a	1
	a	b	b	a	c	1

a	b	d	a	b	b	
	1	1	0	1	0	
					a	1
				a	b	0
			a	b	b	0
		a	b	b	a	1
a	b	b	a	c		1
	1	1	0	1	1	

	1	1	0	1	0
V	1	1	0	0	1
=	1	1	0	1	1

- Exemple complet;

$\Sigma = \{a, b, c, d\}$, $P = abbac$, $T = abbabbac$

x	a	b	c	d
S_x	10110	11001	01111	11111

États successifs de la recherche dans T :

T		a	b	b	a	b	b	a	c
E_j	11111	11110	11101	11011	10110	11101	11011	10110	01111

*

$$E_{j+1} = (E_j \ll b) \vee S_{t_{j+1}}$$

```

ALGORITHM SHIFT-OR ( $t, p$ )
SI ( $|p| > \text{WORD}$ )
    Error ("Use pattern size  $\leq$  word size");

/* Preprocessing */
POUR ( $i = 0$  to  $|\Sigma|$ ) FAIRE
     $T[i] = \neg 0$ ;
lim = 0;  $j = 1$ 
POUR (chaque carac.  $p_c$  de  $p$  de dte. a gch.) FAIRE
     $T[p_c] = T[p_c] \wedge \neg j$ 
    lim = lim  $\vee j$ ;
     $j = j \ll B$ ;
FIN POUR
lim =  $\neg (\text{lim} \gg B)$ ; /* lim: 10000 Dernier Bit utilise*/

/* Recherche */
Match = 0;
Init =  $\neg 0$ ;
Etat = Init;
TANTQUE (pas fin de  $t$ )
     $T[t_c]$ : Prochain caractere du texte;
    Etat = (Etat  $\ll B$ )  $\vee T[t_c]$ ;
    SI Etat  $\leq$  lim, Match = Match+1;
FIN TANT QUE
RETOURNE (Match)

```

Recherche avec mismatches - Algorithme Shift-Add:

(*Baeza-Yates-Gonnet, 1992*)

Recherche de P dans T avec au plus k mismatch.

Pour toute pos. j de T , vecteur E_j de taille m tel que $E_j[i]$ contient le nombre d'erreurs entre $P[1..i]$ et $T[j - i + 1..j]$.

Occurrence de P finissant à la position j ssi $E_j[m] \leq k$.

Phase de prétraitement: Pour tout $a \in \Sigma$, calculer le vecteur S_a :

$$\text{Pour tout } i, 1 \leq i \leq m, \quad S_a[i] = \begin{cases} 0 & \text{si } a = p_i \\ 1 & \text{sinon} \end{cases}$$

Alors, $E_{j+1}[i] = E_j[i - 1] + S_{t_{j+1}}[i]$

T:	a	b	d	a	⁵ b	⁶ b	a	b	b
E[5]:	2	4	2	0	1				
					a				
				a	b				
			a	b	b				
		a	b	b	a				
P:	a	b	b	a	c				

T:	a	b	d	a	⁵ b	⁶ b	a	b	b
		4	2	0	1	0			
					a				
				a	b				
		a	b	b					
	a	b	b	a					

T:	a	b	d	a	⁵ b	⁶ b		a	b	b
		4	2	0	1	0				
						a	1			
					a	b	0			
				a	b	b	0			
		a	b	b	a	c	1			
	a	b	b	a	c	1				
						S ^b				

$$\begin{array}{rcccccc} & 4 & 2 & 0 & 1 & 0 \\ + & 1 & 1 & 0 & 0 & 1 \\ \hline \text{E[6]:} & 5 & 3 & 0 & 1 & 1 \end{array}$$

b : Nombre de bits nécessaires pour représenter chaque état individuel.

Si E_j et S_a codés chacun sur un mot machine:

$$E_{j+1} = (E_j \ll b) + S_{t_{j+1}}$$

Valeurs possibles de $E_j[i]$: $0, \dots, m \implies b = \lceil \log_2(m+1) \rceil$

En fait, il suffit de représenter les valeurs de 0 à $k+1$

Par exemple, pour le vecteur $E_6 = 5\ 3\ 0\ 1\ 1$ de la page précédente, si $k=1$, on ne devrait pas avoir à garder la valeur 5. Et 3?


En fait on a besoin de garder $b = \lceil \log_2(k+1) \rceil + 1$

Pour $k=1$, $b = \lceil \log_2(k+1) \rceil + 1 = 2$ bits : permet de représenter les valeurs de 0 à 3. Si la taille m de P est 5, alors, E_j pour tout j est de taille $5 \cdot 2 = 10$

Donc pour $E_6 = 5\ 3\ 0\ 1\ 1$, on a besoin de garder les valeurs de 0 à 3.

E_6 :

5	3	0	1	1
--------------	---	---	---	---



En fait on a besoin d'un vecteur « retenue »
des additions :

$$E_6^{\text{init}} : \begin{array}{|c|c|c|c|c|} \hline 3 & 3 & 0 & 1 & 1 \\ \hline \end{array} \longrightarrow \begin{array}{|c|c|c|c|c|c|c|c|c|c|} \hline \textcolor{red}{1} & 1 & \textcolor{red}{1} & 1 & 0 & 0 & 0 & 1 & 0 & 1 \\ \hline \end{array}$$

$$E_6 : \begin{array}{|c|c|c|c|c|} \hline 1 & 1 & 0 & 1 & 1 \\ \hline \end{array} \longrightarrow \begin{array}{|c|c|c|c|c|c|c|c|c|c|} \hline \textcolor{red}{0} & 1 & \textcolor{red}{0} & 1 & 0 & 0 & 0 & 1 & 0 & 1 \\ \hline \end{array}$$

+

$$R_6 : \begin{array}{|c|c|c|c|c|} \hline 2 & 2 & 0 & 0 & 0 \\ \hline \end{array} \longrightarrow \begin{array}{|c|c|c|c|c|c|c|c|c|c|} \hline \textcolor{red}{1} & 0 & \textcolor{red}{1} & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ \hline \end{array}$$

$$E_6^{\text{init}}: \begin{array}{|c|c|c|c|c|} \hline 3 & 3 & 0 & 1 & 1 \\ \hline \end{array} \longrightarrow \begin{array}{|c|c|c|c|c|c|c|c|c|c|} \hline \textcolor{red}{1} & 1 & \textcolor{red}{1} & 1 & 0 & 0 & 0 & 1 & 0 & 1 \\ \hline \end{array}$$

$$E_6: \begin{array}{|c|c|c|c|c|} \hline 1 & 1 & 0 & 1 & 1 \\ \hline \end{array} \longrightarrow \begin{array}{|c|c|c|c|c|c|c|c|c|c|} \hline 0 & 1 & 0 & 1 & 0 & 0 & 0 & 1 & 0 & 1 \\ \hline \end{array}$$

+

$$R_6: \begin{array}{|c|c|c|c|c|} \hline 2 & 2 & 0 & 0 & 0 \\ \hline \end{array} \longrightarrow \begin{array}{|c|c|c|c|c|c|c|c|c|c|} \hline \textcolor{red}{1} & 0 & \textcolor{red}{1} & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ \hline \end{array}$$

On a besoin de $M =$

$\wedge$

$$\begin{array}{|c|c|c|c|c|c|c|c|c|c|} \hline \textcolor{red}{1} & 0 & \textcolor{red}{1} & 0 & \textcolor{red}{1} & 0 & \textcolor{red}{1} & 0 & \textcolor{red}{1} & 0 \\ \hline \end{array}$$

$$\begin{array}{|c|c|c|c|c|c|c|c|c|c|} \hline \textcolor{red}{1} & 1 & \textcolor{red}{1} & 1 & 0 & 0 & 0 & 1 & 0 & 1 \\ \hline \end{array} E_6^{\text{init}}$$

$$I = E_6^{\text{init}} \wedge M = \begin{array}{|c|c|c|c|c|c|c|c|c|c|} \hline \textcolor{red}{1} & 0 & \textcolor{red}{1} & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ \hline \end{array} I$$

$$E_6^{\text{init}}: \begin{array}{|c|c|c|c|c|} \hline 3 & 3 & 0 & 1 & 1 \\ \hline \end{array} \longrightarrow \begin{array}{|c|c|c|c|c|c|c|c|c|c|} \hline 1 & 1 & 1 & 1 & 0 & 0 & 0 & 1 & 0 & 1 \\ \hline \end{array}$$

$$E_6: \begin{array}{|c|c|c|c|c|} \hline 1 & 1 & 0 & 1 & 1 \\ \hline \end{array} \longrightarrow \begin{array}{|c|c|c|c|c|c|c|c|c|c|} \hline 0 & 1 & 0 & 1 & 0 & 0 & 0 & 1 & 0 & 1 \\ \hline \end{array}$$

+

$$R_6: \begin{array}{|c|c|c|c|c|} \hline 2 & 2 & 0 & 0 & 0 \\ \hline \end{array} \longrightarrow \begin{array}{|c|c|c|c|c|c|c|c|c|c|} \hline 1 & 0 & 1 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ \hline \end{array}$$

On a besoin de $M =$

$$\begin{array}{|c|c|c|c|c|c|c|c|c|c|} \hline 1 & 0 & 1 & 0 & 1 & 0 & 1 & 0 & 1 & 0 \\ \hline \end{array}$$

$$\begin{array}{|c|c|c|c|c|c|c|c|c|c|} \hline 1 & 1 & 1 & 1 & 0 & 0 & 0 & 1 & 0 & 1 \\ \hline \end{array} E_6^{\text{init}}$$

$\wedge$

$$\begin{array}{|c|c|c|c|c|c|c|c|c|c|} \hline 0 & 1 & 0 & 1 & 1 & 1 & 1 & 1 & 1 & 1 \\ \hline \end{array} \neg I$$

$$E_6 = E_6^{\text{init}} \wedge \neg I$$

$=$

$$\begin{array}{|c|c|c|c|c|c|c|c|c|c|} \hline 0 & 1 & 0 & 1 & 0 & 0 & 0 & 1 & 0 & 1 \\ \hline \end{array} E_6$$

$$R_6: I$$

$$\begin{array}{|c|c|c|c|c|c|c|c|c|c|} \hline 1 & 0 & 1 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ \hline \end{array} I$$

Soit M le vecteur de $m.b$ bits: $2^{b-1}2^{b-1}\dots 2^{b-1}$.

À chaque position j dans T , les vecteurs E_{j+1} et R_{j+1} sont calculés à partir de E_j et R_j de la façon suivante:

- $E_{j+1} = (E_j \ll b) + S_{t_{j+1}};$
- $I = E_{j+1} \wedge M;$
- $E_{j+1} = E_{j+1} \wedge \neg I;$
- $R_{j+1} = (R_j \ll b) \vee I$

Exemple:

$\Sigma = \{a, b, c, d\}$, $P = abbac$ et $k = 1$.

Alors $b = \lceil \log_2(2) \rceil + 1 = 2$. Table S :

x	a	b	c	d
S_x	10110	11001	01111	11111

États successifs lors de la recherche de P dans le texte

$T = abdabbabbac$:

T		a	b	d	a	b	b	a	b	b	a	c
E_j	00000	10110	10101	10101	11100	00001	11011	00000	11001	01011	00000	01111
R_j	22222	22220	22200	22020	20220	22200	22000	20220	02200	22000	20220	02200

*

*

a	b	d	a	b
2	4	2	0	1

a

a b

a b b

a b b a

a	b	b	a	c
---	---	---	---	---

E₅ : **0** **0** **0** **0** **1**

+

R₅ : **2** **2** **2** **0** **0**

=

2 **2** **2** **0** **1**

a	b	d	a	b	a
	5	2	1	2	0
				a	a
			a	b	b
		a	b	b	a
	a	b	b	a	c

E₆: 1 0 1 0 0

R₆: 2 2 0 2 0

Comment les calculer
à partir de E₅ et R₅?

a b d a b a

a

a b

a b b

a b b a

a b b a c

$E_5:$ 0 0 0 0 1

$R_5:$ 2 2 2 0 0

$$E_{j+1} = (E_j \ll b) + S_{t_{j+1}};$$

$$I = E_{j+1} \wedge M;$$

$$E_{j+1} = E_{j+1} \wedge \neg I;$$

$$R_{j+1} = (R_j \ll b) \vee I$$

a	b	d	a	b	a	
					a	0
				a	b	1
		a	b	b	b	1
	a	b	b	a	a	0
a	b	b	a	c	c	1

$E_5:$ 0 0 0 1 0 ←

$$E_{j+1} = (E_j \ll b) + S_{t_{j+1}}; \quad \leftarrow$$

$$I = E_{j+1} \wedge M;$$

$$E_{j+1} = E_{j+1} \wedge \neg I;$$

$$R_{j+1} = (R_j \ll b) \vee I$$

a	b	d	a	b	a
					a 0
				a	b 1
			a	b	b 1
		a	b	b	a 0
	a	b	b	a	c 1

$E_5:$ 0 0 0 1 0 ←

$S_6:$ 1 0 1 1 0

$E_{j+1} = (E_j \ll b) + S_{t_{j+1}}; \leftarrow$

$I = E_{j+1} \wedge M;$

$E_{j+1} = E_{j+1} \wedge \neg I;$

$R_{j+1} = (R_j \ll b) \vee I$

a	b	d	a	b	a
					a 0
				a	b 1
			a	b	b 1
		a	b	b	a 0
	a	b	b	a	c 1

$E_5:$ 0 0 0 1 0 ←

+

$S_6:$ 1 0 1 1 0

=

$E_6:$ 1 0 1 2 0

$E_{j+1} = (E_j \ll b) + S_{t_{j+1}}; \leftarrow$

$I = E_{j+1} \wedge M;$

$E_{j+1} = E_{j+1} \wedge \neg I;$

$R_{j+1} = (R_j \ll b) \vee I$

a	b	d	a	b	a	
					a	0
				a	b	1
			a	b	b	1
		a	b	b	a	0
	a	b	b	a	c	1

$E_6:$

1	0	1	2	0
---	---	---	---	---

$$E_{j+1} = (E_j \ll b) + S_{t_{j+1}};$$

$$I = E_{j+1} \wedge M; \quad \leftarrow$$

$$E_{j+1} = E_{j+1} \wedge \neg I;$$

$$R_{j+1} = (R_j \ll b) \vee I$$

a	b	d	a	b	a	
					a	0
				a	b	1
		a	b	b	b	1
	a	b	b	a	a	0
a	b	b	a	c	c	1

$E_6:$ 1 0 1 2 0

$E_6:$	0	1	0	0	0	1	1	0	0	0
$M:$	1	0	1	0	1	0	1	0	1	0
$I =$	0	0	0	0	0	0	1	0	0	0

$E_{j+1} = (E_j \ll b) + S_{t_{j+1}};$	
$I = E_{j+1} \wedge M;$	←
$E_{j+1} = E_{j+1} \wedge \neg I;$	
$R_{j+1} = (R_j \ll b) \vee I$	

a	b	d	a	b	a	
					a	0
				a	b	1
			a	b	b	1
		a	b	b	a	0
	a	b	b	a	c	1

$I =$

0	0	0	0	0	0	1	0	0	0
---	---	---	---	---	---	---	---	---	---

$E_6:$ 1 0 1 2 0

$$E_{j+1} = (E_j \ll b) + S_{t_{j+1}};$$

$$I = E_{j+1} \wedge M; \quad \leftarrow$$

$$E_{j+1} = E_{j+1} \wedge \neg I;$$

$$R_{j+1} = (R_j \ll b) \vee I$$

a	b	d	a	b	a	
					a	0
				a	b	1
			a	b	b	1
		a	b	b	a	0
	a	b	b	a	c	1

$I =$

0	0	0	0	0	0	1	0	0	0
---	---	---	---	---	---	---	---	---	---

$\neg I =$

1	1	1	1	1	1	0	1	1	1
---	---	---	---	---	---	---	---	---	---

$E_6:$ 1 0 1 2 0

$E_{j+1} = (E_j \ll b) + S_{t_{j+1}};$	
$I = E_{j+1} \wedge M;$	
$E_{j+1} = E_{j+1} \wedge \neg I;$	←
$R_{j+1} = (R_j \ll b) \vee I$	

a	b	d	a	b	a	
					a	0
				a	b	1
			a	b	b	1
	a	b	b	a	a	0
a	b	b	a	c	c	1

$E_6:$ 1 0 1 0 0

$E_6:$

0	1	0	0	0	1	1	0	0	0
---	---	---	---	---	---	----------	---	---	---

$\wedge$

$\neg I =$

1	1	1	1	1	1	0	1	1	1
---	---	---	---	---	---	---	---	---	---

$E_6:$

0	1	0	0	0	1	0	0	0	0
---	---	---	---	---	---	----------	---	---	---

$E_{j+1} = (E_j \ll b) + S_{t_{j+1}};$	
$I = E_{j+1} \wedge M;$	
$E_{j+1} = E_{j+1} \wedge \neg I;$	←
$R_{j+1} = (R_j \ll b) \vee I$	

a	b	d	a	b	a	
					a	0
				a	b	1
			a	b	b	1
		a	b	b	a	0
	a	b	b	a	c	1

$E_6:$ 1 0 1 0 0

$R_5:$ 2 2 2 0 0

$$E_{j+1} = (E_j \ll b) + S_{t_{j+1}};$$

$$I = E_{j+1} \wedge M;$$

$$E_{j+1} = E_{j+1} \wedge \neg I;$$

$$R_{j+1} = (R_j \ll b) \vee I \leftarrow$$

a	b	d	a	b	a
				a	0
			a	b	1
		a	b	b	1
	a	b	b	a	0
a	b	b	a	c	1

$E_6:$ 1 0 1 0 0

$R_6:$ 2 2 0 0 0

$R_6:$

1	0	1	0	0	0	0	0	0	0
---	---	---	---	---	---	---	---	---	---

$\vee$

$I =$

0	0	0	0	0	0	1	0	0	0
---	---	---	---	---	---	---	---	---	---

$R_6:$

1	0	1	0	0	0	1	0	0	0
---	---	---	---	---	---	---	---	---	---

$$E_{j+1} = (E_j \ll b) + S_{t_{j+1}};$$

$$I = E_{j+1} \wedge M;$$

$$E_{j+1} = E_{j+1} \wedge \neg I;$$

$$R_{j+1} = (R_j \ll b) \vee I \leftarrow$$

a	b	d	a	b	a
				a	0
			a	b	1
		a	b	b	1
	a	b	b	a	0
a	b	b	a	c	1

$E_6:$ 1 0 1 0 0

$R_6:$ 2 2 0 2 0

R_6

1	0	1	0	0	0	0	0	0	0
---	---	---	---	---	---	---	---	---	---

$\vee$

$I =$

0	0	0	0	0	0	1	0	0	0
---	---	---	---	---	---	---	---	---	---

$R_6:$

1	0	1	0	0	0	1	0	0	0
---	---	---	---	---	---	---	---	---	---

$$E_{j+1} = (E_j \ll b) + S_{t_{j+1}};$$

$$I = E_{j+1} \wedge M;$$

$$E_{j+1} = E_{j+1} \wedge \neg I;$$

$$R_{j+1} = (R_j \ll b) \vee I \leftarrow$$

a	b	d	a	b	a	
	5	2	1	2	0	
					a	0
				a	b	1
			a	b	b	1
		a	b	b	a	0
	a	b	b	a	c	1

$E_6:$ 1 0 1 0 0

$R_6:$ 2 2 0 2 0

$R_6 \vee$

1	0	1	0	0	0	0	0	0	0
---	---	---	---	---	---	---	---	---	---

$I =$

0	0	0	0	0	0	1	0	0	0
---	---	---	---	---	---	---	---	---	---

$R_6:$

1	0	1	0	0	0	1	0	0	0
---	---	---	---	---	---	----------	---	---	---

$$E_{j+1} = (E_j \ll b) + S_{t_{j+1}};$$

$$I = E_{j+1} \wedge M;$$

$$E_{j+1} = E_{j+1} \wedge \neg I;$$

$$R_{j+1} = (R_j \ll b) \vee I \leftarrow$$

Complexité:

$$|\Sigma| = c.$$

$O(\lceil \frac{mb}{\omega} \rceil)$: temps nécessaire pour effectuer un nombre constant d'opérations sur un état de longueur mb représenté sur un mot machine de longueur ω .

- Calcul de S : temps $O(\lceil \frac{mb}{\omega} \rceil (m + c))$ et espace $O(\lceil \frac{mb}{\omega} \rceil c)$.
- Phase de recherche: temps dans le pire des cas et en moyenne en $O(\lceil \frac{mb}{\omega} \rceil n)$

Lorsque $mb \leq \omega$, complexité totale en temps en $O(n + m + c)$ et complexité en espace en $O(c)$

Lorsque le nombre de mots machine utilisé n'est pas trop grand, Shift-Add reste efficace en pratique.

Le cours s'arrête ici.

La suite est juste pour vous, mais ne
comptera pas à l'examen

Algorithme Shift-And pour la recherche avec erreurs:

Utilisé dans le programme *agrep* de UNIX.

Phase de prétraitement: Pour tout $a \in \Sigma$, calculer C_a : inverse (voir Hirschberg) du vecteur caractéristique de a dans P .

Exemple: Si $P = abbac$, alors $C_a = 01001$, $C_b = 00110$, $C_c = 10000$ et $C_d = 00000$.


Phase de recherche: Utilise $k + 1$ vecteurs $E_j^0, E_j^1, \dots, E_j^k$:

$$\text{Pour tout } i, \quad E_j^d[i] = \begin{cases} 1 & \text{si } P[1 : i] = T[j - i + 1 : j] \text{ à } d \text{ erreurs près} \\ 0 & \text{sinon} \end{cases}$$

Exemple: Si $T = abcbcabba$ et $P = abbac$, alors $E_5^1 = 00001$ et $E_5^2 = 10111$

Initialisation: Pour tout d , $E_0^d = 0^{m-d}1^d$

Pour que $P[1..i]$ s'aligne avec $T[j - i + 2..j + 1]$ à d erreurs près, 4 cas possibles:



- $P[1..i - 1]$ s'aligne avec $T[j - i + 2..j]$ avec au plus d erreurs, et $P_i = T_{j+1} \longrightarrow E_{j+1}^d = E_j^d \ll 1 \wedge C_{T_{j+1}}$
- $P[1..i - 1]$ s'aligne avec $T[j - i + 2..j]$ avec au plus $d - 1$ erreurs (cas d'un match ou d'un mismatch) $\longrightarrow E_{j+1}^d = E_j^{d-1} \ll 1$
- **Suppression de P_i :** $P[1..i - 1]$ s'aligne avec $T[j - i + 2..j + 1]$ avec au plus $d - 1$ erreurs $\longrightarrow E_{j+1}^d = E_{j+1}^{d-1} \ll 1$
- **Insertion de T_{j+1} :** $P[1..i]$ s'aligne avec $T[j - i + 2..j]$ avec au plus $d - 1$ erreurs $\longrightarrow E_{j+1}^d = E_j^{d-1}$

Et donc, pour tout $d > 0$:

$$\begin{aligned} E_{j+1}^d &= ((E_j^d \ll 1) \wedge C_{t_{j+1}}) \vee (E_j^{d-1} \ll 1) \vee \\ &\quad (E_{j+1}^{d-1} \ll 1) \vee E_j^{d-1} \\ &= ((E_j^d \ll 1) \wedge C_{T_{j+1}}) \vee \\ &\quad ((E_j^{d-1} \vee E_{j+1}^{d-1}) \ll 1) \vee E_j^{d-1} \end{aligned}$$

Pour $d = 0$:

$$E_{j+1}^0 = (E_j^0 \ll 1) \wedge C_{T_{j+1}}$$

Complexité: La phase de recherche prend un temps en $O(\lceil \frac{m}{\omega} \rceil kn)$

Lorsque $m \leq \omega$, temps total de Shift-And en $O(kn + m + c)$ et complexité en espace en $O(c)$.

Example:

On recherche `annual` dans le texte `annealing` à $k = 2$ erreurs près.

Au départ: $E^0 = 000000$, $E^1 = 000001$, $E^2 = 000011$.

T:	a	n	n	e	a	⁶ l	⁷ i	n	g
E ₆ ⁰ :	0	0	0	0	0	0			
E ₆ ¹ :	1	0	0	0	1	1			
E ₆ ² :	1	0	0	1	1	1			
					a				
					a	n			
				a	n	n			
P:			a	n	n	u			
		a	n	n	u	a			
	a	n	n	u	a	l			

T:	a	n	n	e	a	⁶ l	⁷ i		n	g			
		0	0	0	0	0	1						
		0	0	0	1	1	1						
		0	0	1	1	1	1						
							a		0				
							a	n	0				
							a	n	n	0			
							a	n	n	u	0		
P:							a	n	n	u	a	0	
							a	n	n	u	a	l	0

S_i


$$E_7^0 = (000000 \ll 1) \ \& \ 000000 = 000000$$

$$E_7^1 = ((100011 \ll 1) \& 000000) \mid (000000 \ll 1) \mid (000000 \ll 1) \mid 000000 = 000001$$

$$E_7^2 = ((100111 \ll 1) \& 000000) \mid (100011 \ll 1) \mid (000001 \ll 1) \mid 100011 = 100111$$

Pour que $P[1..i]$ s'aligne avec $T[..j+1]$ à d erreurs près :

- $P[1..i-1]$ s'aligne avec $T[j-i+2..j]$ avec au plus d erreurs, et
 $P_i = T_{j+1} \longrightarrow E_{j+1}^d = E_j^d << 1 \wedge C_{T_{j+1}}$



$P =$


1	2	3	4	5	6
a	n	n	u	a	l

$T_7 = i \quad C_i =$

1	2	3	4	5	6
0	0	0	0	0	0


Pour que $P[1..i]$ s'aligne avec $T[..j+1]$ à d erreurs près :

- $P[1..i-1]$ s'aligne avec $T[j-i+2..j]$ avec au plus d erreurs, et $P_i = T_{j+1} \longrightarrow E_{j+1}^d = E_j^d \ll 1 \wedge C_{T_{j+1}}$




Pour que $P[1..i]$ s'aligne avec $T[..j+1]$ à d erreurs près :

- $P[1..i-1]$ s'aligne avec $T[j-i+2..j]$ avec au plus $d-1$ erreurs
(cas d'un match ou d'un mismatch) $\longrightarrow E_{j+1}^d = E_j^{d-1} < 1$




Pour que $P[1..i]$ s'aligne avec $T[..j+1]$ à d erreurs près :

- Suppression de P_i : $P[1..i-1]$ s'aligne avec $T[j-i+2..j+1]$ avec au plus $d-1$ erreurs $\longrightarrow E_{j+1}^d = E_{j+1}^{d-1} \ll 1$



Pour que $P[1..i]$ s'aligne avec $T[..j+1]$ à d erreurs près :

- Insertion de T_{j+1} : $P[1..i]$ s'aligne avec $T[j - i + 2..j]$ avec au plus $d - 1$ erreurs $\rightarrow E_{j+1}^d = E_j^{d-1}$



Example:

On recherche `annual` dans le texte `annealing` à $k = 2$ erreurs près.

Au départ: $E^0 = 000000$, $E^1 = 000001$, $E^2 = 000011$.

T:	a	n	n	e	a	⁶ l	⁷ i	n	g
E ₆ ⁰ :	0	0	0	0	0	0			
E ₆ ¹ :	1	0	0	0	1	1			
E ₆ ² :	1	0	0	1	1	1			
					a				
					a	n			
				a	n	n			
P:			a	n	n	u			
		a	n	n	u	a			
	a	n	n	u	a	l			

T:	a	n	n	e	a	⁶ l	⁷ i		n	g			
		0	0	0	0	0	1						
		0	0	0	1	1	1						
		0	0	1	1	1	1						
							a		0				
							a	n	0				
							a	n	n	0			
							a	n	n	u	0		
P:							a	n	n	u	a	0	
							a	n	n	u	a	l	0

S_i

$$E_7^0 = (000000 \ll 1) \ \& \ 000000 = 000000$$

$$E_7^1 = ((100011 \ll 1) \& 000000) \mid (000000 \ll 1) \mid (000000 \ll 1) \mid 000000 = 000001$$

$$E_7^2 = ((100111 \ll 1) \& 000000) \mid (100011 \ll 1) \mid (000001 \ll 1) \mid 100011 = 100111$$