



# Cours

**Modèles de Markov Cachés (MMC)**  
**(En anglais: Hidden Markov Models : HMM)**

# Les modèles de Markov observables

- Temps discret :  $t = 1, 2, \dots, T$
- Une chaîne ou *processus de Markov* est une **séquence** de variables aléatoires :

$$\{X_1, X_2, \dots, X_T\}$$

- Ces variables aléatoires prennent leurs valeurs dans l'espace d'états :

$$S = \{q_1, q_2, \dots, q_N\}.$$

- On dit que le processus stochastique **émet des séquences d'états**  $q_1, q_2, \dots, q_T$
- Un processus stochastique est dit **markovien** s'il vérifie les deux propriétés suivantes :

1. Historique limité
2. Indépendance du temps

# Historique limité

- L'état courant dépend d'un nombre constant d'états précédents.
- Par exemple, on parle de processus du **premier ordre** lorsque:

$$P(X_t = q_j | X_1, X_2, \dots, X_{t-1}) = P(X_t = q_j | X_{t-1})$$

**$X_t = q_j$** : l'état observé à l'instant t est  $q_j$

- Autrement :  
« le future ne dépend que de l'état courant et non pas du passé! »
- Donc:

$$P(q_1, q_2, \dots, q_T) = P(q_1) \times P(q_2 | q_1) \times \cdots \times P(q_T | q_{T-1})$$

# Indépendance du temps

- Les probabilités de transition (passage d'un état à un autre) ne varie pas avec le temps ; cela est formellement exprimé comme suit (*toujours pour un processus du premier ordre*):

$$P(X_t = q_j | X_{t-1} = q_i) = a_{ij}$$

Avec:

$$\begin{aligned} a_{ij} &\geq 0 \\ \sum_{j=1}^N a_{ij} &= 1 \\ 1 \leq i, j &\leq N \end{aligned}$$

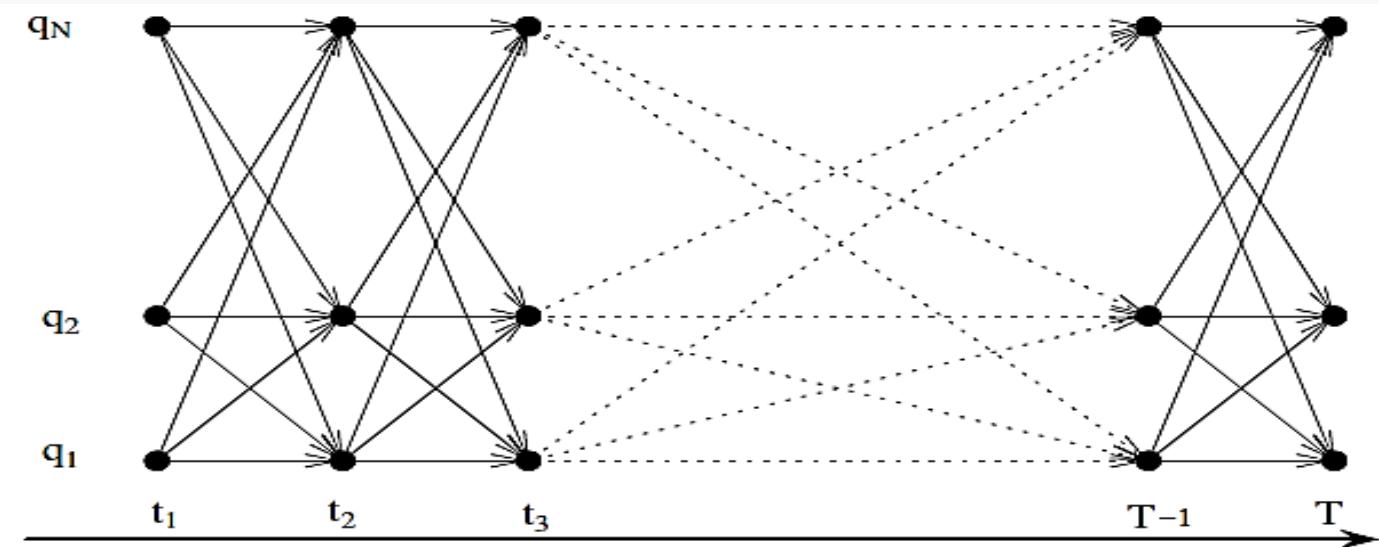
- On dénote A la matrice des probabilités de transition.
- On dit que le processus de Markov auquel nous avons affaire est **stationnaire**.

# Représentation du modèle de Markov

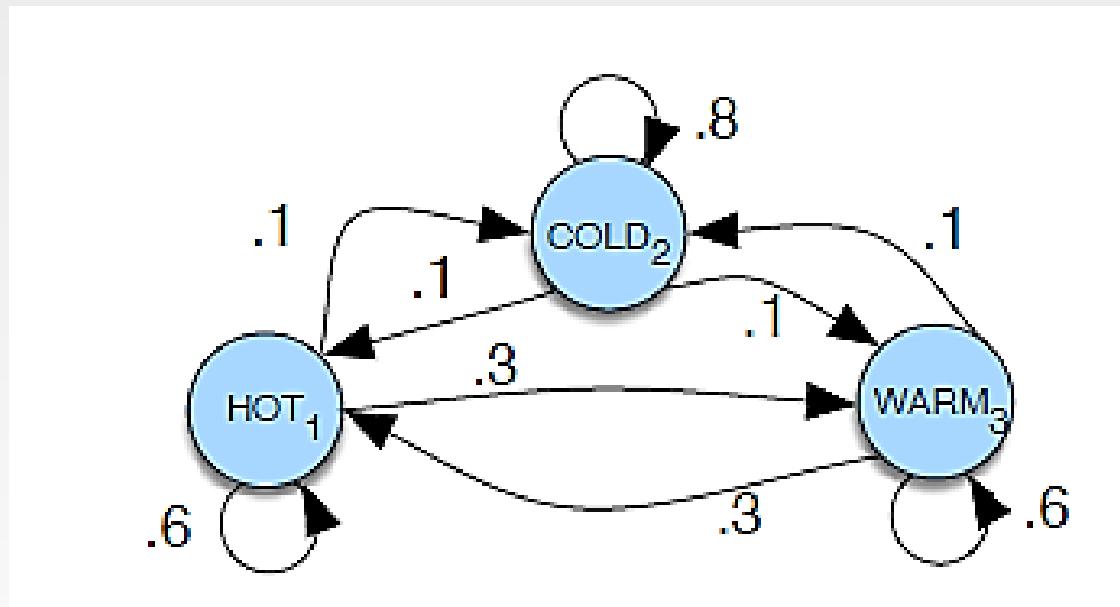
- Une chaîne de Markov peut être alors vue comme un **automate probabiliste**.
- Différemment d'un automate ordinaire, l'état initial (*à l'instant t=1*) peut être n'importe quel élément dans S.
- Plus formellement, on définit la loi de probabilité de l'état initial  $\Pi = \{\pi_i\}$  tel que :

$$\pi_i = P(X_1 = q_i) \text{ avec } \sum_{i=1}^N \pi_i = 1$$

- **L'évolution** d'un modèle de Markov au cours du temps peut être schématisée par un treillis



# Exemple d'une chaîne de Markov pour la prédition du temps



Sachant que  $\Pi = \{0.1, 0.7, 0.2\}$ , trouver la probabilité des séquences:

- COLD HOT COLD HOT
- HOT HOT HOT HOT

# Modèles de Markov Cachés

- La séquence d'états est **inobservable** (*d'où le nom caché du modèle*).
- on peut plutôt observer la séquence des symboles émis par les états :

$$O = O_1, O_2, \dots, O_T .$$

- En plus de la propriété de Markov, il y a l'**Indépendance de la sortie**:

$$P(o_i|q_1, \dots, q_T, o_1, \dots, o_T) = P(o_i|q_i)$$

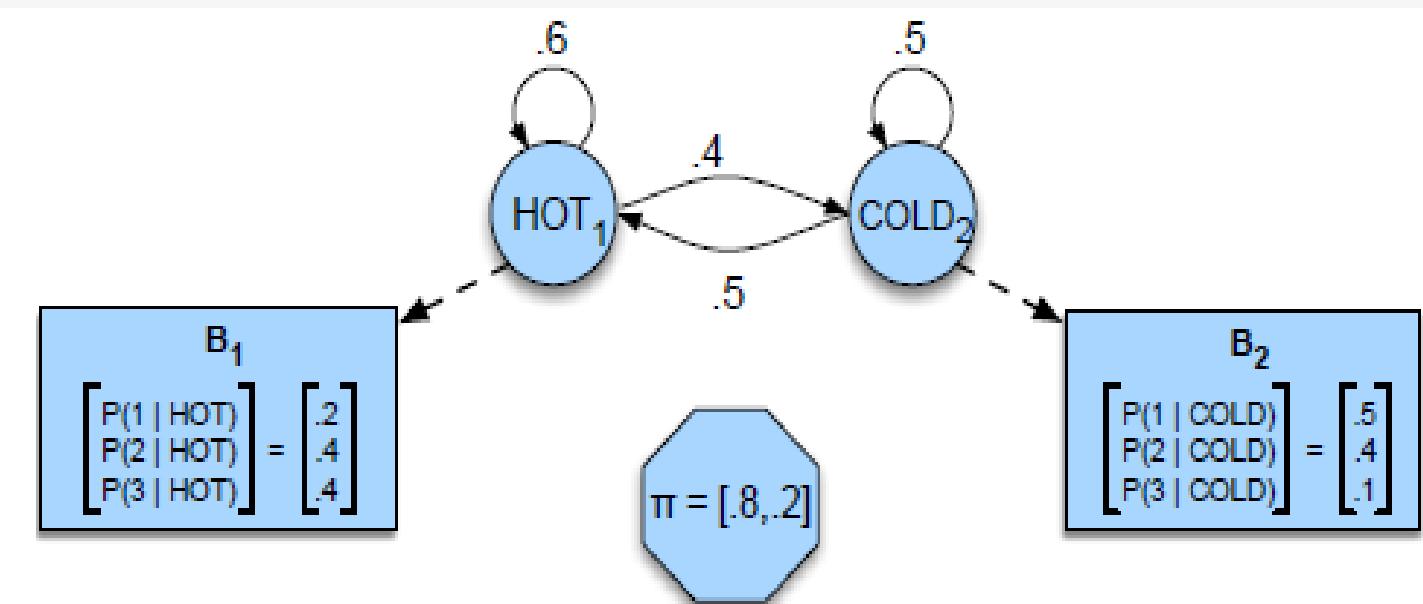
- Un modèle de Markov caché est défini par un quintuple  $\langle S, V, \Pi, A, B \rangle$  :
  - $V = \{v_1, v_2, \dots, v_M\}$  : alphabet des symboles émis par les états.
  - $B$  dénote la matrice des probabilités d'émission ; la probabilité que l'état  $q_j$  émet le symbole  $v_k, b_j(v_k)$ , est définie comme suit :

$$b_j(v_k) = P(o_t = v_k | X_t = q_j)$$

- $S, \Pi, A$  comme déjà définis .

# Exemple 1 (prédiction du temps)

Imaginons que vous ne pouvez pas trouver d'enregistrements de la météo à Jijel l'été 2020, mais vous trouvez l'agenda de la petite Lila qui enregistre **combien de glaces (entre 1 et 3)** elle a mangées tous les jours cet été là. Notre objectif est d'utiliser ces observations pour **estimer la température** chaque jour. Nous allons simplifier cette tâche météo en supposant il n'y a que deux sortes de jours : froid (C) et chaud (H).



## Exemple 2

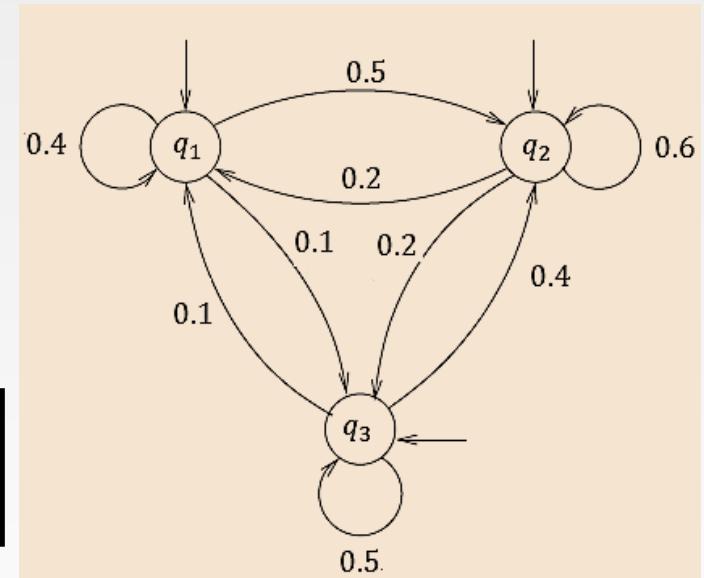
- Expérience aléatoire : lancer trois pièces de monnaie biaisées.
- $S = \{q_1, q_2, q_3\}$  tel que :  $q_1$ : pièce 1,  $q_2$ : pièce 2,  $q_3$ : pièce 3

- La matrice de transition  $A = \begin{bmatrix} 0.4 & 0.5 & 0.1 \\ 0.2 & 0.6 & 0.2 \\ 0.1 & 0.4 & 0.5 \end{bmatrix}$

- $V = \{P, F\}$  (P : Pile, F : Face)

- probabilités d'émission  $B = \begin{bmatrix} 0.48 & 0.52 \\ 0.80 & 0.20 \\ 0.55 & 0.45 \end{bmatrix}$

- Les probabilités de l'état initial :  $\pi_1 = \pi_2 = 0.3$   $\pi_3 = 0.4$

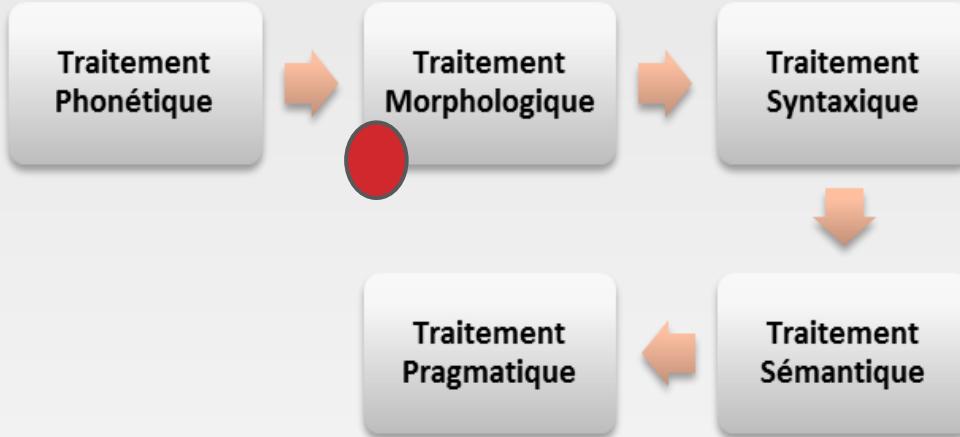


Imaginons que nous avons observé **FPPFPPP**, la question qui se pose est « quelle est la suite d'états ou bien le chemin la/le plus probable ayant généré cette séquence ?».



# Une application en TALN

# Processus du TALN



- Génération de mots à partir de morphèmes / Analyse morphologique

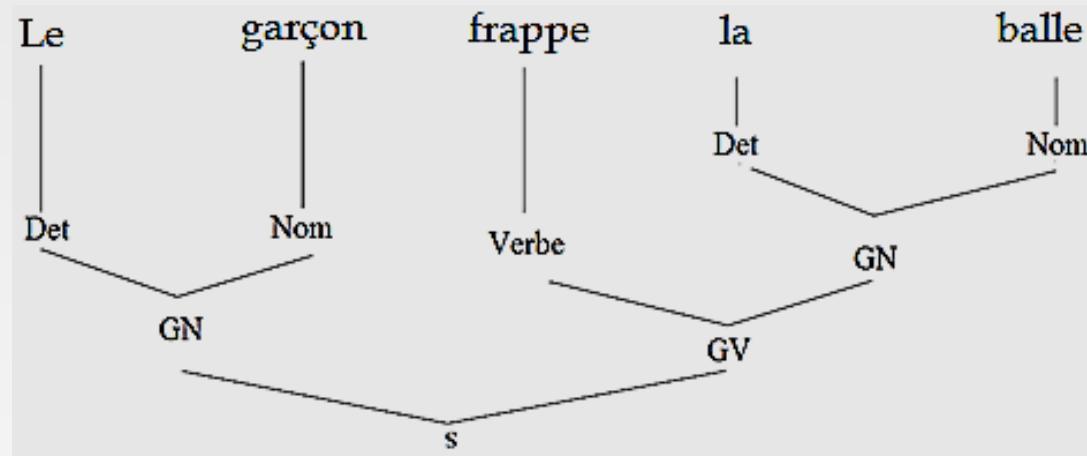
Mot	Racine	Préfixe dérivationnel	Suffixe dérivationnel	Suffixe flexionnel
intolérables	<u>tolér</u>	in	able	s

- **L'étiquetage morphosyntaxique** consiste à faire associer à chaque mot sa catégorie grammaticale.

Le	gros	chat	mange	la	souris	grise
article	adjectif	nom	verbe	article	nom	adjectif

# L'étiquetage morphosyntaxique: intérêt ?

- Base de l'étape suivante qui est : l'analyse syntaxique.



- Aide à comprendre la sémantique d'une phrase :

Exemple :

**"We can can the can".**

- Le mot "can" a plusieurs sens :

(1-verbe) pouvoir

(2-verbe) mettre en boîte

(3-nom) boîte.

- Après étiquetage morpho-syntaxique, on aura :

**"We[pronome] can[verbe] can[verbe] the[déterminant] can[nom]".**

# Projection du modèle de Markov Caché sur l'application de L'étiquetage morphosyntaxique

MMC	Application en étiquetage morphosyntaxique
S	Ensemble des catégories morphosyntaxiques.
V	Ensemble des mots (le vocabulaire).
O	Une séquence de $T$ mots observés qui prennent leurs valeurs dans V.
A	Probabilités que deux catégories morphosyntaxiques se suivent.
B	Probabilités d'observer un mot étant donnée une catégorie morphosyntaxique.
P	La probabilité de débuter par une catégorie morphosyntaxique.

# Corpus

- BD Textuelle, collection de Textes, un ensemble de documents servant d'échantillon et permettant d'extraire un ensemble d'informations utiles pour des traitements statistiques.
- Exemple:

*Corpus de Brown* est un **corpus annoté** avec 87 **étiquettes morphosyntaxiques**. C'est une collection de 1 million de mots provenant de **500 textes** de différents genres (journaux, romans, académiques, etc.)

# Algorithme de Viterbi

- Etant donnés une observation et un modèle de Markov caché en entrée, l'algorithme de Viterbi permet de calculer la séquence d'états *optimale* qui a généré cette observation.
- Cette problématique est souvent connue par ***la problématique de décodage.***
- Notations

✓  $\lambda = (A, B, \Pi)$  .

✓  $\delta_t(j)$  la probabilité maximale d'une observation  $o_1, o_2, \dots, o_t$  sous la condition que l'état courant soit  $q_j$  à l'instant t :

$$\delta_t(j) = \max_{s_1, s_2, \dots, s_{t-1}} P(s_1, s_2, \dots, s_{t-1}, o_1, o_2, \dots, o_t, \mathbf{s}_t = \mathbf{q}_j | \lambda)$$

✓  $\psi_t(j)$  est le chemin optimal correspondant.

## 1. Initialisation pour t=1

Pour i=1 à N faire

$$\delta_1(i) = \pi_i \times b_i(o_1)$$

$$\psi_1(i) = null$$

Fin Pour

## 2. Boucle d'induction

$$t = 2$$

Tant que  $t \leq T$  faire

$$j = 1$$

Tant que  $j \leq N$  faire

$$\delta_t(j) = b_j(o_t) \times \max_{1 \leq i \leq N} \delta_{t-1}(i) \cdot a_{ij}$$

$$\psi_t(j) = \arg \max_{1 \leq i \leq N} \delta_{t-1}(i) \cdot a_{ij}$$

$$j = j + 1$$

Fin TQ

$$t = t + 1$$

Fin TQ

## 3. Terminaison

Pour  $i=1$  à  $N$  faire

$$\delta_1(i) = \pi_i \times b_i(o_1)$$

$$\psi_1(i) = null$$

	$\delta_1(i)$	$\delta_2(i)$	$\delta_3(i)$	$\delta_4(i)$	$\delta_5(i)$
$q_4:NN$	0				
$q_3: TO$	0				
$q_2: VB$	0				
$q_1: PPSS$	0				
$q_0: Start$	<b>1</b>				
	$o1: « s »$	$o2: I$	$o3: want$	$o4: to$	$o5: race$

$\Psi_1(\text{start}) = \text{Null}$

$\Psi_1(PPSS) = \text{Null}$

$\Psi_1(VB) = \text{Null}$

$\Psi_1(TO) = \text{Null}$

$\Psi_1(NN) = \text{Null}$

j= 1

Tant que  $j \leq N$  faire

$$\delta_t(j) = b_j(o_t) \times \max_{1 \leq i \leq N} \delta_{t-1}(i). a_{ij}$$

$$\psi_t(j) = \arg \max_{1 \leq i \leq N} \delta_{t-1}(i). a_{ij}$$

$$j = j + 1$$

	$\delta_1(\mathbf{i})$	$\delta_2(\mathbf{i})$
$q_4$ :NN	0	0×
$q_3$ : TO	0	0×
$q_2$ : VB	0	0×
$q_1$ : PPSS	0	$0,37 \times 1 \times 0,067$
$q_0$ : Start	1	
	o1:<< s >>	o2: I

j=1

Tant que  $j \leq N$  faire

$$\delta_t(j) = b_j(o_t) \times \max_{1 \leq i \leq N} \delta_{t-1}(i) \cdot a_{ij}$$

$$\psi_t(j) = \arg \max_{1 \leq i \leq N} \delta_{t-1}(i) \cdot a_{ij}$$

j = j + 1

	$\delta_1(i)$	$\delta_2(i)$	$\delta_3(i)$
$q_4: NN$	0	0	$0,000054 \times 0,025 \times 0,0012$
$q_3: TO$	0	0	$0 \times$
$q_2: VB$	0	0	$0,0093 \times 0,025 \times 0,23$
$q_1: PPSS$	0	<b>0,025</b>	$0 \times$
$q_0: Start$	<b>1</b>		
	o1:« S »	o2: I	o3:want

$$\psi_2(PPSS) = « S »$$

$$\psi_2(VB) = « S »$$

$$\psi_2(TO) = « S »$$

$$\psi_2(NN) = « S »$$

	$\delta_1(\mathbf{i})$	$\delta_2(\mathbf{i})$	$\delta_3(\mathbf{i})$	$\delta_4(\mathbf{i})$
$q_4: \text{NN}$	0	0	$0.162 \times 10^{-8}$	$0 \times$
$q_3: \text{TO}$	0	0	0	$0.99 \times 0.53 \times 10^{-4} \times 0.035$
$q_2: \text{VB}$	0	0	<b><math>0.53 \times 10^{-4}</math></b>	$0 \times$
$q_1: \text{PPSS}$	0	<b>0,025</b>	0	$0 \times$
$q_0: \text{Start}$	<b>1</b>			
	o1:« s »	o2: I	o3:want	o4:to

$$\psi_3(\text{PPSS}) = \text{PPSS}$$

$$\psi_3(\text{VB}) = \text{PPSS}$$

$$\psi_3(\text{TO}) = \text{PPSS}$$

$$\psi_3(\text{NN}) = \text{PPSS}$$

	$\delta_1(\mathbf{i})$	$\delta_2(\mathbf{i})$	$\delta_3(\mathbf{i})$	$\delta_4(\mathbf{i})$
$q_4: \text{NN}$	0	0	$0.162 \times 10^{-8}$	0
$q_3: \text{TO}$	0	0	0	$0.18 \times 10^{-5}$
$q_2: \text{VB}$	0	0	$0.53 \times 10^{-4}$	0
$q_1: \text{PPSS}$	0	<b>0,025</b>	0	0
$q_0: \text{Start}$	<b>1</b>			
	o1:<< s >>	o2: I	o3: <i>want</i>	o4: <i>to</i>

$$\psi_4(PPSS) = \text{VB}$$

$$\psi_4(VB) = \text{VB}$$

$$\psi_4(TO) = \text{VB}$$

$$\psi_4(NN) = \text{VB}$$

	$\delta_1(i)$	$\delta_2(i)$	$\delta_3(i)$	$\delta_4(i)$	$\delta_5(i)$	
$q_4: NN$	0	0	$0.162 \times 10^{-8}$	0	$0,00057 \times 0.18 \times 10^{-5} \times 0,00047 = 0,48 \times 10^{-13}$	
$q_3: TO$	0	0	0	<b>0.18 <math>\times 10^{-5}</math></b>	$0 \times$	
$q_2: VB$	0	0	<b><math>0,53 \times 10^{-4}</math></b>	0	$0,00012 \times 0.18 \times 10^{-5} \times 0,83 = 0,179 \times 10^{-9}$	
$q_1: PPSS$	0	<b>0,025</b>	0	0	$0 \times$	
$q_0: Start$	<b>1</b>					
	o1:« s »	o2: I	o3:want	o4:to	o5: race	

$$\begin{aligned}
 \psi_5(PPSS) &= TO \\
 \psi_5(VB) &= TO \\
 \psi_5(TO) &= TO \\
 \psi_5(NN) &= TO
 \end{aligned}$$

	$\delta_1(\mathbf{i})$	$\delta_2(\mathbf{i})$	$\delta_3(\mathbf{i})$	$\delta_4(\mathbf{i})$	$\delta_5(\mathbf{i})$
$q_4:$ NN	0	0	$0.162 \times 10^{-8}$	0	$0.48 \times 10^{-13}$
$q_3:$ TO	0	0	0	$0.18 \times 10^{-5}$	$0 \times$
$q_2:$ VB	0	0	$0.53 \times 10^{-4}$	0	$0.179 \times 10^{-9}$
$q_1:$ PPSS	0	<b>0,025</b>	0	0	$0 \times$
$q_0:$ Start	<b>1</b>				
	o1: $\ll s \gg$	o2: I	o3: <i>want</i>	o4: <i>to</i>	o5: race

### 3. Terminaison

$$\hat{P} = \max_{1 \leq i \leq N} \delta_T(i)$$

$$P = 0.179 \times 10^{-9}$$

$$\widehat{S}_T = \arg \max_{1 \leq i \leq N} \delta_T(i) \quad S5 = \text{VB}$$

Le chemin optimal est déterminé par un retour en arrière

$$\widehat{S}_T, \psi_T(\widehat{S}_T), \psi_{T-2}(\widehat{S}_{T-1}), \dots$$

**VB , To, VB, PPSS, « s » ,Null**