

Département d'informatique et de génie logiciel  
**Compression de données**  
**IFT-4003/IFT-7023**

**Notes de cours**  
**Compression basée sur les**  
**contextes**

Édition Hiver 2012

Mohamed Haj Taieb

Local: PLT 2113

Courriel: [mohamed.haj-taieb.1@ulaval.ca](mailto:mohamed.haj-taieb.1@ulaval.ca)

**Faculté des sciences et de génie**  
Département de génie électrique et de  
génie informatique

# Plan de la présentation

---

## □ Compression basée sur les contextes:

- Introduction
- Prédiction avec correspondance partielle
- Symbole échappe
- Longueur du contexte
- Principe d'exclusion
- La transformation Burrows-Wheeler
- Encodeur associatif de Buyanovsky
- Compression dynamique de Markov

# Introduction

---

## □ Compression basée sur les contextes

- Utilisation d'un minimum d'hypothèses sur les statistiques des données.
- Utilisation du contexte des données actuelles et passées.
- → Compression de texte.

## □ Constatation

- Probabilités débalancées → plus de compression.
- Cas extrême:  $P(1)=1$  et  $P(0)=0$  →  $H=0$ .
- L'idée est alors de trouver un moyen pour représenter les données avec plus de débalancement.
- → observation de la probabilité du symbole dans le contexte courant: observation de l'historique.

# Entropie de la langue anglaise selon Shannon

---


## □ Alphabet de 26 lettres:

- $H_0 = \log_2(26) \approx 4.7$  bits/lettre
- En considérant la distribution de chaque lettres:
  - $H_1 \approx 4.14$  bits/lettre
- On se base sur l'observation de la lettre précédente
  - $H_2 \approx 3.56$  bits/lettre [basé sur les digrammes]
- On se base sur l'observation des 2 lettres précédentes
  - $H_3 \approx 3.3$  bits/lettre [basé sur les trigrammes]

## □ Entropie d'un mot:

- $H_{\text{word}} = -\sum_{n=1..8727} p_n \log_2 p_n = 11.82$  bits/mots
- Longueur moyenne d'un mot = 4.5
- $H_{\text{word}} = 11.82/4.5 = 2.62$  bits/lettre

# Formule de zif sur la fréquence de mot: $p_n = 0.1/n$



Prediction and Entropy of printed english [Claude E. Shannon]  
<http://csc.ucdavis.edu/~cmg/Group/readings/CES-PredictEntEng.pdf>

Fig. 1—Relative frequency against rank for English words.

# Compression basée sur la prédiction

## ❑ Expérience effectuée par Shannon: réussite = 70%

Text: THE ROOM WAS NOT VERY LIGHT A SMALL OBLONG  
Human: ---ROOM---NOT-V---I-----S---OBL---

Text: READING LAMP ON THE DESK SHED GLOW ON  
Human: REA-----O-----D---SHED-GLO-O-

Text: POLISHED WOOD BUT LESS ON THE SHABBY RED CARPET  
Human: P-L-S-----O--BU--L-S-O-----SH-----RE-C-----

## ❑ Idée de compression de Shannon



# Codage prédictif

---

## ❑ Pas d'intervention humaine:

- On utilise la probabilité conditionnelle
- Exemple:  $P('h')=5\%$ ,  $P('u')=2\%$
- Mais  $P('h'|'t')=30\%$  et  $P('u'|'q')=99\%$

## ❑ Contexte d'ordre supérieure:

- Contexte d'ordre 1:  $P('a')$ ,  $P('b')$ , ...  $P('z')$  : 26 contextes
- Contexte d'ordre 3:  $P('e'|'t','h') > P('e'|'h') > P('2')$ :  $26^3$
- Contexte d'ordre 5:  $Pr(a|'p', 'r', 'o', 'b')$  :  $26^5 = 11.8 \times 10^7$

## ❑ Problème:

- Quantité colossale d'information à stocker.
- Solution: un ensemble d'algorithmes: ppm (prediction with partial match).

# Prédiction avec correspondance partielle

---

## □ Principe général du ppm

- Estimation des probabilités conditionnelles au fur et à mesure de l'encodage.
- Stockage des contextes vus dans le passé uniquement.
- Encodage de lettre nouvelles au début, surtout au début.
- Utilisation du symbole échappe pour signaler une nouvelle entrée.

## □ Remarques:

- Pas besoin de stocker tous les contextes possibles.
- Plusieurs méthodes ont été proposées.



# Algorithme [Cleary and Witten 1984]

---

□ Taille alphabet=M

1. Taille du contexte = N [typiquement égale 5]
2. Tant que nouveau symbole pour ce contexte et  $N > -1$ 
  - envoi du symbole Échappe.
  - $N-$
  - Boucler à 2
3. Si  $N = -1$  [Contexte d'ordre -1 contient tout les symboles]
  - Encodage du nouveau symbole  $P_r = 1/M$
4. Si  $N > -1$ 
  - Mise à jour des tables des compteurs
  - Encodage arithmétique

# Exemple PPM méthode A: ppma [1]

□ Séquence: **this-is**-the-tithe

- Contexte maximale N=2.
- Codage arithmétique m=6: u=111111=63 et l=000000=0
- État initial: encodage des 7 premiers caractères.

Contexte d'ordre -1		
Lettre	Count	Cum_count
t	1	1
h	1	2
i	1	3
s	1	4
e	1	5
-	1	6
Total count		6

Contexte d'ordre zéro		
Lettre	Count	Cum_count
t	1	1
h	1	2
i	2	4
s	2	6
-	1	7
<Esc>	1	8
Total count		8

# Exemple PPM méthode A: ppma [2]

□ Séquence: **this-is-the-tithe**

Contexte d'ordre 1				
Contexte	Lettre	Count	CC	TC
t	h	1	1	
	Esc	1	2	2
h	i	1	1	
	Esc	1	2	2
i	s	2	2	
	Esc	1	3	3
s	-	1	1	
	Esc	1	2	2
-	s	1	1	
	Esc	1	2	2

Contexte d'ordre 2				
Contexte	Lettre	Count	CC	TC
th	i	1	1	
	Esc	1	2	2
hi	s	1	1	
	ESC	1	2	2
is	-	1	1	
	Esc	1	2	2
s-	i	1	1	
	ESC	1	2	2
-i	s	1	1	
	Esc	1	2	2

# Exemple PPM méthode A: ppma [3]

□ Séquence: this-is-the-tithe

▪ 'is -' ∈ contexte d'ordre 2: mise à jour de cette table

▪ l=000000 et u=111111

Contexte	Lettre	Count	CC	TC
is	-	1	1	
	Esc	1	2	2

Contexte d'ordre 2				
Contexte	Lettre	Count	CC	TC
th	i	1	1	
	Esc	1	2	2
hi	s	1	1	
	ESC	1	2	2
is	-	1→2	1→2	
	Esc	1	2→3	2→3
s-	i	1	1	
	ESC	1	2	2
-i	s	1	1	
	Esc	1	2	2

$$u = 0 + \left\lfloor (63 - 0 + 1) \times \frac{1}{2} \right\rfloor - 1 = 31 = (011111)_2$$

$$l = 0 + \left\lfloor (63 - 0 + 1) \times \frac{0}{2} \right\rfloor = 0 = (000000)_2$$

▪ l=000000, u=011111 → env. MSB

▪ E1 → l=000000, u= 111111

▪ Envoi: 0

# Exemple PPM méthode A: ppma [4]

❑ Séquence: this-is-the-tithe

- Mise à jour des tables des contextes d'ordre 1 et d'ordre 0

Contexte d'ordre zéro		
Lettre	Count	Cum_count
t	1	1
h	1	2
i	2	4
s	2	6
-	<b>1→2</b>	<b>7→8</b>
<Esc>	1	<b>8→9</b>
Total count		<b>8→9</b>

Contexte d'ordre 1				
Contexte	Lettre	Count	CC	TC
t	h	1	1	
	Esc	1	2	2
h	i	1	1	
	Esc	1	2	2
i	s	2	2	
	Esc	1	3	3
s	-	<b>1→2</b>	<b>1→2</b>	
	Esc	1	<b>2→3</b>	<b>2→3</b>
-	s	1	1	
	Esc	1	2	2

▪ Envoi: **0**

# Exemple PPM méthode A: ppma [5]

□ Séquence: this-is-the-tithe

- Encodage arithmétique de 't':  $l=000000=0$  et  $u=111111=63$

's- t' n'existe pas  $\rightarrow$  N- (voir le contexte d'ordre 1 ) et envoi de <esc>

$$u = 0 + \left\lfloor (63 - 0 + 1) \times \frac{2}{2} \right\rfloor - 1 = 63 = (111111)_2$$

$$l = 0 + \left\lfloor (63 - 0 + 1) \times \frac{1}{2} \right\rfloor = 32 = (100000)_2$$

- $l=100000$ ,  $u=111111 \rightarrow$  env. MSB
- E2  $\rightarrow$   $l=000000$ ,  $u=111111$
- Il faut aussi faire la mise à jour de cette table.
- Envoi: 01**

Contexte d'ordre 2				
Contexte	Lettre	Count	CC	TC
th	i	1	1	
	Esc	1	2	2
hi	s	1	1	
	ESC	1	2	2
is	-	2	2	
	Esc	1	3	3
<b>s-</b>	<b>i</b>	<b>1</b>	<b>1</b>	
	<b>ESC</b>	<b>1</b>	<b>2</b>	<b>2</b>
-i	s	1	1	
	Esc	1	2	2

# Exemple PPM méthode A: ppma [6]

□ Séquence: this-is-t-the-tithe

- Mise à jour de la table de contexte d'ordre 2
- On passe au contexte d'ordre 1

Contexte d'ordre 2				
Contexte	Lettre	Count	CC	TC
th	i	1	1	
	Esc	1	2	2
hi	s	1	1	
	ESC	1	2	2
is	-	2	2	
	Esc	1	3	3
<b>s-</b>	i	1	1	
	t	1	2	
	<b>ESC</b>	<b>1</b>	<b>3</b>	<b>3</b>
-i	s	1	1	
	Esc	1	2	2

▪ Envoi: **01**

# Exemple PPM méthode A: ppma [7]

□ Séquence: this-is-**t**he-tithe

- Encodage arithmétique de 't':  $l=000000=0$  et  $u=111111=63$

'- t' n'existe pas  $\rightarrow$  N- (voir le contexte d'ordre 0) et envoi de <esc>

$$u = 0 + \left\lfloor (63 - 0 + 1) \times \frac{2}{2} \right\rfloor - 1 = 63 = (111111)_2$$

$$l = 0 + \left\lfloor (63 - 0 + 1) \times \frac{1}{2} \right\rfloor = 32 = (100000)_2$$

- $l=100000$ ,  $u=111111 \rightarrow$  env. MSB
- E2  $\rightarrow$   $l=000000$ ,  $u=111111$
- Il faut aussi faire la mise à jour de cette table.
- Envoi: 011**

Contexte d'ordre 1				
Contexte	Lettre	Count	CC	TC
t	h	1	1	
	Esc	1	2	2
h	i	1	1	
	Esc	1	2	2
i	s	2	2	
	Esc	1	3	3
s	-	2	2	
	Esc	1	3	3
-	<b>s</b>	<b>1</b>	<b>1</b>	
	<b>Esc</b>	<b>1</b>	<b>2</b>	<b>2</b>



# Exemple PPM méthode A: ppma [8]

□ Séquence: this-is-tithe

- Mise à jour de la table de contexte d'ordre 1
- On passe au contexte d'ordre 0

Contexte d'ordre 1				
Contexte	Lettre	Count	CC	TC
t	h	1	1	
	Esc	1	2	2
h	i	1	1	
	Esc	1	2	2
i	s	2	2	
	Esc	1	3	3
s	-	2	2	
	Esc	1	3	3
-	<b>s</b>	<b>1</b>	<b>1</b>	
	<b>t</b>	<b>1</b>	<b>2</b>	
	<b>Esc</b>	<b>1</b>	<b>3</b>	<b>3</b>

▪ Envoi: 011

# Exemple PPM méthode A: ppma [9]

❑ Séquence: this-is-**t**he-tithe

- Encodage arithmétique de 't' l=000000=0 et u=111111=63
- Mise à jour tables ordre 0.

t existe → Count t++

$$u = 0 + \left\lfloor (63 - 0 + 1) \times \frac{1}{9} \right\rfloor - 1 = 6 = (000110)_2$$
$$l = 0 + \left\lfloor (63 - 0 + 1) \times \frac{0}{9} \right\rfloor = 0 = (000000)_2$$

- l=**000**000, u=**000**110 → env. 000
- 3xE1 → l=000000, u= 110111
- **Envoi: 011000**

Contexte d'ordre zéro		
Lettre	Count	Cum_count
t	1→2	1→2
h	1	2→3
i	2	4→5
s	2	6→7
-	2	8→9
<Esc>	1	9→10
Total count		9→10

# Exemple PPM méthode A: ppma [10]

□ Séquence: this-is-**th**e-tithe

Le contexte du second ordre '**-t**' n'existe pas → on passe directement au premier ordre et on effectue la mise à jour.

Contexte d'ordre 2				
Contexte	Lettre	Count	CC	TC
th	i	1	1	
	Esc	1	2	2
hi	s	1	1	
	ESC	1	2	2
is	-	2	2	
	Esc	1	3	3
s-	i	1	1	
	t	1	2	
	ESC	1	3	3
-i	s	1	1	
	Esc	1	2	2

■ **Envoi:** 011000

# Exemple PPM méthode A: ppma [11]

□ Séquence: this-is-**th**e-tithe

Ajout du contexte '**-t h**'

Contexte d'ordre 2				
Contexte	Lettre	Count	CC	TC
th	i	1	1	
	Esc	1	2	2
hi	s	1	1	
	ESC	1	2	2
is	-	2	2	
	Esc	1	3	3
s-	i	1	1	
	t	1	2	
	ESC	1	3	3
-i	s	1	1	
	Esc	1	2	2
-t	h	1	1	
	Esc	1	2	2

■ **Envoi:** 011000

# Exemple PPM méthode A: ppma [12]

❑ Séquence: this-is-**th**e-tithe

- Encodage arithmétique de 't'  
l=000000=0 et u=110111=55

$$u = 0 + \left\lfloor (55 - 0 + 1) \times \frac{1}{2} \right\rfloor - 1 = 27 = (011011)_2$$

$$l = 0 + \left\lfloor (55 - 0 + 1) \times \frac{0}{2} \right\rfloor = 0 = (000000)_2$$

- l=0000000, u=011011 → env. 0
- E1 → l=000000, u= 110111
- Envoi: 0110000**

t h existe → count ++

Contexte d'ordre 1				
Contexte	Lettre	Count	CC	TC
<b>t</b>	<b>h</b>	<b>1→2</b>	<b>1→2</b>	
	<b>Esc</b>	<b>1</b>	<b>2→3</b>	<b>2→3</b>
h	i	1	1	
	Esc	1	2	2
i	s	2	2	
	Esc	1	3	3
s	-	1	1	
	Esc	1	2	2
-	s	1	1	
	Esc	1	2	2
-	t	1	1	
	Esc	1	2	2

# Exemple PPM méthode A: ppma [13]

□ Séquence: this-is-**th**e-tithe

- Mise à jour de la table du contexte d'ordre zéro

**Et ainsi de suite ...**

Contexte d'ordre zéro		
Lettre	Count	Cum_count
t	2	2
h	1→2	3→4
i	2	5→6
s	2	7→8
-	2	9→10
<Esc>	1	10→11
Total count		10→11

- **Envoi:** 0110000

# Le symbole <Esc>

## □ ppma

- On rajoute un symbole <Esc> pour chaque contexte.
- Total count (TC) est dilaté de 1.

## □ Ppmb [variante de ppma]

- Nouvelle entrée à la table → count de <ESC> ++
- Un symbole nouveau → initialisation à 0 au lieu de 1.
- TC est égale au nombre occurrence totale dans le contexte.

Contexte d'ordre 4 ppma			
Contexte	Lettre	Count	CC
prob	a	10	10
	l	9	19
	o	3	22
	ESC	1	23
Total count			23

Contexte d'ordre 4 ppmb			
Contexte	Lettre	Count	CC
prob	a	9	9
	l	8	17
	o	2	19
	ESC	3	22
Total count			22

# Exemple: ppmb

❑ État initial: 9 x probability+ 8 x problem

❑ Encodage: probability probosics problem probosics probosics

État initial		
Contexte	Lettre	Count
prob	a	8
	l	7
	ESC	2
Total count		17

probability		
Contexte	Lettre	Count
prob	<b>a</b>	<b>9</b>
	l	7
	ESC	2
Total count		18

probosics		
Contexte	Lettre	Count
prob	a	9
	l	7
	<b>o</b>	<b>0</b>
	<b>ESC</b>	<b>3</b>
Total count		19

problelem		
Contexte	Lettre	Count
prob	a	9
	<b>l</b>	<b>8</b>
	o	0
	ESC	3
Total count		20

probosics		
Contexte	Lettre	Count
prob	a	9
	l	8
	<b>o</b>	<b>1</b>
	ESC	3
Total count		21

probosics		
Contexte	Lettre	Count
prob	a	9
	l	8
	<b>o</b>	<b>2</b>
	ESC	3
Total count		22



# ppmc

---

## ❑ Ppmb [variante de ppma]

- Nouvelle entrée à la table → count de <ESC> ++
- Un symbole nouveau → **initialisation à 0 au lieu de 1.**
- TC est égale au nombre occurrence totale dans le contexte.

## ❑ Ppmc [variante de ppmb]

- Nouvelle entrée à la table → count de <ESC> ++
- Un symbole nouveau → **initialisation à 1.**
- TC est dilaté chaque fois il y a une nouvelle entrée.

# Exemple: ppmc

❑ État initial: 9 x probability+ 8 x problem

❑ Encodage: probability probosics problem probosics probosics

État initial		
Contexte	Lettre	Count
prob	<b>a</b>	<b>9</b>
	<b>l</b>	<b>8</b>
	ESC	2
Total count		<b>19</b>

probability		
Contexte	Lettre	Count
prob	<b>a</b>	<b>10</b>
	l	8
	ESC	2
Total count		20

probosics		
Contexte	Lettre	Count
prob	a	10
	l	8
	<b>o</b>	<b>1</b>
	<b>ESC</b>	<b>3</b>
Total count		22

problelem		
Contexte	Lettre	Count
prob	a	10
	<b>l</b>	<b>9</b>
	o	1
	ESC	3
Total count		23

probosics		
Contexte	Lettre	Count
prob	a	10
	l	9
	<b>o</b>	<b>2</b>
	ESC	3
Total count		24

probosics		
Contexte	Lettre	Count
prob	a	10
	l	9
	<b>o</b>	<b>3</b>
	ESC	3
Total count		25

# Principe d'exclusion

---

## ❑ Codage arithmétique

- Sous-intervalle réduit  $\rightarrow$  application E1, E2 et E3  $\rightarrow$  plus de bits sont nécessaires.
- Si l'on réduit le nombre de symboles  $\rightarrow$  sous-intervalles plus large  $\rightarrow$  moins de bits sont nécessaire

## ❑ Le principe d'exclusion

- Détecter les situations où l'on peut éliminer certains symboles des tables de contexte.
- Lors du passage d'un contexte d'ordre  $k$  à un autre contexte d'ordre  $k-1$  les symboles communs peuvent être éliminés.

# Exemple: Principe d'exclusion

État initial Contexte d'ordre 2		
Contexte	Lettre	Count
ob	<b>l</b>	10
	<b>o</b>	3
	ESC	2
Total count		15

État initial Contexte d'ordre 1		
Contexte	Lettre	Count
b	<b>l</b>	5
	<b>o</b>	3
	a	4
	r	2
	e	2
	ESC	5
Total count		21

Encodage: de la lettre 'a':

On examine au départ le contexte d'ordre 2.

La lettre 'a' n'y figure pas → envoi de <Esc>.

<Esc> → on sait alors que ce n'est ni 'l' ni 'o'.

Lors du passage au contexte d'ordre 1 on peut éliminer les entrées 'l' et 'o'.

État initial Contexte d'ordre 1		
Contexte	Lettre	Count
b	a	4
	r	2
	e	2
	ESC	<b>3</b>
Total count		<b>11</b>

Codage arithmétique en utilisant les counts du nouveau tableau.

Utilisation de l'ancien tableau pour la mise à jour.

# La transformation de Burrows-Wheeler (1)

---

## □ Algorithme de BWT

- Utilisation du contexte du symbole encodé.
- Il faut que toute la séquence soit disponible dès le début.
- Transformation d'une séquence de N symboles en une autre séquence de N symboles.
- La raison en est que la nouvelle séquence est probablement plus appropriée pour d'autres méthodes de compression.

## □ Méthodes de compression

- MTF
- RLE
- Huffman

# La transformation de Burrows-Wheeler (2)

---

## □ Transformation de la séquence de taille N

- Création de  $N-1$  séquences à partir d'un décalage cyclique.
- Arrangement de ces  $N-1$  séquences avec la séquence originale selon un ordre lexicographique.
- Sélection des dernières lettres de chaque séquence  $\rightarrow L$
- Transmission de cette séquence  $L$  (de taille  $N$ ).
- Transmission l'ordre de la séquence originale dans l'arrangement.
- À partir de la séquence  $L$  et de l'ordre on peut reconstituer la séquence originale.
- Séquence taille  $N$ :  $N+1$  éléments transmis.
- La nouvelle séquence présente une structure particulière.

# Exemple: La transformation BWT

Permutation  
cyclique

t h i s - i s - t h e

h i s - i s - t h e t

i s - i s - t h e t h

s - i s - t h e t h i

- i s - t h e t h i s

i s - t h e t h i s -

s - t h e t h i s - i

- t h e t h i s - i s

t h e t h i s - i s -

h e t h i s - i s - t

e t h i s - i s - t h

Tri

- i s - t h e t h i s

- t h e t h i s - i s

e t h i s - i s - t h

h e t h i s - i s - t

h i s - i s - t h e t

i s - i s - t h e t h

i s - t h e t h i s -

s - i s - t h e t h i

s - t h e t h i s - i

t h e t h i s - i s -

t h i s - i s - t h e

# Exemple: Encodage BWT

## ❑ Séquence L

- On voit bien un certaine structure

Séquence L

## ❑ Encodage

- 'sshtth-ii-e', 10

0

- i s - t h e t h i s  
- t h e t h i s - i s  
e t h i s - i s - t h  
h e t h i s - i s - t  
h i s - i s - t h e t  
i s - i s - t h e t h  
i s - t h e t h i s -  
s - i s - t h e t h i  
s - t h e t h i s - i  
t h e t h i s - i s -  
t h i s - i s - t h e

Ordre = 10



# Décodage BWT (1)

---

## □ Encodage

- 'sshtth-ii-e' , 10
- On voit qu'on la transformation résulte en une séquence de même taille que l'originale + un indice → expansion.
- Sauf que il y a des répétitions dans la séquence.
- Ce phénomène est plus frappant pour une séquence plus longue.

## □ Séquence reçue: L= sshtth-ii-e

- Génération de la séquence F qui comporte les premiers éléments de chaque ligne après le tri.
- F est simplement le résultat du tri de la séquence L.
- F=--ehiisstt

# Décodage BWT (2)

---

## ❑ Observation

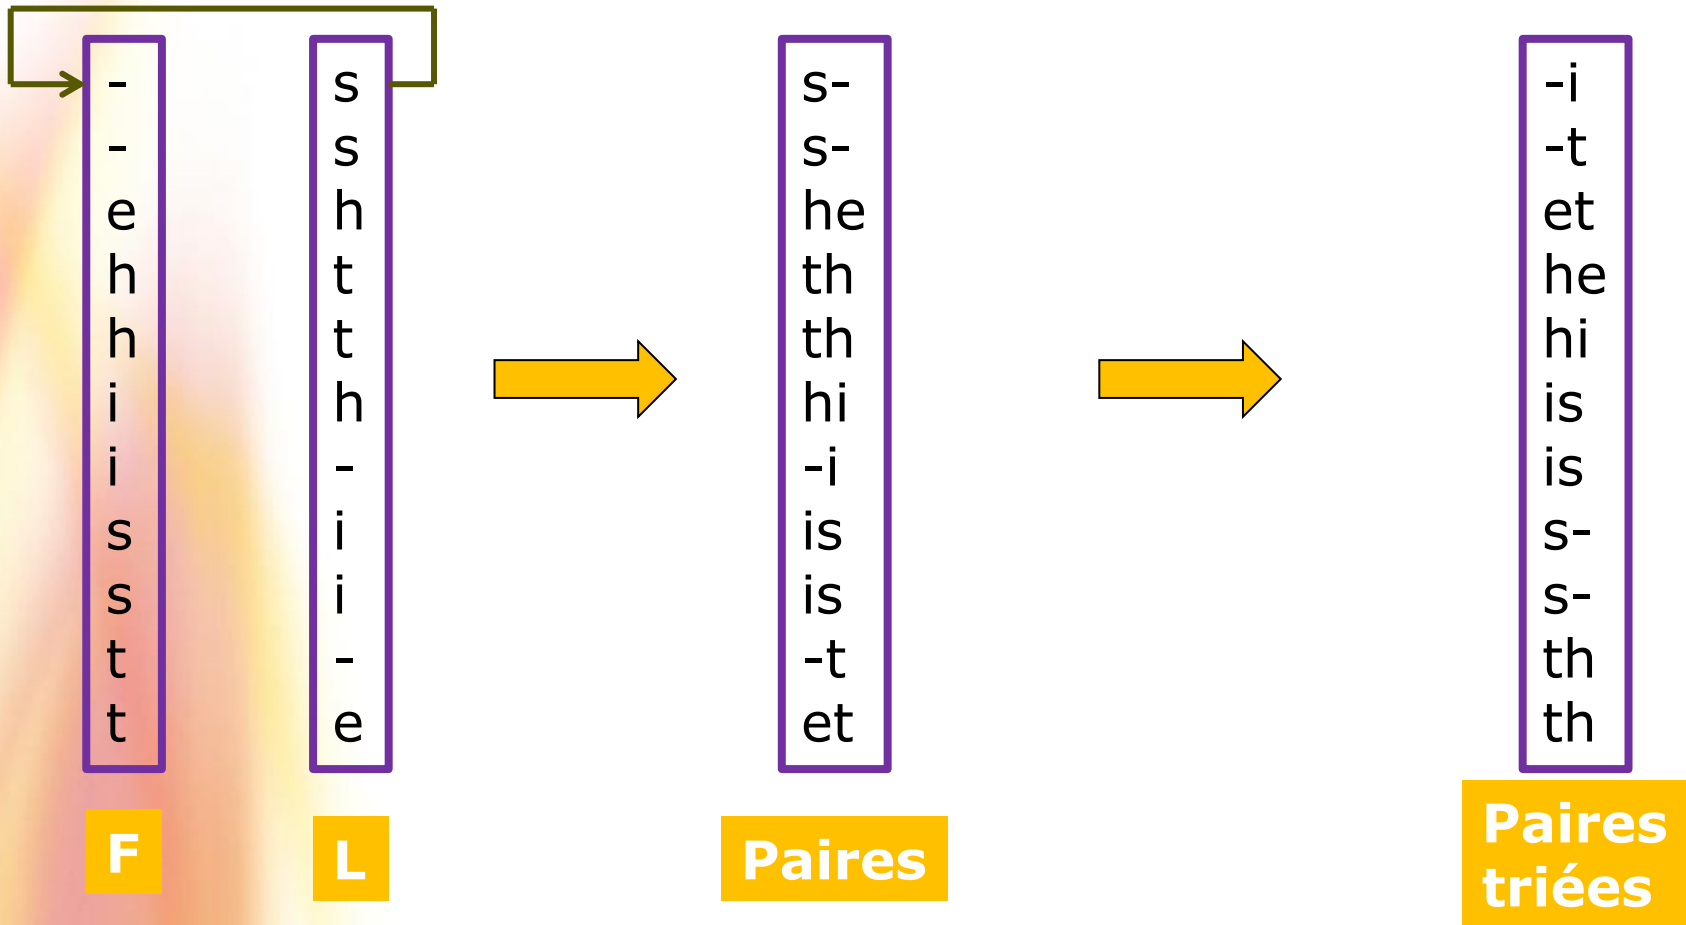
- Génération de F(First) → il suffit de trier L
- On constate que la première colonne F et la dernière colonne L(Last) forment toutes les paires possibles.

## ❑ Algorithme: approche ajout-tri

- Répéter:
  - Ajouter une copie de L(Last)
  - Trier
- Jusqu'à obtenir une longueur = N
- L'indice nous indique quelle ligne choisir.

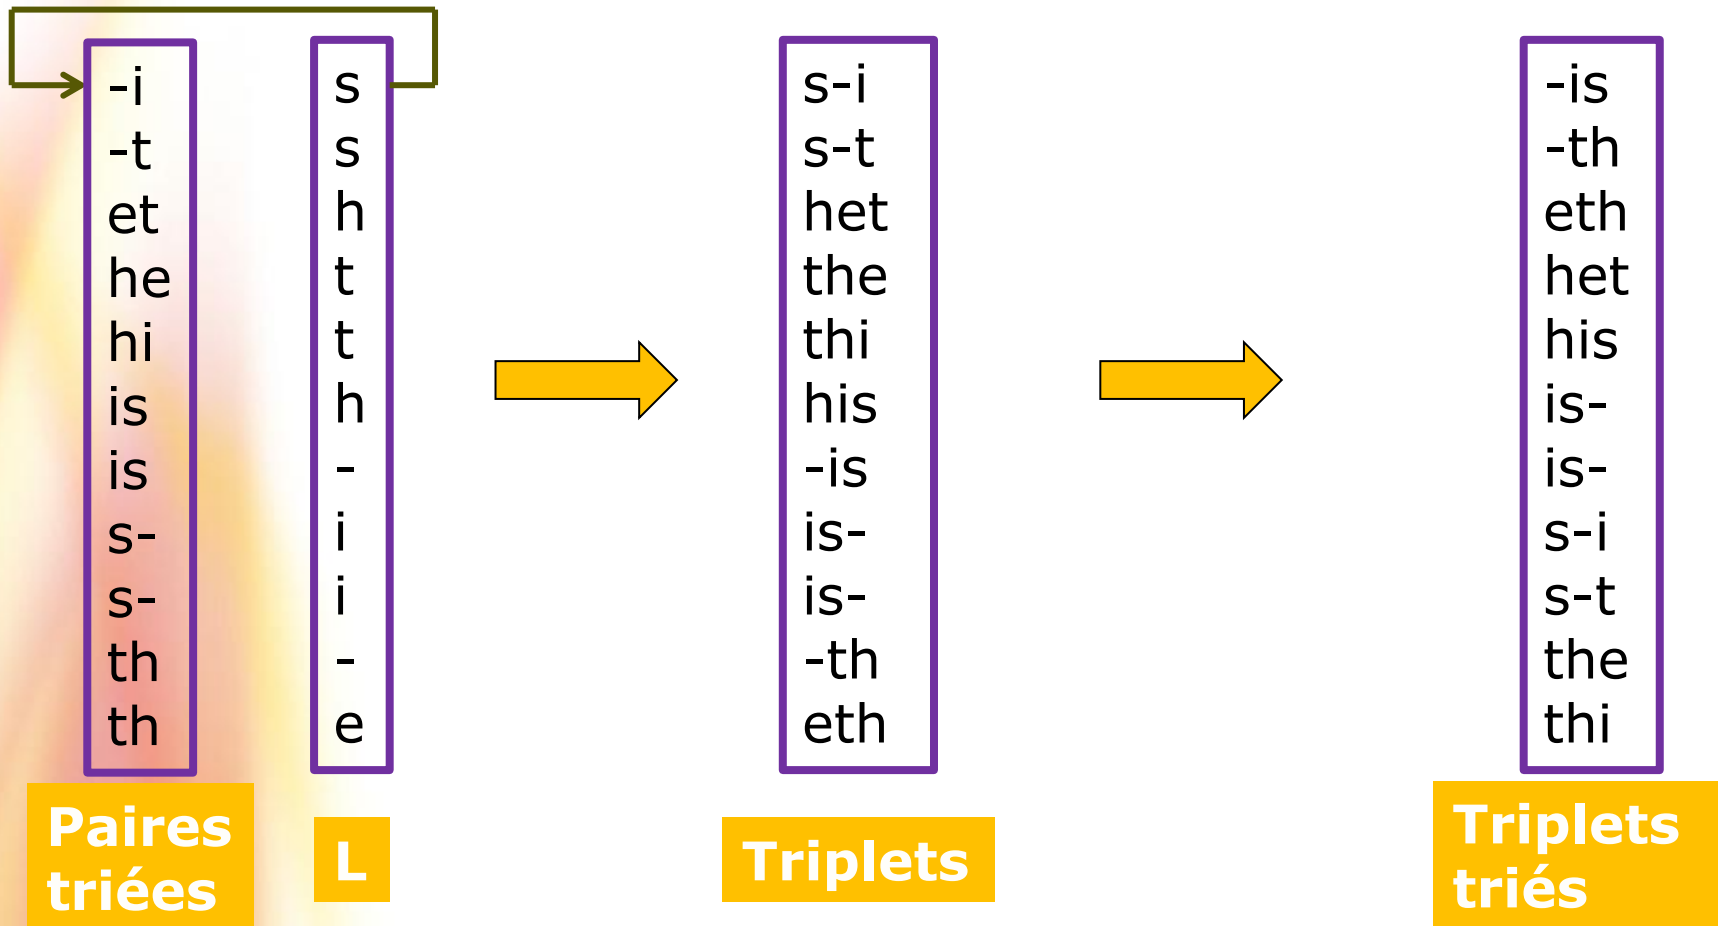
# Exemple: Décodage BWT (1)

❑ Séquence: L= ssth-ii-e, Indice: 10



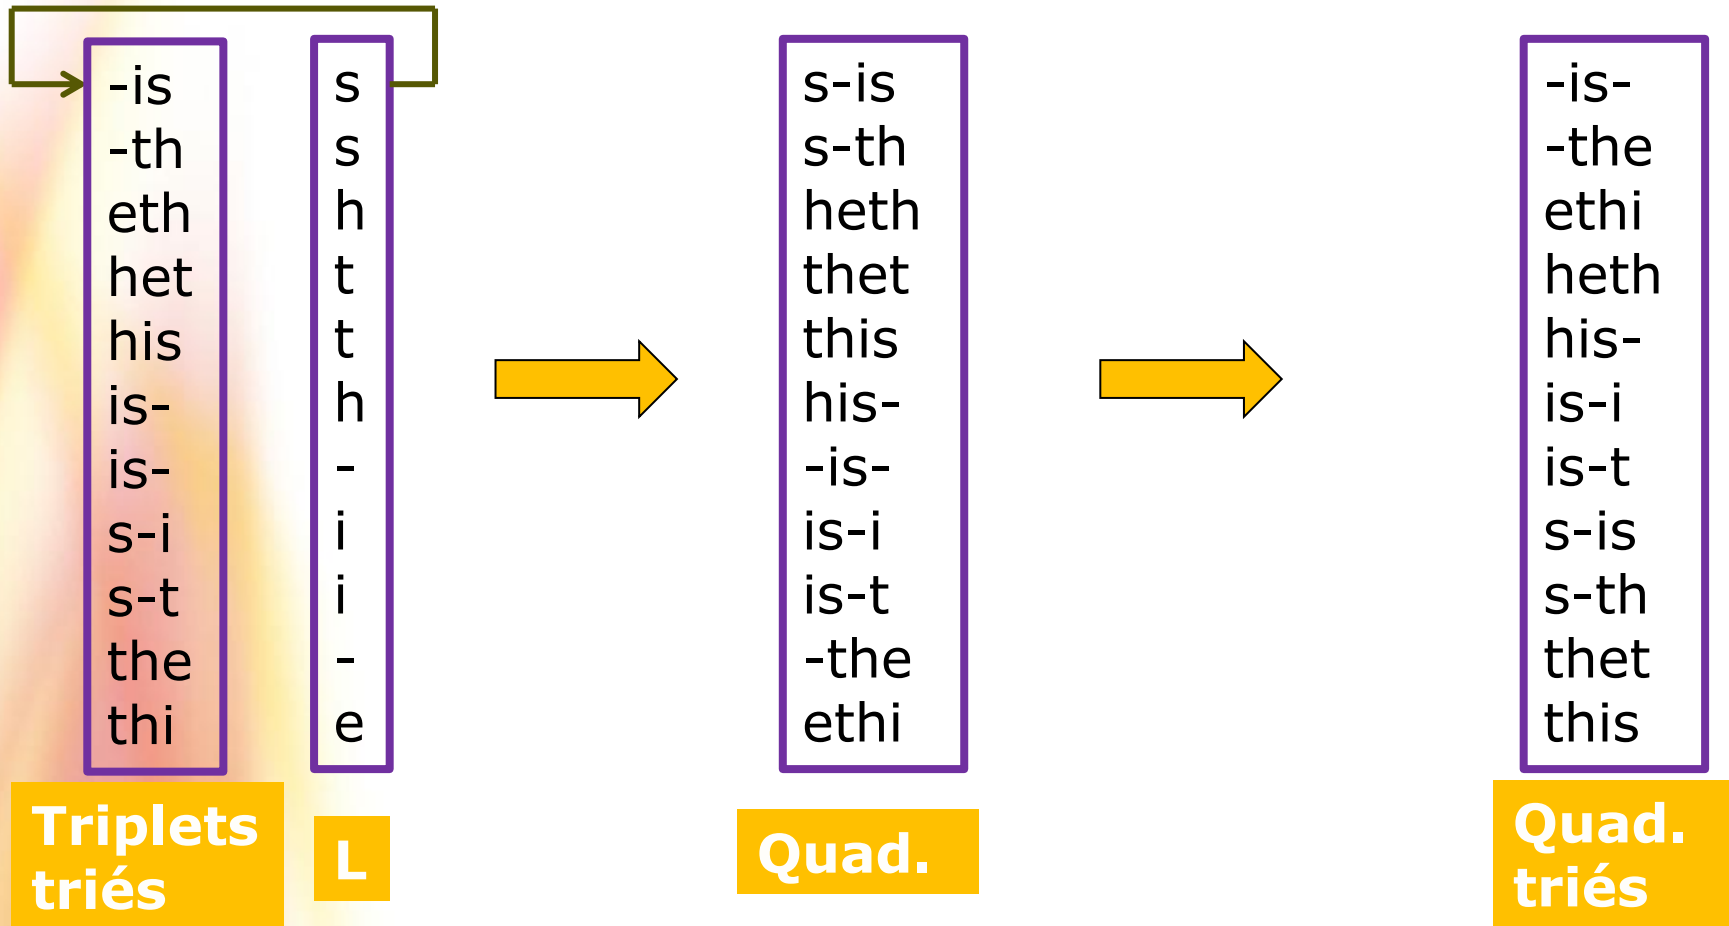
# Exemple: Décodage BWT (2)

❑ Séquence: L= ssthth-ii-e, Indice: 10



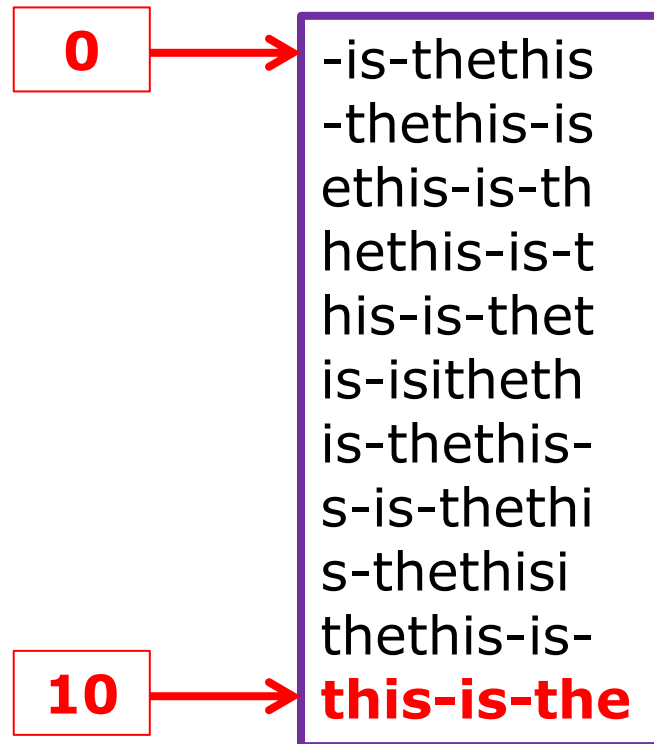
# Exemple: Décodage BWT (3)

❑ Séquence: L= ssthth-ii-e, Indice: 10



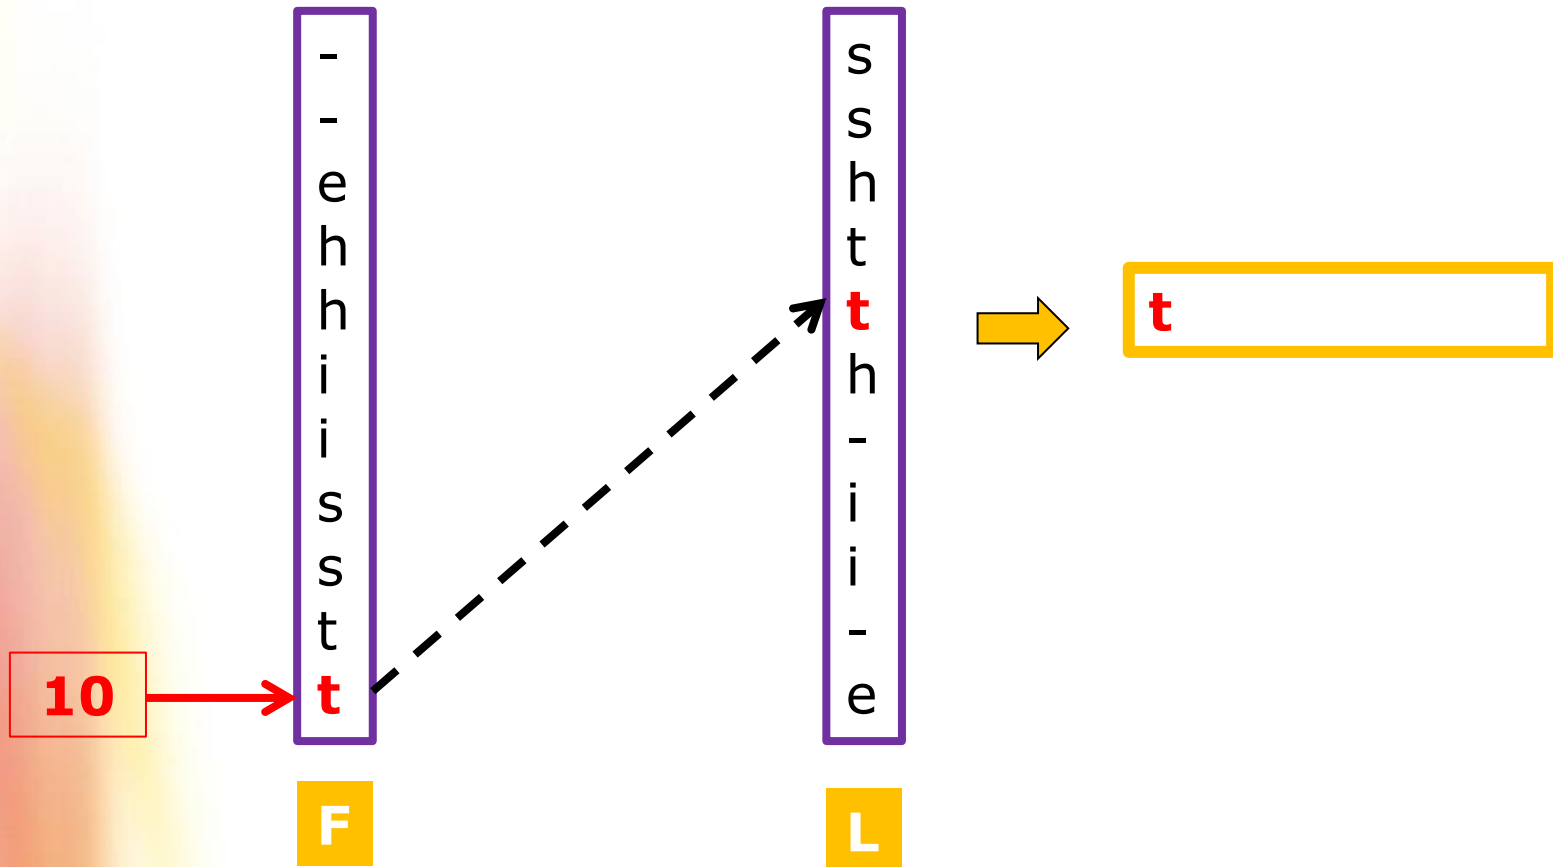
# Exemple: Décodage BWT (3)

❑ Séquence: L= sstth-ii-e, Indice: 10



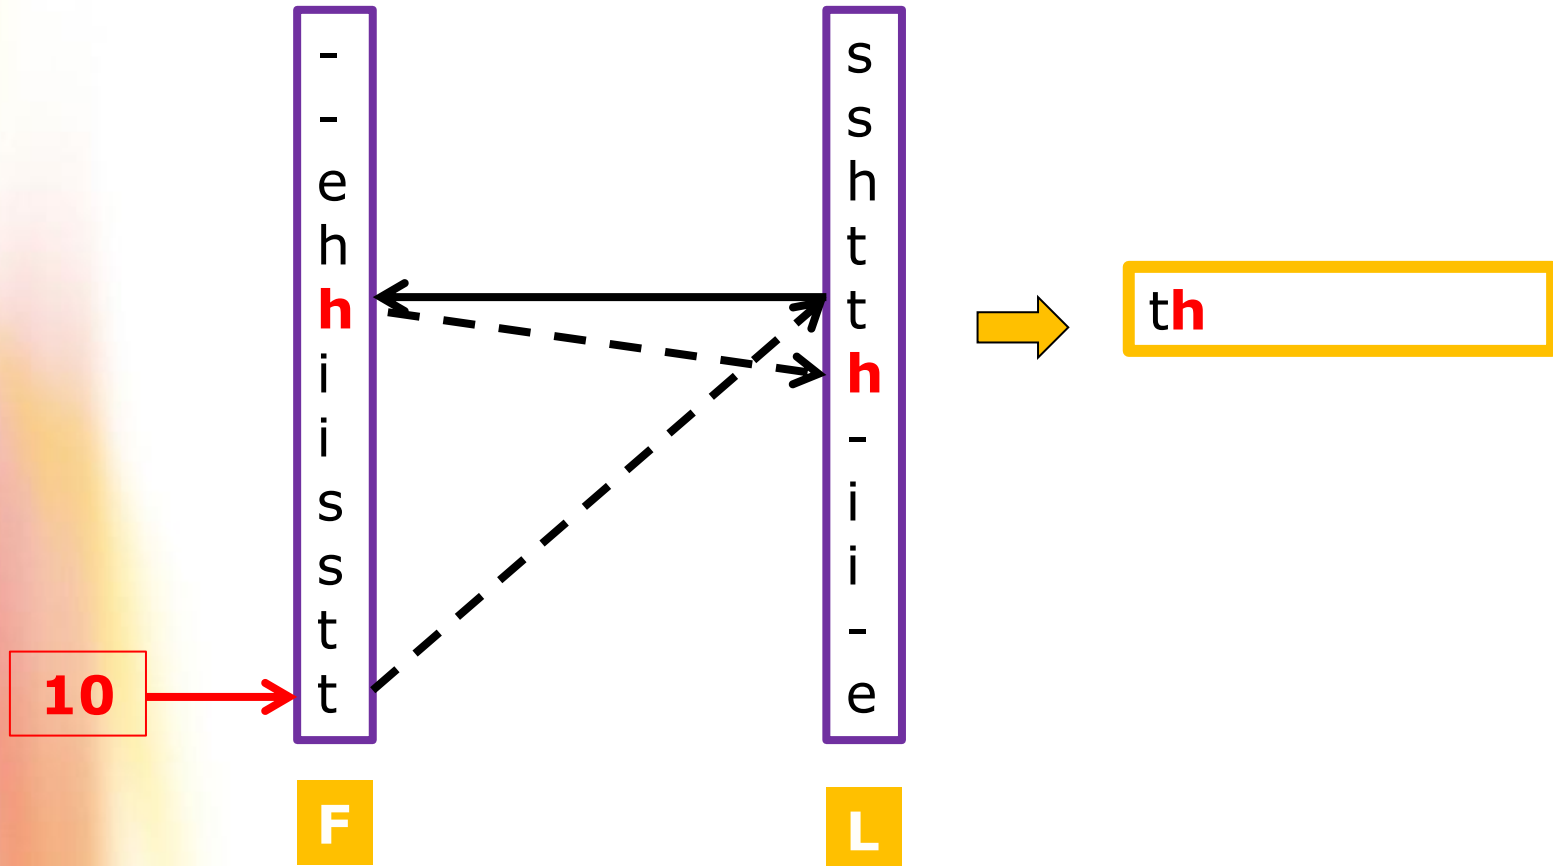
# Exemple: Décodage BWT (4) [une autre méthode]

❑ Séquence: L= ssth-ii-e, Indice: 10



# Exemple: Décodage BWT (5) [une autre méthode]

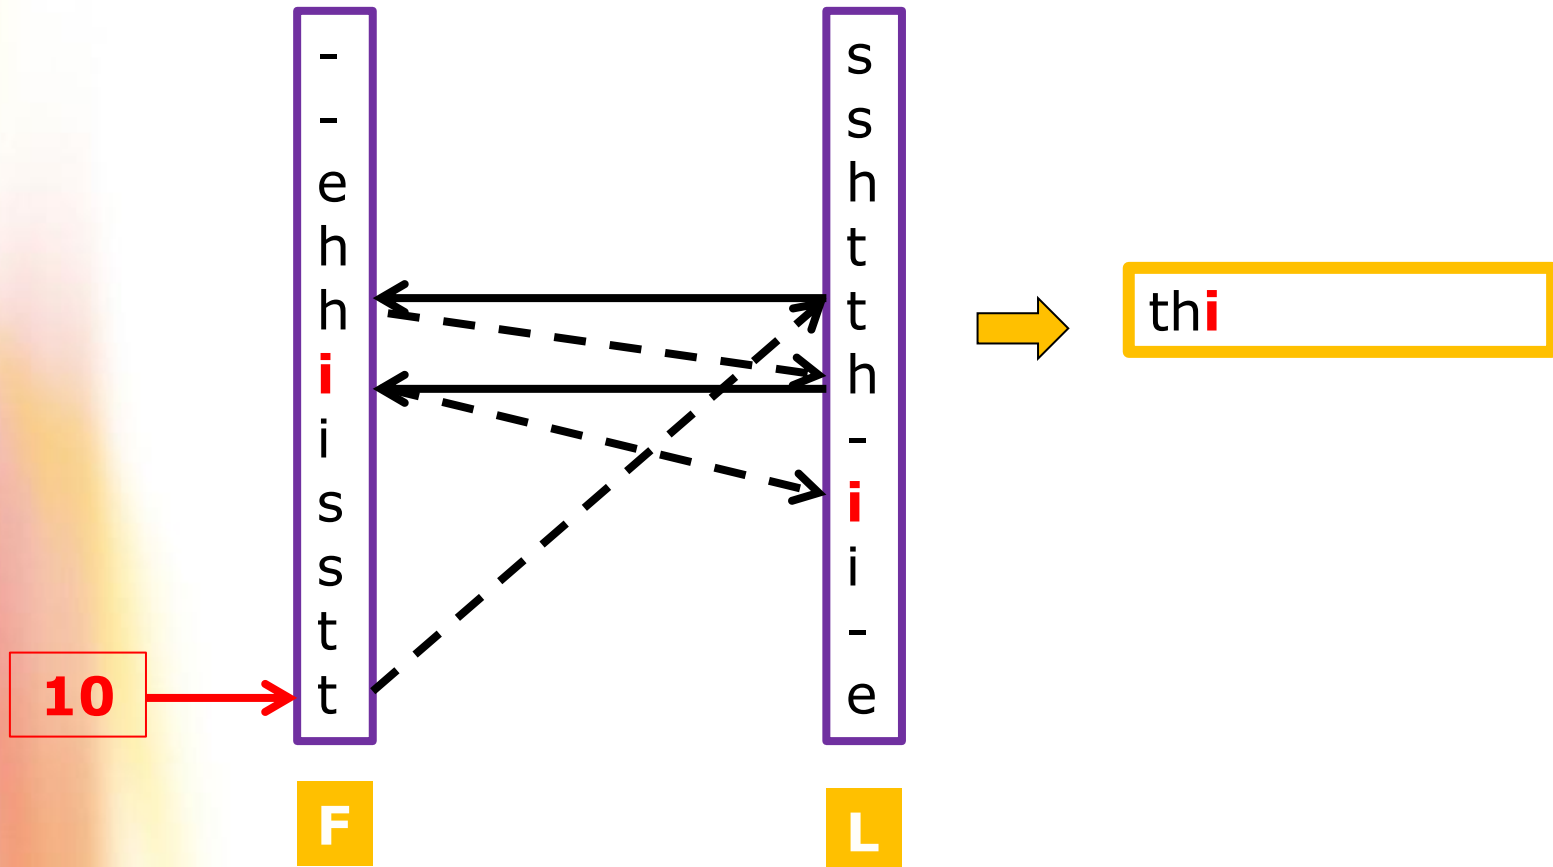
❑ Séquence: L= sshth-ii-e, Indice: 10





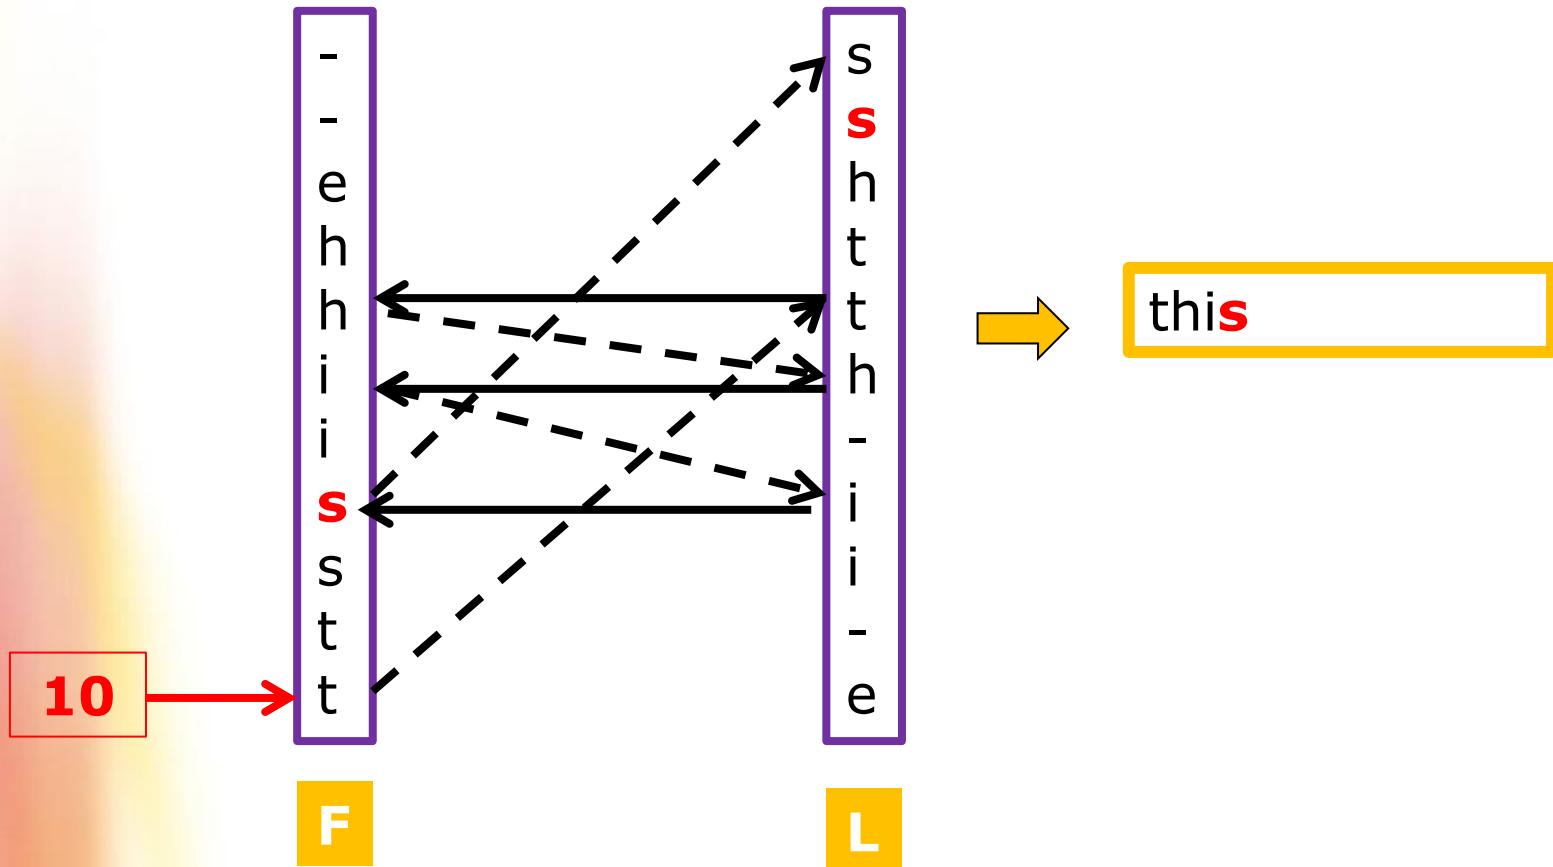
# Exemple: Décodage BWT (6) [une autre méthode]

❑ Séquence: L= ssth-ii-e, Indice: 10



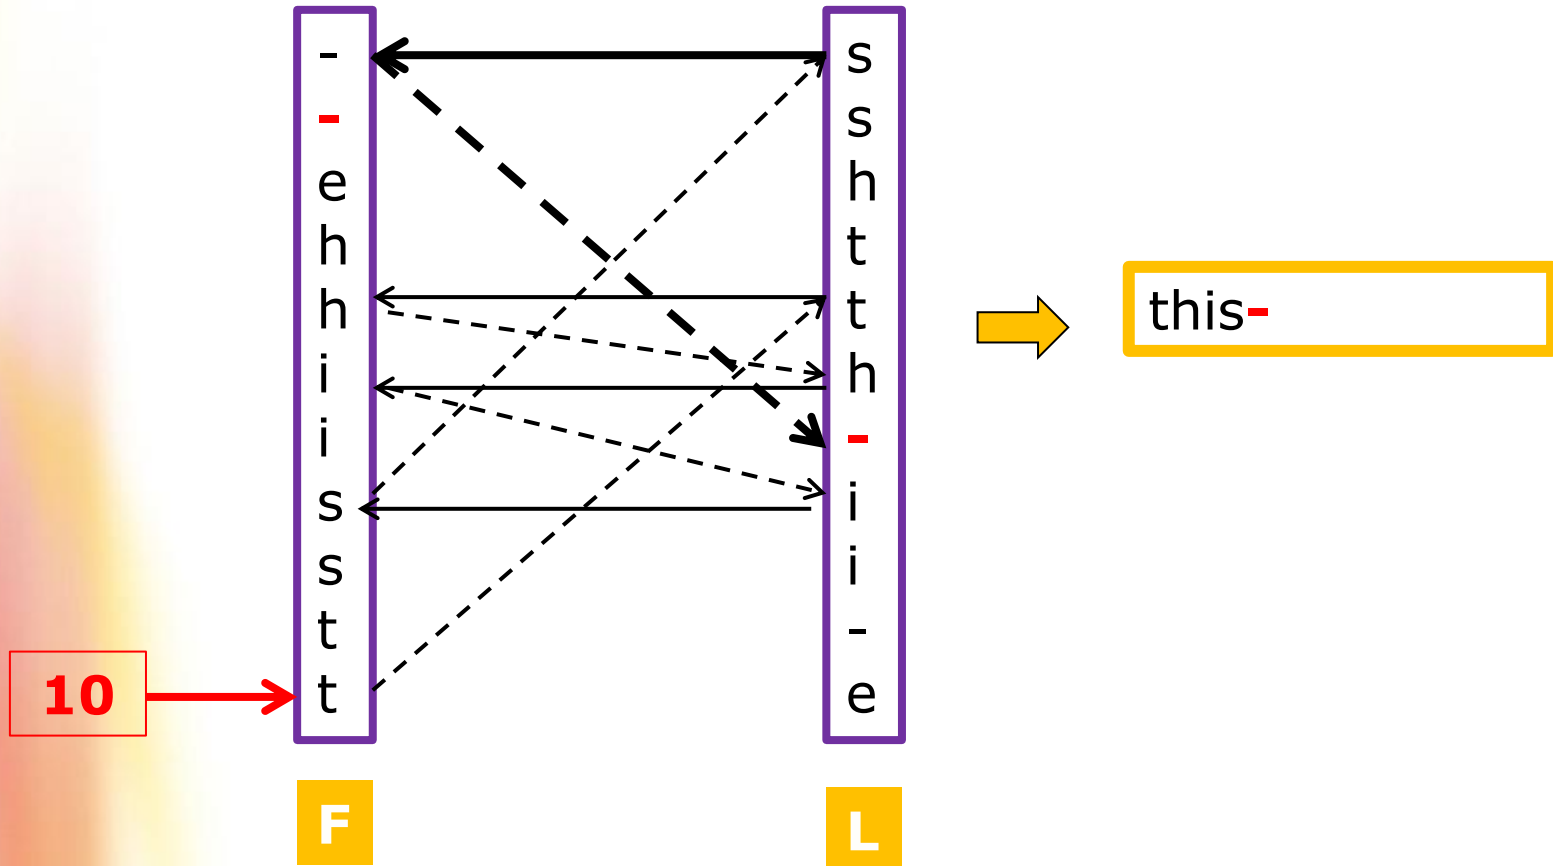
# Exemple: Décodage BWT (7) [une autre méthode]

❑ Séquence: L= sstth-ii-e, Indice: 10




# Exemple: Décodage BWT (8) [une autre méthode]

❑ Séquence: L= ssth-ii-e, Indice: 10



# Exemple: Décodage BWT (9) [une autre méthode]


❑ Séquence: L= ssth-ii-e, Indice: 10



# Exemple: Décodage BWT (10)


## [une autre méthode]

❑ Séquence: L= sshth-ii-e, Indice: 10



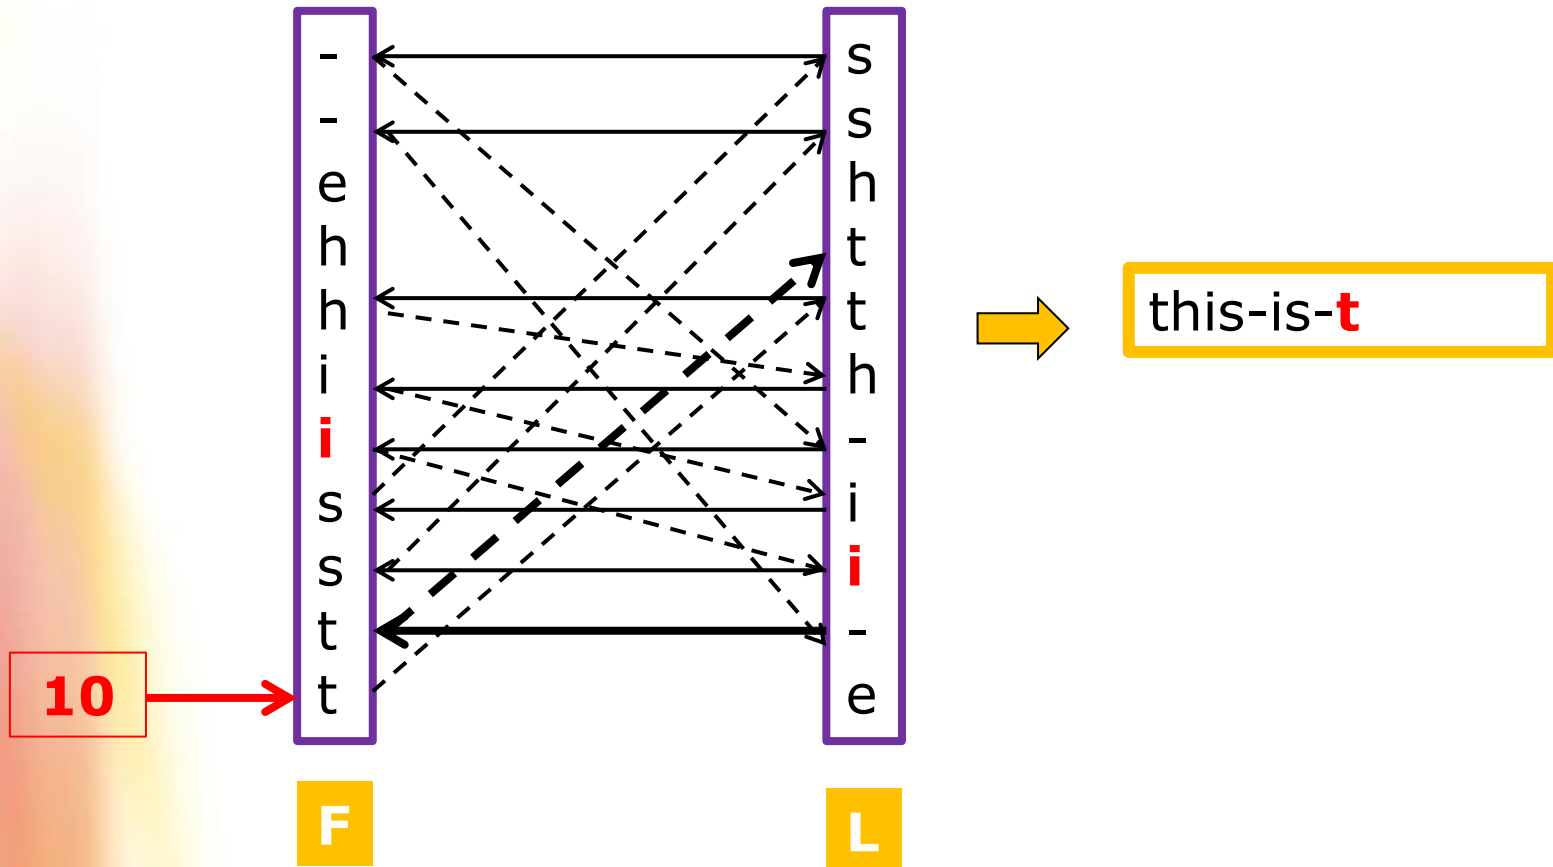
# Exemple: Décodage BWT (10) [une autre méthode]

❑ Séquence: L= ssth-ii-e, Indice: 10



# Exemple: Décodage BWT (11) [une autre méthode]


❑ Séquence: L= sshth-ii-e, Indice: 10



# Exemple: Décodage BWT (12)

## [une autre méthode]

❑ Séquence: L= ssth-ii-e, Indice: 10

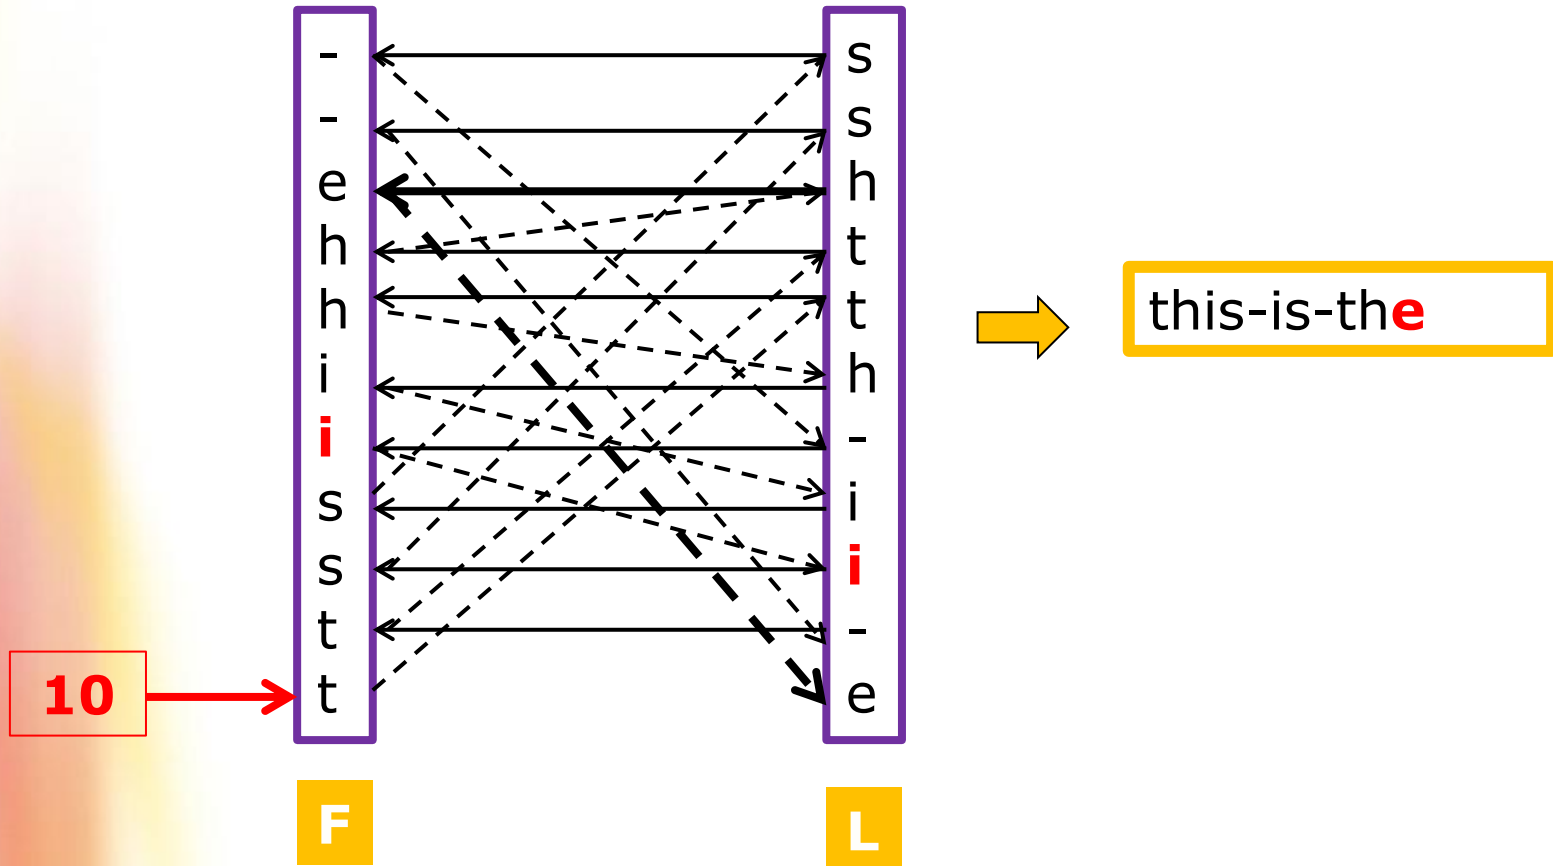




# Exemple: Décodage BWT (13)

## [une autre méthode]

❑ Séquence: L= ssth-ii-e, Indice: 10



# Codage MTF: Move-to-Front

---

## □ Observation

- La transformation BWT donne une séquence avec une structure de lettres identiques qui se répètent successivement.
  - Pour bénéficier de cette structure on utilise le codage MTF.
  - On commence par un tri initial de l'alphabet de la source.
  - On assigne '0' au symbole au haut de la liste.
  - Le suivant '1' et ainsi de suite ('2' pour le suivant, '3' ...).
  - Nouvelle lettre → envoi du nombre correspondant.
    - Déplacement de la lettre au top de la liste.
- Ainsi une série de lettres identiques consécutives se traduit par une série de '0'

# Exemple de codage MTF (1)

## □ Observation

- L= **s**shthh-ii-e
- A={-,e,h,i,s,t}
- Arrangement initial

0	1	2	3	<b>4</b>	5
-	e	h	i	<b>s</b>	t

- Séquence à envoyer: **4**
- Mise à jour de la table

<b>0</b>	1	2	3	4	5
<b>s</b>	-	e	h	i	t

# Exemple de codage MTF (2)

## □ Observation

- L= s**s**htth-ii-e

<b>0</b>	1	2	3	4	5
<b>s</b>	-	e	h	i	t

- Séquence à envoyer: 4 **0**
- Mise à jour de la table

<b>0</b>	1	2	3	4	5
<b>s</b>	-	e	h	i	t

# Exemple de codage MTF (3)

## □ Observation

- L= ss**h**tth-ii-e

0	1	2	<b>3</b>	4	5
s	-	e	<b>h</b>	i	t

- Séquence à envoyer: 4 0 **3**
- Mise à jour de la table

<b>0</b>	1	2	3	4	5
<b>h</b>	s	-	e	i	t

# Exemple de codage MTF (4)

## □ Observation

- L= ssh**t**th-ii-e

0	1	2	3	4	<b>5</b>
h	s	-	e	i	<b>t</b>

- Séquence à envoyer: 4 0 3 **5**
- Mise à jour de la table

<b>0</b>	1	2	3	4	5
<b>t</b>	h	s	-	e	i

# Exemple de codage MTF (5)

## □ Observation

- L= ssht**t**h-ii-e

<b>0</b>	1	2	3	4	5
<b>t</b>	h	s	-	e	i

- Séquence à envoyer: 4 0 3 5 **0**
- Mise à jour de la table

<b>0</b>	1	2	3	4	5
<b>t</b>	h	s	-	e	i

# Exemple de codage MTF (6)

## □ Observation

- L= sshth-ii-e

0	<b>1</b>	2	3	4	5
t	<b>h</b>	s	-	e	i

- Séquence à envoyer: 4 0 3 5 0 **1**
- Mise à jour de la table

<b>0</b>	1	2	3	4	5
<b>h</b>	t	s	-	e	i



# Exemple de codage MTF (7)

---

## □ Observation

- L= sshtth-ii-e
- Séquence à envoyer: 4 0 3 5 0 1 3 5 0 1 5
- Le résultat ne montre pas beaucoup de '0' car l'exemple traite une séquence courte.
- Mais si on considère un fichier texte de grande taille on va avoir plus de séquence de '0' et des valeurs généralement faible.
- Comme les faibles valeurs sont plus fréquentes on peut utiliser un code qui assigne de petits code aux valeurs faibles.
- → **Huffman ou codage arithmétique.**