

# IFT 615 – Intelligence Artificielle

## Raisonnement probabiliste temporel

Professeur: Froduald Kabanza

Assistants: D'Jeff Nkashama

# Sujets couverts


- Types d'inférence probabiliste temporelle
  - ◆ Filtrage
  - ◆ Prédiction
  - ◆ Explication la plus plausible
  - ◆ Lissage
- Réseau bayésien dynamique
- Chaîne de Markov
- Chaîne de Markov cachée
- Filtre de particules

# Réseau bayésien dynamique (RBD)


- Comment modéliser des situations dynamiques?
  - ◆ les changements dynamiques peuvent être vus **comme une séquence d'états**, chaque état représentant la situation à un instant  $t$  donné
  - ◆  $X_t$ : ensemble des **variables non observables (cachées)** décrivant l'état au temps  $t$
  - ◆  $E_t$ : ensembles de **variables observées (evidence)** au temps  $t$
- Le terme dynamique réfère au dynamisme du système qu'on veut modéliser et la structure du réseau

# Exemple de RDBs

- Réseau bayésien dynamique (RBD) du premier ordre avec une seule variable  $X$ , répliquées dans les différents états pour modéliser la dynamique du système:




- RBD du second ordre:



# Exemple de RDBs

- Réseau bayésien dynamique (RBD) du premier ordre avec une seule variable  $X$ , répliquées dans les différents états pour modéliser la dynamique du système:



# Représentation dans un RBD

- Problème:


- ◆ il faudrait spécifier un grand nombre (même infini) de tables de probabilités conditionnelles, c.-à-d. une pour chaque temps  $t$
- ◆ chaque table pourrait impliquer un nombre infini de parents

- Solution:

1. supposer que les changements dynamiques sont causés par un **processus homogène dans le temps** - les probabilités ne changent pas dans le temps:  $P(X_t | Parent(X_t))$  est la même pour tous les  $t$
2. supposer des **changements d'états markovien** – l'état courant dépend seulement d'un nombre fini d'états précédents
  - » ex.: processus markoviens **du premier ordre**:
    - $P(X_t | X_{0:t-1}) = P(X_t | X_{t-1})$       modèle pour les transitions
3. supposer des **capteurs markoviens** : l'observation **dépend uniquement de l'état courant**
  - $P(E_t | X_{0:t}, E_{0:t-1}) = P(E_t | X_t)$       modèle pour les observations/capteurs

# Exemple

- « Un gardien de sécurité passe un mois dans un édifice sous-terrain, sans sortir. Chaque jour, son directeur arrive avec ou sans parapluie. Le gardien veut inférer la possibilité qu'il ait plu ou non en fonction des séquences d'observation du parapluie. »
- Modélisation:
  - ◆ Variables:  $X_t = \{R_t\}$  (pour « *Rain* ») et  $E_t = \{U_t\}$  (pour « *Umbrella* »).
  - ◆ Dépendances entre les variables (c.-à-d., le RBD):




- ◆ Modèle des transitions:  $\mathbf{P}(R_t | R_{t-1})$ . Modèle d'observation:  $\mathbf{P}(U_t | R_t)$


# Application - Localisation

- **Modèle (filtre de particule)**

- ◆  $E_t$  sont l'information fournie par les capteurs du robot
- ◆  $X_t$  sont l'information sur la position du robot



Source: [Udacity](https://www.udacity.com/)




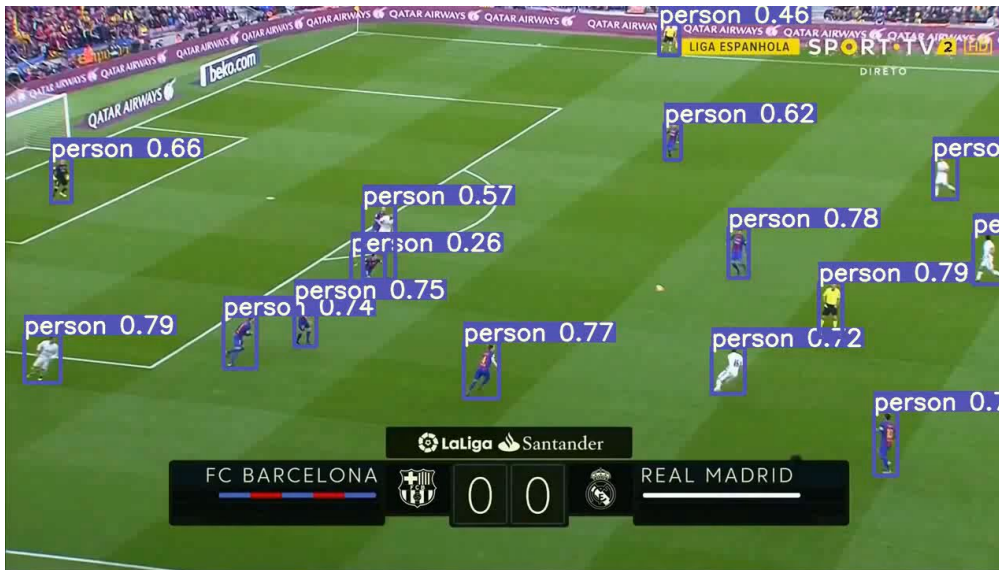
- Très utilisé en robotique et conduite autonome (filtre de particules)



# Application – Suivi d'objets (tracking)

- **Modèle (modèle de Markov caché et filtre de Kalman)**


- ◆  $E_t$  sont les *frames* de la vidéo
- ◆  $X_t$  sont l'information sur la position d'un/des objet(s)



# Application – Traduction automatique

- **Modèle:**

- ◆  $E_t$  sont les mots en français
- ◆  $X_t$  sont les mots de la traduction en anglais



## Traduction

Source : français ▾



Cible : anglais ▾

Traduire

français anglais arabe

Se familiariser avec les fondements de l'intelligence artificielle. Connaître les possibilités et les limites des techniques utilisées en intelligence artificielle. Savoir choisir et appliquer les différentes approches en fonction du problème à résoudre.



anglais français arabe

Become familiar with the foundations of artificial intelligence. Know the capabilities and limitations of the techniques used in artificial intelligence. Learn to select and apply different approaches to the problem to solve.




- Les réseaux de neurones ont pris le dessus sur les approches probabilistes.

# Application - Reconnaissance vocale

- **Modèle:**

- ◆  $E_t$  sont les éléments du signal sonore
- ◆  $X_t$  sont les phrases et les mots prononcés ainsi que les phonèmes




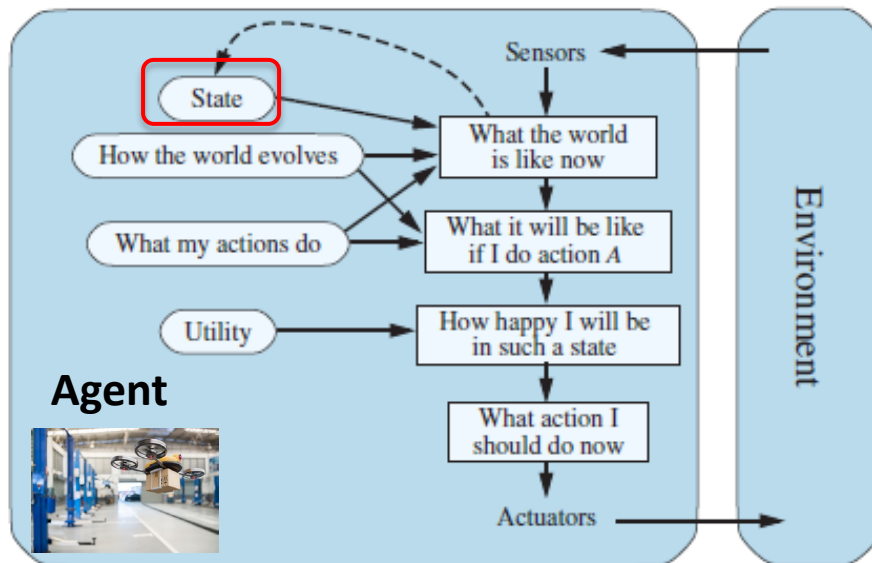
- Les réseaux de neurones ont remplacé les approches probabilistes.

# Types d'inférence dans un RBD

- **Filtrage (*filtering*)**: calcul de l'état de croyance (*belief state*), c.-à-d. la distribution à posteriori de la variable cachée la plus récente

$$P(X_t | e_{1:t})$$

- ◆ ex. : quelle est la probabilité qu'il pleuve aujourd'hui ?
- ◆ ex. : quelle est la position du robot (la plus probable) ?



# Programmation dynamique pour le filtrage

- Étant donné le résultat du filtrage au temps  $t$ , on peut calculer le résultat du filtrage au temps  $t+1$  à partir des nouvelles observations  $e_{t+1}$ .

$$\begin{aligned}
 P(X_{t+1} | e_{1:t+1}) &= P(X_{t+1} | e_{1:t}, e_{t+1}) && \text{(Séparer l'évidence en 2)} \\
 &= \alpha P(e_{t+1} | X_{t+1}, e_{1:t}) P(X_{t+1} | e_{1:t}) && \text{(Règle de Bayes)} \\
 &&& \alpha : \text{constante de normalisation} \\
 &= \alpha P(e_{t+1} | X_{t+1}) P(X_{t+1} | e_{1:t}) && \text{(Hypothèse markovienne du modèle sensoriel)} \\
 &= \alpha P(e_{t+1} | X_{t+1}) \sum_{x_t} P(X_{t+1} | x_t, e_{1:t}) P(x_t | e_{1:t}) && \text{Marginalisation} \\
 &= \underbrace{\alpha P(e_{t+1} | X_{t+1})}_{\text{modèle sensoriel}} \sum_{x_t} \underbrace{P(X_{t+1} | x_t)}_{\text{modèle dynamique}} \underbrace{P(x_t | e_{1:t})}_{\text{récursion}} && \text{(Hypothèse Markovienne)}
 \end{aligned}$$

# Programmation dynamique pour le filtrage

L'équation

$$P(X_{t+1} | \mathbf{e}_{1:t+1}) = \alpha \underbrace{P(e_{t+1} | X_{t+1})}_{\text{modèle sensoriel}} \sum_{x_t} \underbrace{P(X_{t+1} | x_t)}_{\text{modèle dynamique}} \underbrace{P(x_t | \mathbf{e}_{1:t})}_{\text{récursion}}$$

Peut se réécrire

$$\mathbf{f}_{1:t+1} = \alpha \text{FORWARD}(\mathbf{f}_{1:t}, \mathbf{e}_{t+1})$$


où FORWARD est un algorithme de programmation dynamique implémentant la récursion de l'équation précédente et  $\mathbf{f}_{1:0} = P(X_0)$ .

# Exemple de l'agent de sécurité

- RBD:

- ◆ une distribution de **probabilité a priori**  $P(R_0)$ , par exemple [0.5, 0.5]
- ◆ un **modèle des transition**  $P(R_t | R_{t-1})$
- ◆ un **modèle d'observation**  $P(U_t | R_t)$

$R_{t-1}$	$P(R_t   R_{t-1})$
V	0.7
F	0.3




$R_t$	$P(U_t   R_t)$
V	0.9
F	0.2

- **Jour 1:** le parapluie apparait, ( $U_1=true$  ou  $u_1$ )

- ◆ le filtrage de  $t=0$  à  $t=1$  est:
 
$$\begin{aligned}
 P(R_1 | u_1) &= \alpha P(u_1 | R_1) P(R_1) \\
 &= \alpha \langle 0.9, 0.2 \rangle \langle 0.5, 0.5 \rangle \\
 &= \alpha \langle 0.45, 0.1 \rangle \\
 &\approx \langle 0.818, 0.182 \rangle
 \end{aligned}$$

## Exemple de l'agent de sécurité

$R_{t-1}$	$P(R_t   R_{t-1})$
V	0.7
F	0.3



$R_t$	$P(U_t   R_t)$
V	0.9
F	0.2

$$P(R_1 | u_1) \approx \langle 0.818, 0.182 \rangle$$

$$P(X_{t+1} | \mathbf{e}_{1:t+1}) = \alpha P(e_{t+1} | X_{t+1}) \sum_{h_t} P(X_{t+1} | x_t) P(x_t | \mathbf{e}_{1:t})$$

- **Jour 2:** le parapluie apparait de nouveau, c.-à-d.,  $U_2 = true$ 
  - ◆ le filtrage de  $t=1$  à  $t=2$  est:

$$\begin{aligned} P(R_2 | u_1, u_2) &= \alpha P(u_2 | R_2) \sum_{r_1} P(R_2 | r_1) P(r_1 | u_1) \\ &= \alpha \langle 0.9, 0.2 \rangle (\langle 0.7, 0.3 \rangle * 0.818 + \langle 0.7, 0.3 \rangle * 0.182) \\ &= \alpha \langle 0.565, 0.075 \rangle \approx \langle 0.883, 0.117 \rangle \end{aligned}$$


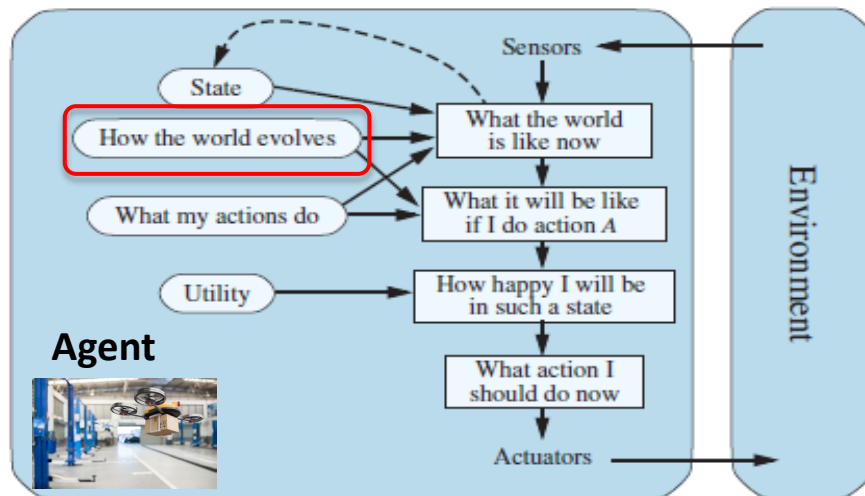


# Types d'inférence dans un RBD

- **Prédiction:** calculer la distribution a posteriori sur un état futur

$$P(X_{t+k} | e_{1:t}) \text{ où } k > 0$$

- ◆ ex. : quelle est la probabilité qu'il pleuve dans  $k$  jours ?
- ◆ ex.: quelle est la mission la plus probable du drone ?
- ◆ ex: quelle est la position probable à un temps future ?
- ◆ ex: quelle est la probabilité qu'une composante tombe en panne



- Les réseaux de neurones ont pris le dessus sur les approches probabilistes.

# Types d'inférence dans un RBD

- **Lissage (*smoothing*)**: calculer la distribution a posteriori sur un état passé

$$P(X_k | e_{1:t}) \text{ où } 0 \leq k < t$$

◆ ex. : quelle est la probabilité qu'il y ait eu de la pluie hier ( $k=t-1$ ) ?

- **Explication la plus plausible**: trouver la séquence d'états cachés qui explique le mieux les observations

$$\operatorname{argmax}_{X_{1:t}} P(x_{1:t} | e_{1:t}) = \operatorname{argmax}_{X_{1:t}} P(x_{1:t}, e_{1:t}) / P(e_{1:t}) = \operatorname{argmax}_{X_{1:t}} P(x_{1:t}, e_{1:t})$$

- ◆ ex. : quelle a été la météo la plus probable pour toutes les  $t$  dernières journées ?
- ◆ ex. : quelle est la traduction en anglais d'une phrase donnée en français ?
- ◆ ex. : quelle est la phrase qui a été prononcée ?

# Chaînes de Markov

- Une **chaîne de Markov** (de premier ordre) est un cas particulier de RBD
  - ◆ avec **une seule** variable aléatoire **discrète**  $X_t$  dans l'état au temps  $t$
- Le domaine de  $X_t$  est souvent un ensemble de symboles (ex.: un caractère, un mot, etc.)
- Une **distribution a priori** (initiale) de probabilités sur les symboles (états) est spécifiée  $\mathbf{P}(X_1)$
- Une **matrice de transition** contenant les probabilités conditionnelles  $\mathbf{P}(X_{t+1} \mid X_t)$

# Illustration




Illustration dans le cas d'une **chaîne finie**

# Visualisation d'une chaîne de Markov

## Représentation matricielle

$X_t$   
Symbole actuel

	$a$	$b$	$c$
$a$	.7	.3	0
$b$	.2	.7	.5
$c$	.1	0	.5

$X_{t+1}$   
Prochain symbole

## Représentation graphique





Illustration dans le cas d'une **chaîne infinie** (flux de symboles)

Exemple de chaîne: *ccbbaaaaaabaabacbabaaa*

# Probabilité de générer une séquence d'états



produit des probabilités, une pour chaque terme de la séquence

$$P(X_{1:t}) = P(X_1) \prod_{i=2}^t P(X_i | X_{i-1})$$

distribution initiale de probabilités

une séquence d'états, allant du temps 1 au temps  $t$

modèle de transition

# Modèle de Markov caché

- Dans un **modèle de Markov caché** (*hidden Markov model* ou **HMM**):
  - ◆ il y a des **variables cachées**  $X_t$  et des **variables d'observation**  $E_t$ , toutes les deux discrètes
  - ◆ la chaîne de Markov est sur les variables cachées  $X_t$
  - ◆ le symbole observé (émis)  $E_t=e_t$  dépend uniquement de la variable cachée actuelle  $X_t$

# Illustration

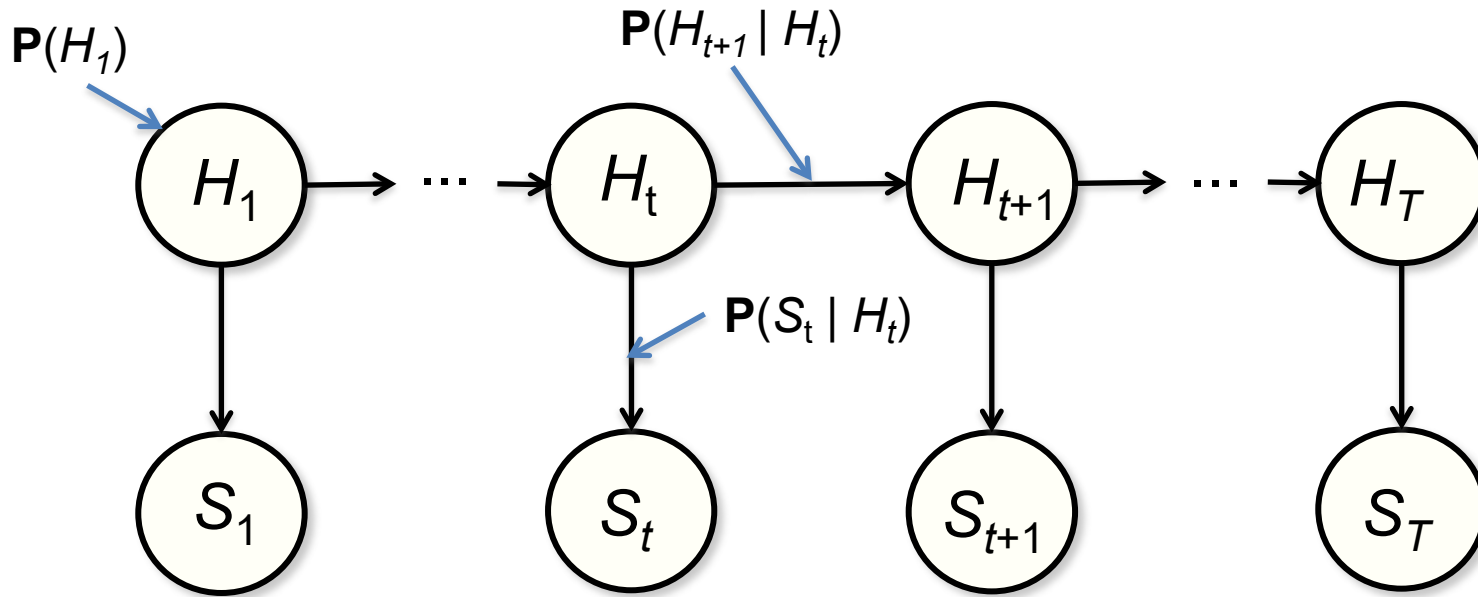



Illustration dans le cas d'une **chaîne finie**



# Illustration

$H_{t-1}$	$P(H_t=i H_{t-1})$	$P(H_t=j H_{t-1})$	$P(H_t=k H_{t-1})$
i	.7	.2	.1
j	.3	.7	0
k	0	.5	.5



H	$P(S=a H)$	$P(S=b H)$	$P(S=c H)$
i	.1	.3	.6
j	.4	.6	0
k	0	.2	.8


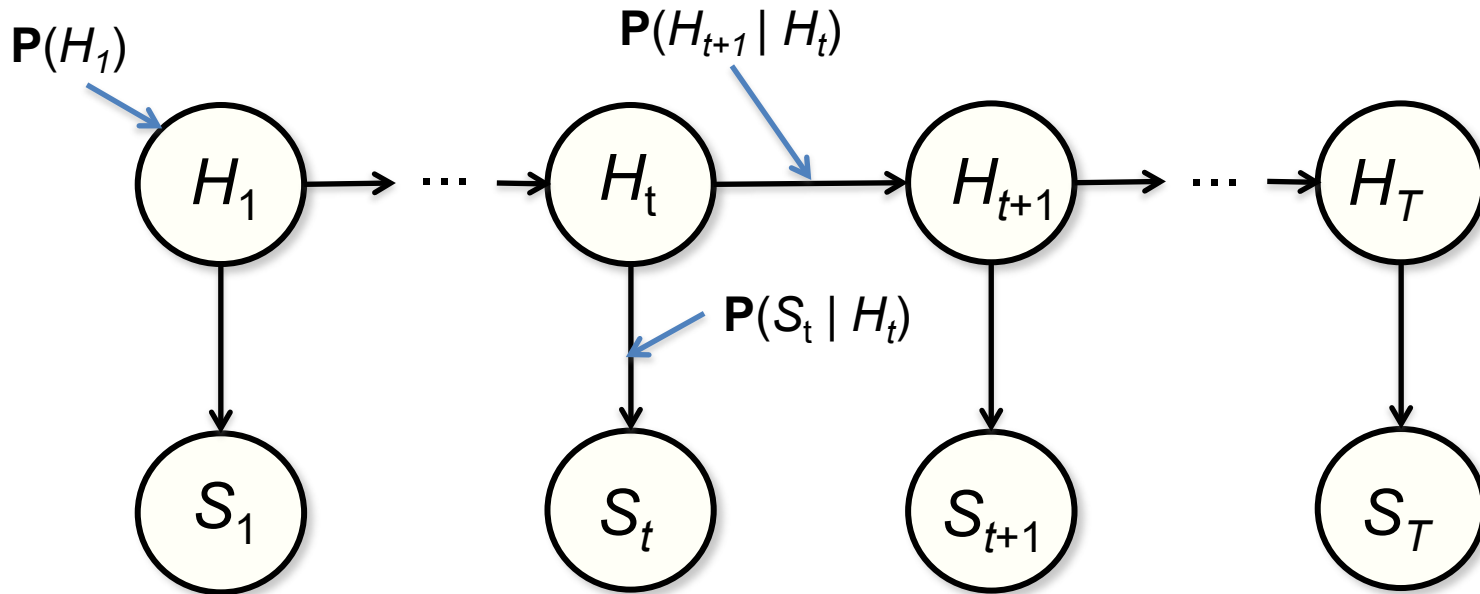


Illustration dans le cas d'une **chaîne infinie**, avec visualisation des valeurs de la variable cachée et la variable d'observation

Chaque **nœud caché** (valeur possible  $h$  de  $H$ ) a un vecteur de **probabilités de transitions** et un **vecteur de probabilités d'émission (observations)**

# Probabilité de générer une séquence cachée et une séquence visible



La distribution initiale (à priori)  $P(H_1)$  est donnée.


$$P(\underbrace{H_{1:t}, E_{1:t}}_{\text{séquence d'états cachés et d'observations}}) = P(H_1) \prod_{i=2}^t \underbrace{P(H_i | H_{i-1})}_{\text{modèle dynamique}} \underbrace{P(S_i | H_i)}_{\text{modèle d'observation}}$$

séquence d'états cachés et d'observations

modèle dynamique

modèle d'observation

# Filtrage avec un HMM



- Nous avons déjà vu un algorithme de programmation dynamique pour le filtrage qui itère sur la probabilité conditionnelle  $P(H_K = k | S_{1:T} = s_{1:T})$
- Nous voyons maintenant une programmation dynamique un peu différente, mais équivalente, qui itère sur la probabilité conjointe  $P(S_{1:T} = e_{1:T}, S_K = k)$ .



# Filtrage avec un HMM

- Par définition de la probabilité conditionnelle et par marginalisation:

$$P(H_K = k \mid E_{1:T} = e_{1:T}) = P(E_{1:T} = e_{1:T}, H_K = k) / \sum_i P(E_{1:T} = e_{1:T}, H_K = i)$$

- On calcule d'abord  $P(E_{1:T} = e_{1:T}, H_K = k)$  par **programmation dynamique** :

- ◆ Notons  $\alpha(i,t) = P(S_{1:t} = s_{1:t}, H_t = i)$

- ◆ Récursivement, on a:

$$\alpha(i,t+1) = P(S_{1:t+1} = s_{1:t+1}, H_{t+1} = i)$$

$$= \sum_j P(S_{1:t+1} = s_{1:t+1}, H_t = j, H_{t+1} = i)$$

$$= \sum_j P(S_{1:t} = s_{1:t}, H_t = j, H_{t+1} = i, S_{t+1} = s_{t+1})$$

$$= P(S_{t+1} = s_{t+1} \mid H_{t+1} = i) \sum_j P(H_{t+1} = i \mid H_t = j) P(S_{1:t} = s_{1:t}, H_t = j)$$

$$= P(S_{t+1} = s_{t+1} \mid H_{t+1} = i) \sum_j P(H_{t+1} = i \mid H_t = j) \alpha(j,t)$$

modèle sensoriel

modèle dynamique

← récursion

- ◆ On a les valeurs initiales

$$\alpha(i,1) = P(S_1 = s_1, H_1 = i) = P(S_1 = s_1 \mid H_1 = i) P(H_1 = i) \quad \forall i$$

- Une fois le tableau  $\alpha$  calculé, on peut facilement faire du filtrage:

$$P(H_K = k \mid S_{1:T} = s_{1:T}) = \alpha(k,T) / \sum_i \alpha(i,T)$$

# Exemple - Programmation dynamique avant

- Décoder un message binaire avec canal bruité (T=4)
  - ◆ message observé:  $S_1=0, S_2=1, S_3=0, S_4=0$

Modèle d'observation

	$H_t=0$	$H_t=1$
$P(S_t=0   H_t)$	0.9	0.2
$P(S_t=1   H_t)$	0.1	0.8

Modèle de transition

	$H_{t-1}=0$	$H_{t-1}=1$
$P(H_t=0   H_{t-1})$	0.3	0.4
$P(H_t=1   H_{t-1})$	0.7	0.6

Distribution initiale

	$H_1=0$	$H_1=1$
$P(H_1)$	0.5	0.5

$i \backslash t$	1	2	3	4
0				
1				

- ◆ initialisation:  $\alpha(i,1) = P(S_1=s_1, H_1 = i) = P(S_1=s_1 | H_1 = i) P(H_1 = i)$

# Exemple - Programmation dynamique avant pour

- Décoder un message binaire avec canal bruité (T=4)
  - ◆ message observé:  $S_1=0, S_2=1, S_3=0, S_4=0$

Modèle d'observation

	$H_t=0$	$H_t=1$
$P(S_t=0   H_t)$	0.9	0.2
$P(S_t=1   H_t)$	0.1	0.8

Modèle de transition

	$H_{t-1}=0$	$H_{t-1}=1$
$P(H_t=0   H_{t-1})$	0.3	0.4
$P(H_t=1   H_{t-1})$	0.7	0.6

Distribution initiale

	$H_1=0$	$H_1=1$
$P(H_1)$	0.5	0.5

$\alpha(i,t)$	$t$	1	2	3	4
0		0.45			
1					

- ◆ initialisation:  $\alpha(0,1) = P(S_1=0 | H_1 = 0) P(H_1 = 0) = 0.9 \times 0.5 = 0.45$

# Exemple - Programmation dynamique avant pour un HMM

- Décoder un message binaire avec canal bruité (T=4)
  - ◆ message observé:  $S_1=0, S_2=1, S_3=0, S_4=0$

Modèle d'observation

	$H_t=0$	$H_t=1$
$P(S_t=0   H_t)$	0.9	0.2
$P(S_t=1   H_t)$	0.1	0.8

Modèle de transition

	$H_{t-1}=0$	$H_{t-1}=1$
$P(H_t=0   H_{t-1})$	0.3	0.4
$P(H_t=1   H_{t-1})$	0.7	0.6

Distribution initiale

	$H_1=0$	$H_1=1$
$P(H_1)$	0.5	0.5

$\alpha(i,t)$	$i \backslash t$	1	2	3	4
0		0.45			
1		0.1			

- ◆ initialisation:  $\alpha(1,1) = P(S_1=0 | H_1 = 1) P(H_1 = 1) = 0.2 \times 0.5 = 0.1$

# Exemple - Programmation dynamique avant pour un HMM

- Décoder un message binaire avec canal bruité (T=4)
  - ◆ message observé:  $S_1=0, S_2=1, S_3=0, S_4=0$

Modèle d'observation

	$H_t=0$	$H_t=1$
$P(S_t=0   H_t)$	0.9	0.2
$P(S_t=1   H_t)$	0.1	0.8

Modèle de transition

	$H_{t-1}=0$	$H_{t-1}=1$
$P(H_t=0   H_{t-1})$	0.3	0.4
$P(H_t=1   H_{t-1})$	0.7	0.6

Distribution initiale

	$H_1=0$	$H_1=1$
$P(H_1)$	0.5	0.5

$i \backslash t$		1	2	3	4
0		0.45			
1		0.1			

- ◆ récursion (t=1):  $\alpha(i,t+1) = P(S_{t+1} = s_{t+1} | H_{t+1} = i) \sum_j P(H_{t+1} = i | H_t = j) \alpha(j,t)$



# Exemple - Programmation dynamique avant pour un HMM

- Décoder un message binaire avec canal bruité (T=4)
  - ◆ message observé:  $S_1=0, S_2=1, S_3=0, S_4=0$

Modèle d'observation

	$H_t=0$	$H_t=1$
$P(S_t=0   H_t)$	0.9	0.2
$P(S_t=1   H_t)$	0.1	0.8

Modèle de transition

	$H_{t-1}=0$	$H_{t-1}=1$
$P(H_t=0   H_{t-1})$	0.3	0.4
$P(H_t=1   H_{t-1})$	0.7	0.6

Distribution initiale

	$H_1=0$	$H_1=1$
$P(H_1)$	0.5	0.5

$\alpha(i,t)$	t	1	2	3	4
0		0.45	→		
1		0.1	↗		

- ◆ récursion:  $\alpha(0,2) = P(S_2=1 | H_2=0) ( P(H_2=0 | H_1=0) \alpha(0,1) + P(H_2=0 | H_1=1) \alpha(1,1) )$

# Exemple - Programmation dynamique avant pour un HMM

- Décoder un message binaire avec canal bruité (T=4)
  - ◆ message observé:  $S_1=0, S_2=1, S_3=0, S_4=0$

Modèle d'observation

	$H_t=0$	$H_t=1$
$P(S_t=0   H_t)$	0.9	0.2
$P(S_t=1   H_t)$	0.1	0.8

Modèle de transition

	$H_{t-1}=0$	$H_{t-1}=1$
$P(H_t=0   H_{t-1})$	0.3	0.4
$P(H_t=1   H_{t-1})$	0.7	0.6

Distribution initiale

	$H_1=0$	$H_1=1$
$P(H_1)$	0.5	0.5

$\alpha(i,t)$	$t$	1	2	3	4
0		0.45	0.0175		
1		0.1			

- ◆ récursion:  $\alpha(0,2) = 0.1 (0.3 \times 0.45 + 0.4 \times 0.1) = 0.0175$

# Exemple - Programmation dynamique avant pour un HMM

- Décoder un message binaire avec canal bruité (T=4)
  - ◆ message observé:  $S_1=0, S_2=1, S_3=0, S_4=0$

Modèle d'observation

	$H_t=0$	$H_t=1$
$P(S_t=0   H_t)$	0.9	0.2
$P(S_t=1   H_t)$	0.1	0.8

Modèle de transition

	$H_{t-1}=0$	$H_{t-1}=1$
$P(H_t=0   H_{t-1})$	0.3	0.4
$P(H_t=1   H_{t-1})$	0.7	0.6

Distribution initiale

	$H_1=0$	$H_1=1$
$P(H_1)$	0.5	0.5

$\alpha(i,t)$	$t$	1	2	3	4
0		0.45	0.0175		
1		0.1			

- ◆ récursion:  $\alpha(1,2) = P(S_2=1 | H_2=1) ( P(H_2=1 | H_1=0) \alpha(0,1) + P(H_2=1 | H_1=1) \alpha(1,1) )$

# Exemple - Programmation dynamique avant pour un HMM

- Décoder un message binaire avec canal bruité (T=4)
  - ◆ message observé:  $S_1=0, S_2=1, S_3=0, S_4=0$

Modèle d'observation

	$H_t=0$	$H_t=1$
$P(S_t=0   H_t)$	0.9	0.2
$P(S_t=1   H_t)$	0.1	0.8

Modèle de transition

	$H_{t-1}=0$	$H_{t-1}=1$
$P(H_t=0   H_{t-1})$	0.3	0.4
$P(H_t=1   H_{t-1})$	0.7	0.6

Distribution initiale

	$H_1=0$	$H_1=1$
$P(H_1)$	0.5	0.5

$\alpha(i,t)$	$i \backslash t$	1	2	3	4
0		0.45	0.0175		
1		0.1	0.3		

- ◆ récursion:  $\alpha(1,2) = 0.8 ( 0.7 \times 0.45 + 0.6 \times 0.1 ) = 0.3$

# Exemple - Programmation dynamique avant pour un HMM

- Décoder un message binaire avec canal bruité (T=4)
  - ◆ message observé:  $S_1=0, S_2=1, S_3=0, S_4=0$

Modèle d'observation

	$H_t=0$	$H_t=1$
$P(S_t=0   H_t)$	0.9	0.2
$P(S_t=1   H_t)$	0.1	0.8

Modèle de transition

	$H_{t-1}=0$	$H_{t-1}=1$
$P(H_t=0   H_{t-1})$	0.3	0.4
$P(H_t=1   H_{t-1})$	0.7	0.6

Distribution initiale

	$H_1=0$	$H_1=1$
$P(H_1)$	0.5	0.5

$i \backslash t$	1	2	3	4
0	0.45	0.0175		
1	0.1	0.3		

- ◆ récursion (t=2):  $\alpha(i,t+1) = P(S_{t+1} = s_{t+1} | H_{t+1} = i) \sum_j P(H_{t+1} = i | H_t = j) \alpha(j,t)$

# Exemple - Programmation dynamique avant pour un HMM

- Décoder un message binaire avec canal bruité (T=4)
  - ◆ message observé:  $S_1=0, S_2=1, S_3=0, S_4=0$

Modèle d'observation

	$H_t=0$	$H_t=1$
$P(S_t=0   H_t)$	0.9	0.2
$P(S_t=1   H_t)$	0.1	0.8

Modèle de transition

	$H_{t-1}=0$	$H_{t-1}=1$
$P(H_t=0   H_{t-1})$	0.3	0.4
$P(H_t=1   H_{t-1})$	0.7	0.6

Distribution initiale

	$H_1=0$	$H_1=1$
$P(H_1)$	0.5	0.5

$\alpha(i,t)$	$i \backslash t$	1	2	3	4
0		0.45	0.0175	0.112725	
1		0.1	0.3		

- ◆ récursion:  $\alpha(0,3) = 0.9 (0.3 \times 0.0175 + 0.4 \times 0.3) = 0.112725$

# Exemple - Programmation dynamique avant pour un HMM

- Décoder un message binaire avec canal bruité (T=4)
  - ◆ message observé:  $S_1=0, S_2=1, S_3=0, S_4=0$

Modèle d'observation

	$H_t=0$	$H_t=1$
$P(S_t=0   H_t)$	0.9	0.2
$P(S_t=1   H_t)$	0.1	0.8

Modèle de transition

	$H_{t-1}=0$	$H_{t-1}=1$
$P(H_t=0   H_{t-1})$	0.3	0.4
$P(H_t=1   H_{t-1})$	0.7	0.6

Distribution initiale

	$H_1=0$	$H_1=1$
$P(H_1)$	0.5	0.5

$\alpha(i,t)$	$i \backslash t$	1	2	3	4
0		0.45	0.0175	0.112725	0.04427
1		0.1	0.3	0.03845	0.02039

- ◆ on continue d'appliquer la récursion jusqu'à la fin (t=4)...

# Exemple - Filtrage avec un HMM



- Décoder un message binaire avec canal bruité (T=4)
  - ◆ message observé:  $S_1=0, S_2=1, S_3=0, S_4=0$

$\alpha(i,t)$	$i \backslash t$	1	2	3	4
0		0.45	0.0175	0.112725	0.04427
1		0.1	0.3	0.03845	0.02039

- ◆ on peut calculer les probabilités de filtrage

$$\begin{aligned}
 P(H_4 = 0 \mid S_1=0, S_2=1, S_3=0, S_4=0) &= \frac{P(H_4 = 0, S_1=0, S_2=1, S_3=0, S_4=0)}{\sum_i P(H_4 = i, S_1=0, S_2=1, S_3=0, S_4=0)} \\
 &= \alpha(0,4) / (\alpha(0,4) + \alpha(1,4)) \\
 &= 0.04427 / (0.04427 + 0.02039) \\
 &\approx 0.6847
 \end{aligned}$$

$$\begin{aligned}
 P(H_4 = 1 \mid S_1=0, S_2=1, S_3=0, S_4=0) &= 0.02039 / (0.04427 + 0.02039) \\
 &\approx 0.3153
 \end{aligned}$$



# Probabilité de générer une séquence visible

- Un calcul naïf basé sur la sémantique d'un réseau bayésien serait:

$$P(S_{1:T}) = \sum_{h_{1:T}} P(H_{1:T} = h_{1:T}) P(S_{1:T} | H_{1:T} = h_{1:T})$$

- Ce serait inefficace: il y a un nombre exponentiel de séquences cachées possibles (la même séquence de sortie peut être produite par plusieurs séquences cachées différentes).
- Les tableaux  $\alpha(i,t)$  nous donne une façon plus efficace ( $O(n)$ ).
- Rappelons-nous que  $\alpha(i,t) = P(S_{1:t}=s_{1:t}, H_t = i)$
- Ainsi:

$$P(S_{1:T}=s_{1:T}) = \sum_j P(S_{1:T}=s_{1:T}, H_T = j) = \sum_j \alpha(j,T)$$

# Application: reconnaissance vocale

- La reconnaissance vocale est difficile:
  - ◆ bruit ambiant ou introduit par la digitalisation
  - ◆ variations dans la prononciation
  - ◆ différents mots ont la même prononciation
- Problème: Quelle est la séquence de mots la plus vraisemblable étant donné un signal sonore ?
- Réponse: Choisir la séquence de mots la plus probable a posteriori
  - ◆  $\underset{\text{mots}}{\operatorname{argmax}} P(\text{mots} \mid \text{signal}) = \underset{\text{mots}}{\operatorname{argmax}} \alpha P(\text{mots}, \text{signal})$

# Modèle acoustique et modèle du langage

- En utilisant la règle de Bayes
  - ◆  $P(\text{mots} \mid \text{signal}) = \alpha P(\text{signal} \mid \text{mots}) P(\text{mots})$
- On peut donc décomposer le problème en deux:
  - ◆  $P(\text{Signal} \mid \text{Mots})$ : **modèle acoustique**
  - ◆  $P(\text{Mots})$ : **modèle de langage**
- Chaîne cachée: les mots
- Chaîne observée: le signal


# Phones et phonèmes

- Des travaux dans le domaine de phonologie ont montré que toutes les langues humaines sont basées sur un sous-ensemble d'environ 100 sons, appelés **phones**, communs à toutes les langues
- Les phones découlent de l'articulation des lèvres, des dents, de la langue, des cordes vocales et du flux de l'air
- Intuitivement, un phone est un son qui correspond à une seule consonne ou une seule voyelle
- Mais c'est plus subtil ! Des combinaisons de consonnes comme « th » ou « ng » en anglais ont chacun leur phone
- Un **phonème** est la plus petite unité de son distinctive que l'on puisse isoler par segmentation dans un mot
- Un phonème sera associé à un ou plusieurs phones qui peuvent être interchangés sans changer la compréhension d'un mot
  - ◆ phonème /k/: phones [k] (« *cat* », « *kit* ») et [k<sup>h</sup>] (« *school* », « *skill* »)

# Application - Reconnaissance vocale

- **Modèle:**

- ◆  $E_t$  sont les éléments du signal sonore
- ◆  $X_t$  sont les phrases et les mots prononcés ainsi que les phonèmes



# Phones: exemple

- Phones pour l'anglais américain:


[iy]	b <u>ea</u> t	[b]	<u>b</u> et	[p]	<u>p</u> et
[ih]	b <u>i</u> t	[ch]	<u>Ch</u> et	[r]	<u>r</u> at
[ey]	b <u>e</u> t	[d]	<u>d</u> ebt	[s]	<u>s</u> et
[ao]	b <u>ou</u> ght	[hh]	<u>h</u> at	[th]	<u>th</u> ick
[ow]	b <u>oa</u> t	[hv]	<u>h</u> igh	[dh]	<u>th</u> at
[er]	B <u>e</u> rt	[l]	<u>l</u> et	[w]	<u>w</u> et
[ix]	ros <u>e</u> s	[ng]	s <u>ing</u>	[en]	butt <u>on</u>
⋮	⋮	⋮	⋮	⋮	⋮

# Modèle acoustique

- Rappel:
  - ◆  $P(\text{Mots} \mid \text{Signal}) = \alpha P(\text{Signal} \mid \text{Mots}) P(\text{Mots})$ 
    - »  $P(\text{Signal} \mid \text{Mots})$ : modèle acoustique
    - »  $P(\text{Mots})$ : modèle de langage
- L'existence des phones permet de diviser le modèle acoustique en deux autres parties:
  - ◆ **modèle de prononciation**: spécifie, pour chaque mot, une distribution de probabilités sur une séquence de phones
    - » par exemple, « *ceiling* » est parfois prononcé [s iy l ih ng], ou [s iy l ix ng], ou encore [s iy l en]
    - » le phone est une variable cachée, le signal est la variable observée
  - ◆ **modèle phonique**: le modèle phonique  $P(e_t \mid x_t)$  donne la probabilité que le signal échantillonné soit observé au temps  $t$  si le phone est  $x_t$

# Exemple de modèle de prononciation

- Modèle de prononciation
  - ◆  $P([\text{towmeytow}] | \text{« tomato »}) = P([\text{towmaatow}] | \text{« tomato »}) = 0.1$
  - ◆  $P([\text{tahmeytow}] | \text{« tomato »}) = P([\text{tahmaatow}] | \text{« tomato »}) = 0.4$
- Les transitions sont apprises automatiquement d'un corpus
- Les probabilités sont aussi apprises





# Apprendre les tables des probabilités conditionnelles

- Observer plusieurs chaînes et définir les probabilités conditionnelles en fonction des fréquences d'occurrence des symboles

$$P(B=b|a) = \frac{\sum_{\text{chaînes}} \text{freq}(a,b)}{\sum_{\text{chaînes}} \text{freq}(a)}$$

- Pour éviter les problèmes avec zéro occurrences, on utilise plutôt:


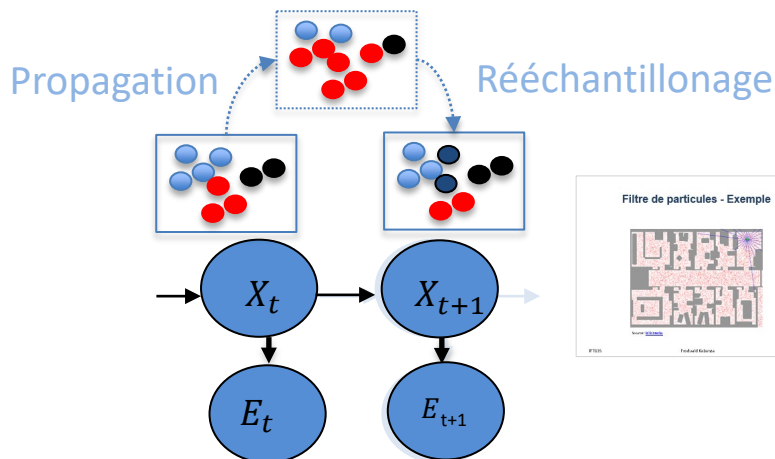
$$P(B=b|A=a) = \frac{1 + \sum_{\text{chaînes}} \text{freq}(a,b)}{\text{Nb. symboles} + \sum_{\text{chaînes}} \text{freq}(a)}$$

# Conversation continue

- Dans une conversation continue on doit tenir compte de la corrélation des mots adjacents et non juste la reconnaissance d'un mot isolé.
- Aujourd'hui, les HMM ont été dépassés par les réseaux de neurones pour la reconnaissance vocale.

# Filtre de particules

- Un filtre de particule est un filtrage par inférence approximative
  - ◆ Au temps  $t$ , on a une incertitude sur la valeur de la variable  $X$
  - ◆ On maintient une population  $N$  des valeurs (états) probables. Chaque valeur probable est représentée par une particule. On a donc  $N$  particules.
  - ◆ À chaque temps  $t$ , on met à jour la population de particules, en échantillonnant la population courante, tenant compte du modèle dynamique (**propagation par échantillonnage**) et du modèle de transition (**rééchantillonnage pondéré**)
- Utilisé notamment pour le *tracking* (estimer la position d'un objet mobile).





Source: [Udacity](https://www.udacity.com/)

# Filtere de particules - Algorithme

- Générer une population de N particules selon  $P(X_0)$
- À chaque transition  $X_t \rightarrow X_{t+1}$ :
  1. **Propager** la population en échantillonnant la prochaine valeur  $x_{t+1}$  étant donné la valeur courante  $x_t$ , selon le modèle de transition  $P(X_{t+1} | X_t)$
  2. Étant donné la nouvelle observation  $e_{t+1}$ , **pondérer** chaque particule  $x_{t+1}$  par  $P(e_{t+1} | x_{t+1})$ 
    - ❖ c.-à-d., pondérer chaque particule par la vraisemblance qu'elle accorde à la nouvelle observation
  3. **Rééchantillonner** (avec remplacement) la population pour générer N nouveaux particules
    - ❖ La probabilité qu'un échantillon particulier soit choisi est proportionnelle à son poids.

$R_{t-1}$	$P(R_t   R_{t-1})$	$R_t$	$P(U_t   R_t)$
V	0.7	V	0.9
F	0.3	F	0.2



1. Propagate      2. Weight      3. Resample

Au temps  $t+1$ ,  
 $\neg Umbrella$  est observé

# Filtre de particules - Algorithme

**function** PARTICLE-FILTERING( $\mathbf{e}$ ,  $N$ ,  $dbn$ ) **returns** a set of samples for the next time step

**inputs:**  $\mathbf{e}$ , the new incoming evidence

$N$ , the number of samples to be maintained

$dbn$ , a DBN defined by  $\mathbf{P}(\mathbf{X}_0)$ ,  $\mathbf{P}(\mathbf{X}_1 | \mathbf{X}_0)$ , and  $\mathbf{P}(\mathbf{E}_1 | \mathbf{X}_1)$

**persistent:**  $S$ , a vector of samples of size  $N$ , initially generated from  $\mathbf{P}(\mathbf{X}_0)$

**local variables:**  $W$ , a vector of weights of size  $N$

**for**  $i = 1$  to  $N$  **do**

$S[i] \leftarrow$  sample from  $\mathbf{P}(\mathbf{X}_1 | \mathbf{X}_0 = S[i])$  // step 1

$W[i] \leftarrow \mathbf{P}(\mathbf{e} | \mathbf{X}_1 = S[i])$  // step 2

$S \leftarrow$  WEIGHTED-SAMPLE-WITH-REPLACEMENT( $N$ ,  $S$ ,  $W$ ) // step 3

**return**  $S$

# Consistence de l'algorithme

On peut prouver (par induction) que l'algorithme est consistant, c.-à.d.-., que lorsque le nombre d'échantillons  $N$  tend vers l'infini, il se rapproche de la probabilité de filtrage.

- Cas de base: On suppose que la population initiale est consistante avec  $P(X_0)$ .

Notons  $N(x_t | e_{1:t})$ , le nombre de particules ayant la valeur  $x_t$  après avoir observé  $e_{1:t}$ .

- Cas inductif: Supposons que  $N(x_t | e_{1:t}) / N = P(x_t | e_{1:t})$   
Montrons que  $N(x_{t+1} | e_{1:t+1}) / N = P(x_{t+1} | e_{1:t+1})$

# Consistance de l'algorithme

- Se rappeler que  $N(x_t | e_{1:t})$  est le nombre de particules ayant la valeur  $x_t$  après avoir observé  $e_{1:t}$ .
- On suppose que  $N(x_t | e_{1:t}) / N = P(x_t | e_{1:t})$  -- Notre hypothèse inductive
- On veut montrer que  $N(x_{t+1} | e_{1:t+1}) / N = P(x_{t+1} | e_{1:t+1})$

- ◆ Partant de  $N(x_t | e_{1:t})$ , l'étape de propagation va donner

$$N(x_{t+1} | e_{1:t}) = \sum_{x_t} P(x_{t+1} | x_t) N(x_t | e_{1:t})$$

- ◆ Après avoir observé  $e_{t+1}$  l'étape de pondération donne une population de particules dont le poids total est

$$W(x_{t+1} | e_{1:t}) = P(e_{t+1} | x_{t+1}) N(x_{t+1} | e_{1:t})$$

- ◆ Après l'étape de rééchantillonnage, vu que chaque échantillon est choisi proportionnellement à son poids, le poids total des échantillons ayant la valeur  $x_{t+1}$  est proportionnel à leur poids total avant le rééchantillonnage, c.-à-d.,

$$N(x_{t+1} | e_{1:t+1}) / N = \alpha W(x_{t+1} | e_{1:t})$$



# Consistance de l'algorithme, suite

- Cas inductif: Supposons que  $N(x_t | e_{1:t}) / N = P(x_t | e_{1:t})$

Montrons que  $N(x_{t+1} | e_{1:t+1}) / N = P(x_{t+1} | e_{1:t+1})$

- ◆ Partant de  $N(x_t | e_{1:t})$ , l'étape de propagation va donner

$$N(x_{t+1} | e_{1:t}) = \sum_{x_t} P(x_{t+1} | x_t) N(x_t | e_{1:t})$$

- ◆ Après avoir observé  $e_{t+1}$  l'étape de pondération donne que le poids total des particules est

$$W(x_{t+1} | e_{1:t}) = P(e_{t+1} | x_{t+1}) N(x_{t+1} | e_{1:t})$$

- ◆ Après l'étape de rééchantillonnage, vu que chaque échantillon est choisi proportionnellement à son poids, le poids total des échantillons ayant la valeur  $x_{t+1}$  est proportionnel à leur poids total avant le rééchantillonnage, c.-à-d.,

$$N(x_{t+1} | e_{1:t+1}) / N = \alpha W(x_{t+1} | e_{1:t})$$



# Consistance de l'algorithme, suite ...

- Cas inductif : En supposant que  $N(x_t | e_{1:t}) / N = P(x_t | e_{1:t})$   
On veut montrer  $N(x_{t+1} | e_{1:t+1}) / N = P(x_{t+1} | e_{1:t+1})$


◆ On était rendu à  $N(x_{t+1} | e_{1:t+1}) / N = \alpha W(x_{t+1} | e_{1:t})$

$$\begin{aligned} N(x_{t+1} | e_{1:t+1}) / N &= \alpha W(x_{t+1} | e_{1:t}) \\ &= \alpha P(e_{t+1} | x_{t+1}) N(x_{t+1} | e_{1:t}) \quad \text{-- selon la définition de } W \\ &= \alpha P(e_{t+1} | x_{t+1}) \sum_{x_t} P(x_{t+1} | x_t) N(x_t | e_{1:t}) \\ &\quad \text{selon l'équation de } N(x_{t+1} | e_{1:t}) \text{ à la slide précédente} \\ &= \alpha^* N^* P(e_{t+1} | x_{t+1}) \sum_{x_t} P(x_{t+1} | x_t) P(x_t | e_{1:t}) \\ &\quad \text{Par hypothèse inductive : } N(x_t | e_{1:t}) / N = P(x_t | e_{1:t}) \\ &= \alpha' P(e_{t+1} | x_{t+1}) \sum_{x_t} P(x_{t+1} | x_t) P(x_t | e_{1:t}) \quad \text{-- en posant } \alpha' = \alpha^* N \\ &= P(x_{t+1} | e_{t+1}) \end{aligned}$$

Selon l'équation de programmation dynamique pour le filtrage

◆ CQFD

# Filtre de particules - Exemple



Source: [Wikimedia](#)

# Filtre de Kalman

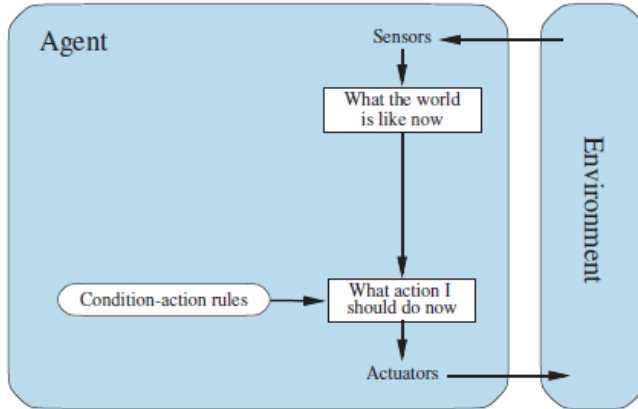
- **Dans un HMM**, la variable cachée est discrète et change dynamiquement ses valeurs en suivant une chaîne de Markov et sa distribution de probabilité conditionnelle (modèle dynamique)
- Un **Filtre de Kalman** est la version continue d'un HMM. La variable est continue, avec une distribution gaussienne.
- La méthode est utilisée pour le suivi d'objets (*tracking*).
- Pas couverte dans ce cours. Voir section 14.4.

# Résumé

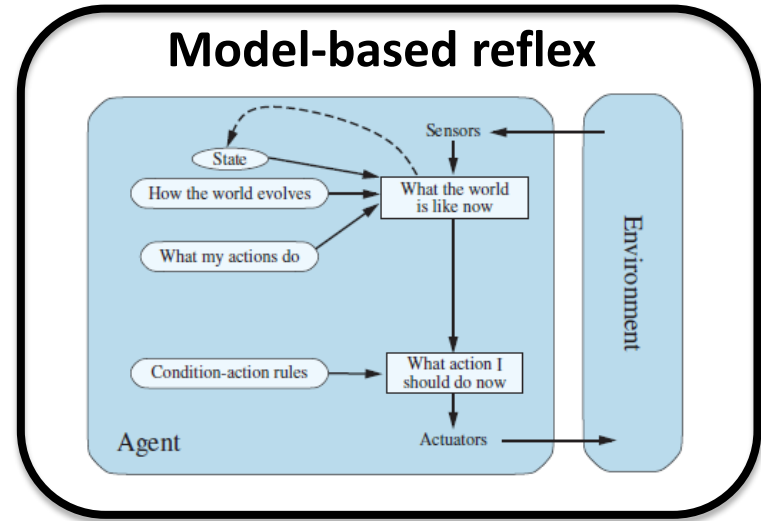
- Un **réseau bayésien dynamique** (RBD) permet de tenir compte de la nature séquentielle d'un environnement
- Un **modèle de Markov caché** (HMM) est un cas particulier de RBD avec
  - ◆ une seule variable cachée  $X_t = \{H_t\}$  et une seule variable observée  $E_t = \{S_t\}$
  - ◆ les variables  $H_t$  et  $S_t$  sont discrètes
- Il existe des procédures de programmation dynamique efficaces dans un HMM pour faire de l'inférence : **filtrage, prédiction, lissage, explication la plus plausible**. Le cours couvre seulement le filtrage.
- Un filtre de particule est une méthode approximative de filtrage pour un RBD. Très utilisée pour le suivi des objets en mouvement.

# Raisonnement probabiliste pour quel type d'agents?

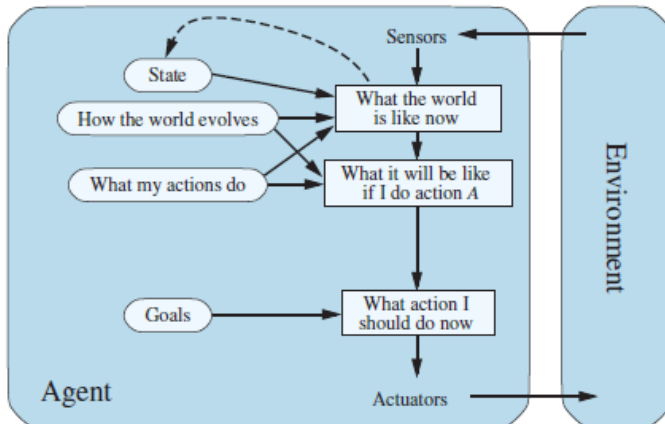
## Simple reflex



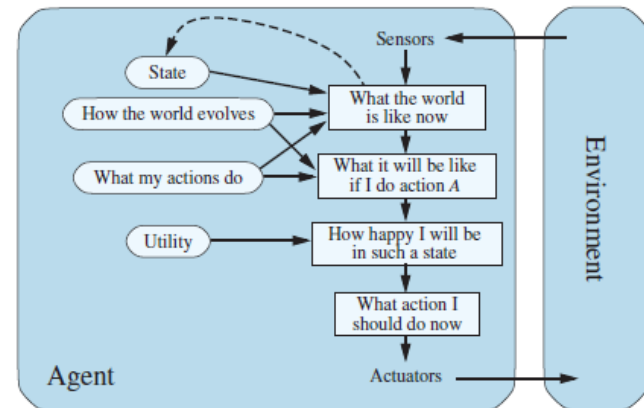
## Model-based reflex



## Goal-based



## Utility-based

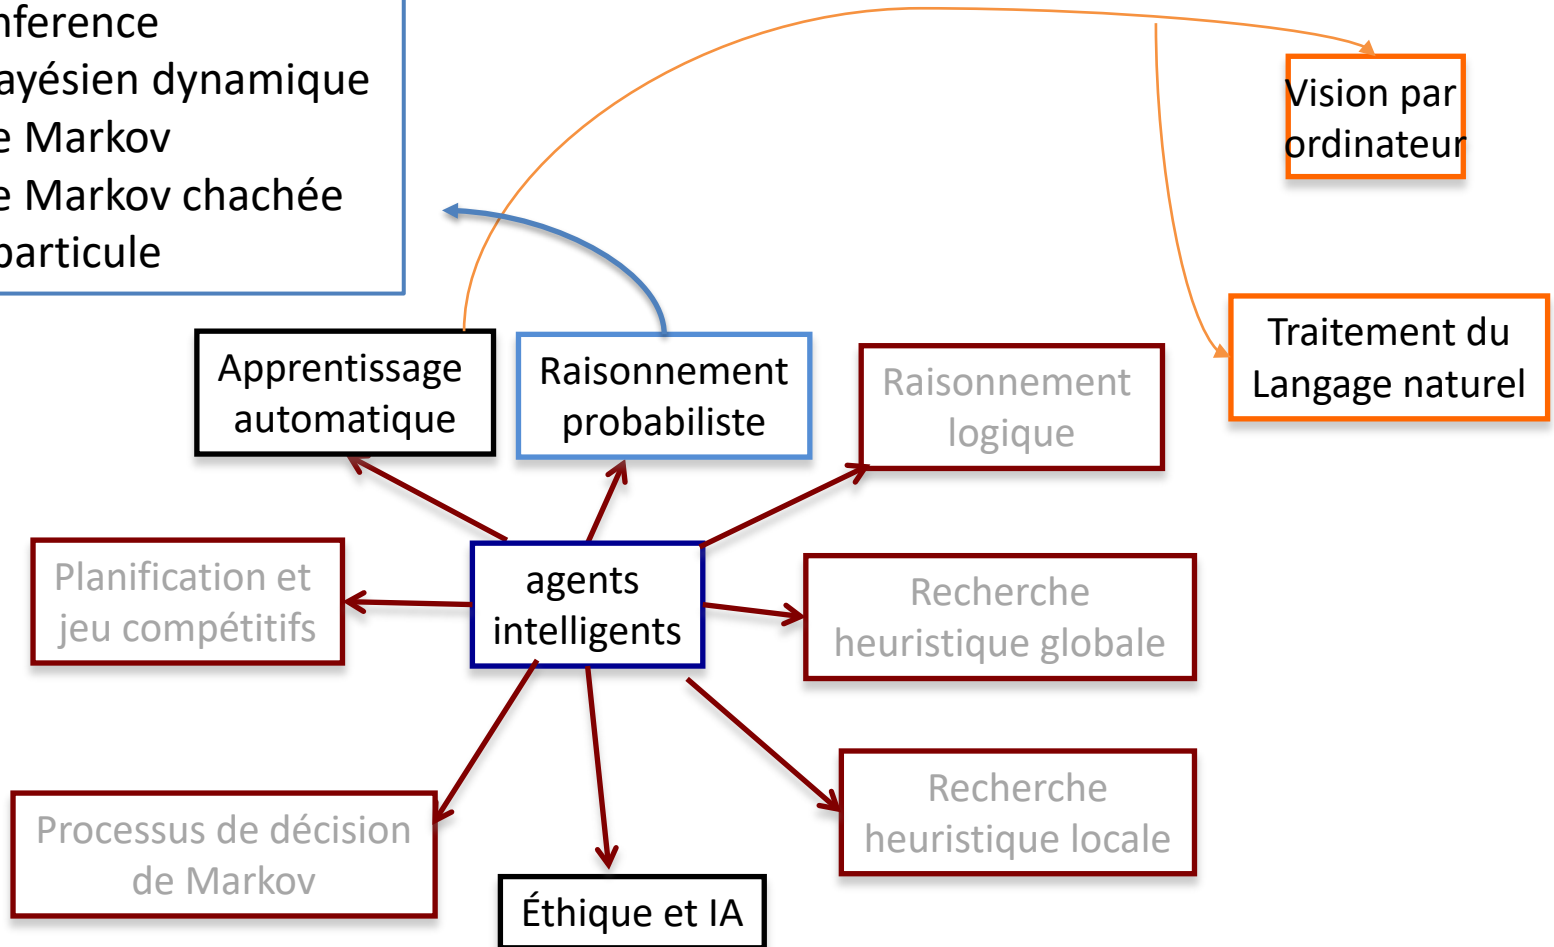


# Sujets couverts par le cours

## Concepts et algorithmes

## Applications

- Classifieur bayésien naïf
- Réseau bayésien
- Types d'inference
- Réseau bayésien dynamique
- Chaîne de Markov
- Chaîne de Markov cachée
- Filtre de particule



# Vous devriez être capable de...

- Distinguer les différents types d'inférence probabiliste temporelle:
  - ◆ filtrage
  - ◆ prédiction
  - ◆ lissage
  - ◆ explication la plus plausible
- Décrire ce qu'est un modèle de Markov caché
  - ◆ Définir et calculer le tableau  $\alpha$  par la programmation dynamique avant
  - ◆ Appliquer le tableau  $\alpha$  pour le filtrage et le calcul d'une séquence visible
- Décrire et appliquer un filtre de particules
- Note: TP #3 porte sur ces sujets.

**LA PARTIE SUIVANTE N'EST PAS  
COUVERTE PAR LES EXAMENS**



# Prédiction avec un HMM

- $\alpha(i,t)$  peut être utilisé pour inférer la distribution de prédiction  $\mathbf{P}(H_{t+k} | s_{1:t})$
- On utilise également un programme dynamique

- ◆ Notons  $\pi(i,k) = P(H_{t+k} = i | S_{1:t} = s_{1:t})$

- ◆ Récursivement:

$$\begin{aligned} \pi(i,k+1) &= P(H_{t+k+1} = i | S_{1:t} = s_{1:t}) \\ &= \sum_s \sum_j P(H_{t+k+1} = i, H_{t+k} = j, S_{t+k} = s | S_{1:t} = s_{1:t}) \\ &= \sum_s \sum_j P(S_{t+k} = s | H_{t+k} = j) P(H_{t+k+1} = i | H_{t+k} = j) P(H_{t+k} = j | S_{1:t} = s_{1:t}) \\ &= \sum_j P(H_{t+k+1} = i | H_{t+k} = j) P(H_{t+k} = j | S_{1:t} = s_{1:t}) \sum_s P(S_{t+k} = s | H_{t+k} = j) \\ &= \sum_j P(H_{t+k+1} = i | H_{t+k} = j) \pi(j,k) \end{aligned}$$

- ◆ On a les valeurs initiales

$$\pi(i,0) = P(H_t = i | s_{1:t}) = \alpha(i,t) / \sum_j \alpha(j,t) \quad \forall i$$

- On pourrait également faire une prédiction de  $S_{t+k}$

- ◆ 
$$\begin{aligned} P(S_{t+k} = s | S_{1:t} = s_{1:t}) &= \sum_j P(S_{t+k} = s | H_{t+k} = j) P(H_{t+k} = j | S_{1:t} = s_{1:t}) \\ &= \sum_j P(S_{t+k} = s | H_{t+k} = j) \pi(j,k) \end{aligned}$$

# Exemple - Prédiction avec un HMM

- Décoder un message binaire avec canal bruité (T=4)
  - ◆ on souhaite calculer la distribution de prédiction  $P(H_6=0 \mid S_1=0, S_2=1, S_3=0, S_4=0)$

Modèle d'observation


	$H_t=0$	$H_t=1$
$P(S_t=0 \mid H_t)$	0.9	0.2
$P(S_t=1 \mid H_t)$	0.1	0.8

Modèle de transition

	$H_{t-1}=0$	$H_{t-1}=1$
$P(H_t=0 \mid H_{t-1})$	0.3	0.4
$P(H_t=1 \mid H_{t-1})$	0.7	0.6

Distribution initiale

	$H_1=0$	$H_1=1$
$P(H_1)$	0.5	0.5



- Voir la suite dans les diapos en ligne (cachés)

# Exemple - Prédiction avec un HMM

- Décoder un message binaire avec canal bruité (T=4)
  - ◆ on souhaite calculer la distribution de prédiction  $P(H_6=0 \mid S_1=0, S_2=1, S_3=0, S_4=0)$

Modèle d'observation


	$H_t=0$	$H_t=1$
$P(S_t=0 \mid H_t)$	0.9	0.2
$P(S_t=1 \mid H_t)$	0.1	0.8

Modèle de transition

	$H_{t-1}=0$	$H_{t-1}=1$
$P(H_t=0 \mid H_{t-1})$	0.3	0.4
$P(H_t=1 \mid H_{t-1})$	0.7	0.6

Distribution initiale

	$H_1=0$	$H_1=1$
$P(H_1)$	0.5	0.5



- ◆ initialisation:  $\pi(i,0) = \alpha(i,t) / \sum_j \alpha(j,t)$

# Exemple - Prédiction avec un HMM

- Décoder un message binaire avec canal bruité (T=4)
  - ◆ on souhaite calculer la distribution de prédiction  $P(H_6=0 \mid S_1=0, S_2=1, S_3=0, S_4=0)$

**Modèle d'observation**

	$H_t=0$	$H_t=1$
$P(S_t=0 \mid H_t)$	0.9	0.2
$P(S_t=1 \mid H_t)$	0.1	0.8

**Modèle de transition**

	$H_{t-1}=0$	$H_{t-1}=1$
$P(H_t=0 \mid H_{t-1})$	0.3	0.4
$P(H_t=1 \mid H_{t-1})$	0.7	0.6

**Distribution initiale**

	$H_1=0$	$H_1=1$
$P(H_1)$	0.5	0.5

$\alpha(i,t)$	$i \backslash t$	...	4
0	...	0.04427	
1	...	0.02039	

$\pi(i,k)$	$i \backslash k$	0	1	2
0				
1				

- ◆ initialisation:  $\pi(0,0) = \alpha(0,4) / (\alpha(0,4) + \alpha(1,4))$

# Exemple - Prédiction avec un HMM

- Décoder un message binaire avec canal bruité (T=4)
  - ◆ on souhaite calculer la distribution de prédiction  $P(H_6=0 \mid S_1=0, S_2=1, S_3=0, S_4=0)$

**Modèle d'observation**

	$H_t=0$	$H_t=1$
$P(S_t=0 \mid H_t)$	0.9	0.2
$P(S_t=1 \mid H_t)$	0.1	0.8

**Modèle de transition**

	$H_{t-1}=0$	$H_{t-1}=1$
$P(H_t=0 \mid H_{t-1})$	0.3	0.4
$P(H_t=1 \mid H_{t-1})$	0.7	0.6

**Distribution initiale**

	$H_1=0$	$H_1=1$
$P(H_1)$	0.5	0.5

$\alpha(i,t)$

$i \backslash t$	...	4
0	...	0.04427
1	...	0.02039

$\pi(i,k)$

$i \backslash k$	0	1	2
0	0.68466		
1			

- ◆ initialisation:  $\pi(0,0) = 0.04427 / (0.04427 + 0.02039) = 0.68466$

# Exemple - Prédiction avec un HMM

- Décoder un message binaire avec canal bruité (T=4)
  - ◆ on souhaite calculer la distribution de prédiction  $P(H_6=0 \mid S_1=0, S_2=1, S_3=0, S_4=0)$

**Modèle d'observation**

	$H_t=0$	$H_t=1$
$P(S_t=0 \mid H_t)$	0.9	0.2
$P(S_t=1 \mid H_t)$	0.1	0.8

**Modèle de transition**

	$H_{t-1}=0$	$H_{t-1}=1$
$P(H_t=0 \mid H_{t-1})$	0.3	0.4
$P(H_t=1 \mid H_{t-1})$	0.7	0.6

**Distribution initiale**

	$H_1=0$	$H_1=1$
$P(H_1)$	0.5	0.5

$\alpha(i,t)$

$i \backslash t$	...	4
0	...	0.04427
1	...	0.02039

$\pi(i,k)$

$i \backslash k$	0	1	2
0	0.68466		
1	0.31534		

- ◆ initialisation:  $\pi(1,0) = 0.02039 / (0.04427 + 0.02039) = 0.31534$

# Exemple - Prédiction avec un HMM

- Décoder un message binaire avec canal bruité (T=4)
  - ◆ on souhaite calculer la distribution de prédiction  $P(H_6=0 \mid S_1=0, S_2=1, S_3=0, S_4=0)$

Modèle d'observation

	$H_t=0$	$H_t=1$
$P(S_t=0 \mid H_t)$	0.9	0.2
$P(S_t=1 \mid H_t)$	0.1	0.8

Modèle de transition

	$H_{t-1}=0$	$H_{t-1}=1$
$P(H_t=0 \mid H_{t-1})$	0.3	0.4
$P(H_t=1 \mid H_{t-1})$	0.7	0.6

Distribution initiale

	$H_1=0$	$H_1=1$
$P(H_1)$	0.5	0.5

$\alpha(i,t)$

$i \backslash t$	...	4
0	...	0.04427
1	...	0.02039

$\pi(i,k)$

$i \backslash k$	0	1	2
0	0.68466		
1	0.31534		

- ◆ récursion (k=0):  $\pi(i,k+1) = \sum_j P(H_{t+k+1} = i \mid H_{t+k} = j) \pi(j,k)$

# Exemple - Prédiction avec un HMM

- Décoder un message binaire avec canal bruité (T=4)
  - ◆ on souhaite calculer la distribution de prédiction  $P(H_6=0 \mid S_1=0, S_2=1, S_3=0, S_4=0)$

Modèle d'observation

	$H_t=0$	$H_t=1$
$P(S_t=0 \mid H_t)$	0.9	0.2
$P(S_t=1 \mid H_t)$	0.1	0.8

Modèle de transition

	$H_{t-1}=0$	$H_{t-1}=1$
$P(H_t=0 \mid H_{t-1})$	0.3	0.4
$P(H_t=1 \mid H_{t-1})$	0.7	0.6

Distribution initiale

	$H_1=0$	$H_1=1$
$P(H_1)$	0.5	0.5

$\alpha(i,t)$	$i \backslash t$	...	4
0	...	0.04427	
1	...	0.02039	

$\pi(i,k)$	$i \backslash k$	0	1	2
0	0	0.68466		
1	0	0.31534		

- ◆ récursion (k=0):  $\pi(0, 1) = P(H_5 = 0 \mid H_4 = 0) \pi(0,0) + P(H_5 = 0 \mid H_4 = 1) \pi(1,0)$



# Exemple - Prédiction avec un HMM

- Décoder un message binaire avec canal bruité (T=4)
  - ◆ on souhaite calculer la distribution de prédiction  $P(H_6=0 \mid S_1=0, S_2=1, S_3=0, S_4=0)$

Modèle d'observation

	$H_t=0$	$H_t=1$
$P(S_t=0 \mid H_t)$	0.9	0.2
$P(S_t=1 \mid H_t)$	0.1	0.8

Modèle de transition

	$H_{t-1}=0$	$H_{t-1}=1$
$P(H_t=0 \mid H_{t-1})$	0.3	0.4
$P(H_t=1 \mid H_{t-1})$	0.7	0.6

Distribution initiale

	$H_1=0$	$H_1=1$
$P(H_1)$	0.5	0.5

$\alpha(i,t)$	$i \backslash t$	...	4
0	...	0.04427	
1	...	0.02039	

$\pi(i,k)$	$i \backslash k$	0	1	2
0	0	0.68466	0.33154	
1	0	0.31534		

- ◆ récursion (k=0):  $\pi(0, 1) = 0.3 \times 0.68466 + 0.4 \times 0.31534 = 0.33154$

# Exemple - Prédiction avec un HMM

- Décoder un message binaire avec canal bruité (T=4)
  - ◆ on souhaite calculer la distribution de prédiction  $P(H_6=0 \mid S_1=0, S_2=1, S_3=0, S_4=0)$

Modèle d'observation

	$H_t=0$	$H_t=1$
$P(S_t=0 \mid H_t)$	0.9	0.2
$P(S_t=1 \mid H_t)$	0.1	0.8

Modèle de transition

	$H_{t-1}=0$	$H_{t-1}=1$
$P(H_t=0 \mid H_{t-1})$	0.3	0.4
$P(H_t=1 \mid H_{t-1})$	0.7	0.6

Distribution initiale

	$H_1=0$	$H_1=1$
$P(H_1)$	0.5	0.5

$\alpha(i,t)$

i \ t	...	4
0	...	0.04427
1	...	0.02039

$\pi(i,k)$

i \ k	0	1	2
0	0.68466	0.33154	
1	0.31534		

Arrows point from the cell (0,1) to (1,1) and from (1,0) to (1,1).

- ◆ récursion (k=0):  $\pi(1, 1) = P(H_5 = 1 \mid H_4 = 0) \pi(0,0) + P(H_5 = 1 \mid H_4 = 1) \pi(1,0)$

# Exemple - Prédiction avec un HMM

- Décoder un message binaire avec canal bruité (T=4)
  - ◆ on souhaite calculer la distribution de prédiction  $P(H_6=0 \mid S_1=0, S_2=1, S_3=0, S_4=0)$

Modèle d'observation

	$H_t=0$	$H_t=1$
$P(S_t=0 \mid H_t)$	0.9	0.2
$P(S_t=1 \mid H_t)$	0.1	0.8

Modèle de transition

	$H_{t-1}=0$	$H_{t-1}=1$
$P(H_t=0 \mid H_{t-1})$	0.3	0.4
$P(H_t=1 \mid H_{t-1})$	0.7	0.6

Distribution initiale

	$H_1=0$	$H_1=1$
$P(H_1)$	0.5	0.5

$\alpha(i,t)$	$i \backslash t$	...	4
0	...	0.04427	
1	...	0.02039	

$\pi(i,k)$	$i \backslash k$	0	1	2
0	0	0.68466	0.33154	
1	0	0.31534	0.66846	

- ◆ récursion (k=0):  $\pi(0, 1) = 0.7 \times 0.68466 + 0.6 \times 0.31534 = 0.66846$

# Exemple - Prédiction avec un HMM

- Décoder un message binaire avec canal bruité (T=4)
  - ◆ on souhaite calculer la distribution de prédiction  $P(H_6=0 \mid S_1=0, S_2=1, S_3=0, S_4=0)$

**Modèle d'observation**

	$H_t=0$	$H_t=1$
$P(S_t=0 \mid H_t)$	0.9	0.2
$P(S_t=1 \mid H_t)$	0.1	0.8

**Modèle de transition**

	$H_{t-1}=0$	$H_{t-1}=1$
$P(H_t=0 \mid H_{t-1})$	0.3	0.4
$P(H_t=1 \mid H_{t-1})$	0.7	0.6

**Distribution initiale**

	$H_1=0$	$H_1=1$
$P(H_1)$	0.5	0.5

$\alpha(i,t)$

$i \backslash t$	...	4
0	...	0.04427
1	...	0.02039

$\pi(i,k)$

$i \backslash k$	0	1	2
0	0.68466	0.33154	0.36685
1	0.31534	0.66846	0.63315

- ◆ on continue d'appliquer la récursion jusqu'à la fin (k=2)...

# Exemple - Prédiction avec un HMM

- Décoder un message binaire avec canal bruité (T=4)
  - ◆ on souhaite calculer la distribution de prédiction  $P(H_6=0 \mid S_1=0, S_2=1, S_3=0, S_4=0)$

Modèle d'observation

	$H_t=0$	$H_t=1$
$P(S_t=0 \mid H_t)$	0.9	0.2
$P(S_t=1 \mid H_t)$	0.1	0.8

Modèle de transition

	$H_{t-1}=0$	$H_{t-1}=1$
$P(H_t=0 \mid H_{t-1})$	0.3	0.4
$P(H_t=1 \mid H_{t-1})$	0.7	0.6

Distribution initiale

	$H_1=0$	$H_1=1$
$P(H_1)$	0.5	0.5

$\alpha(i,t)$	$i \backslash t$	...	4
0	...	0.04427	
1	...	0.02039	

$\pi(i,k)$	$i \backslash k$	0	1	2
0	0	0.68466	0.33154	0.36685
1	0	0.31534	0.66846	0.63315

◆  $P(H_6=0 \mid S_1=0, S_2=1, S_3=0, S_4=0) = \pi(0,2) = 0.36685$

# Lissage pour un HMM

- Pour faire le lissage, en plus du tableau des  $\alpha(i,t)$  généré par un balayage de gauche à droite, nous avons besoin d'un tableau analogue,  $\beta(i,t)$ , généré de de droite à gauche

- ◆ Notons  $\beta(i,t) = P(S_{t+1:T}=s_{t+1:T} \mid H_t = i)$

- ◆ Récursivement on a:

$$\begin{aligned} \beta(i,t-1) &= P(S_{t:T}=s_{t:T} \mid H_{t-1} = i) \\ &= \sum_j P(S_{t:T}=s_{t:T}, H_t = j \mid H_{t-1} = i) = \sum_j P(S_{t+1:T}=s_{t+1:T}, S_t=s_t, H_t = j \mid H_{t-1} = i) \\ &= \sum_j P(S_t = s_t \mid H_t = j) P(H_t = j \mid H_{t-1} = i) P(S_{t+1:T}=s_{t+1:T} \mid H_t = j) \\ &= \sum_j P(S_t = s_t \mid H_t = j) P(H_t = j \mid H_{t-1} = i) \beta(j,t) \end{aligned}$$

- ◆ On a les valeurs initiales  $\beta(i,T) = 1 \forall i$

- Remarquez le tableau  $\beta$  calculé donne aussi une autre façon de calculer la probabilité d'une séquence de sortie:

$$\begin{aligned} P(S_{1:T}=s_{1:T}) &= \sum_j P(S_{1:T}=s_{1:T}, H_1 = j) \\ &= \sum_j P(S_{2:T}=s_{2:T} \mid H_1 = j) P(S_1=s_1 \mid H_1 = j) P(H_1 = j) \\ &= \sum_j \beta(j,1) P(S_1=s_1 \mid H_1 = j) P(H_1 = j) \end{aligned}$$

# Exemple - Programmation dynamique à rebours pour un HMM

- Décoder un message binaire avec canal bruité ( $T=4$ )
  - ◆ message observé:  $S_1=0, S_2=1, S_3=0, S_4=0$

Modèle d'observation

	$H_t=0$	$H_t=1$
$P(S_t=0   H_t)$	0.9	0.2
$P(S_t=1   H_t)$	0.1	0.8

Modèle de transition

	$H_{t-1}=0$	$H_{t-1}=1$
$P(H_t=0   H_{t-1})$	0.3	0.4
$P(H_t=1   H_{t-1})$	0.7	0.6

Distribution initiale

	$H_1=0$	$H_1=1$
$P(H_1)$	0.5	0.5

$\beta(i,t)$	$i \backslash t$	1	2	3	4
0					
1					

- ◆ initialisation:  $\beta(i,4) = 1$

# Exemple - Programmation dynamique à rebours pour un HMM

- Décoder un message binaire avec canal bruité (T=4)
  - ◆ message observé:  $S_1=0, S_2=1, S_3=0, S_4=0$

Modèle d'observation

	$H_t=0$	$H_t=1$
$P(S_t=0   H_t)$	0.9	0.2
$P(S_t=1   H_t)$	0.1	0.8

Modèle de transition

	$H_{t-1}=0$	$H_{t-1}=1$
$P(H_t=0   H_{t-1})$	0.3	0.4
$P(H_t=1   H_{t-1})$	0.7	0.6

Distribution initiale

	$H_1=0$	$H_1=1$
$P(H_1)$	0.5	0.5

$\beta(i,t)$	$t$	1	2	3	4
0					
1					

- ◆ initialisation:  $\beta(i,4) = 1$



# Exemple - Programmation dynamique à rebours pour un HMM

- Décoder un message binaire avec canal bruité (T=4)
  - ◆ message observé:  $S_1=0, S_2=1, S_3=0, S_4=0$

Modèle d'observation

	$H_t=0$	$H_t=1$
$P(S_t=0   H_t)$	0.9	0.2
$P(S_t=1   H_t)$	0.1	0.8

Modèle de transition

	$H_{t-1}=0$	$H_{t-1}=1$
$P(H_t=0   H_{t-1})$	0.3	0.4
$P(H_t=1   H_{t-1})$	0.7	0.6

Distribution initiale

	$H_1=0$	$H_1=1$
$P(H_1)$	0.5	0.5

$\beta(i,t)$	$i \backslash t$	1	2	3	4
0					1
1					1

- ◆ initialisation:  $\beta(i,4) = 1$

# Exemple - Programmation dynamique à rebours pour un HMM

- Décoder un message binaire avec canal bruité (T=4)
  - ◆ message observé:  $S_1=0, S_2=1, S_3=0, S_4=0$

Modèle d'observation

	$H_t=0$	$H_t=1$
$P(S_t=0   H_t)$	0.9	0.2
$P(S_t=1   H_t)$	0.1	0.8

Modèle de transition

	$H_{t-1}=0$	$H_{t-1}=1$
$P(H_t=0   H_{t-1})$	0.3	0.4
$P(H_t=1   H_{t-1})$	0.7	0.6

Distribution initiale

	$H_1=0$	$H_1=1$
$P(H_1)$	0.5	0.5

$\beta(i,t)$	$t$	1	2	3	4
0					1
1					1

- ◆ récursion ( $t=4$ ):  $\beta(i,t-1) = \sum_j P(S_t = s_t | H_t = j) P(H_t = j | H_{t-1} = i) \beta(j,t)$

# Exemple - Programmation dynamique à rebours pour un HMM

- Décoder un message binaire avec canal bruité (T=4)
  - ◆ message observé:  $S_1=0, S_2=1, S_3=0, S_4=0$

Modèle d'observation

	$H_t=0$	$H_t=1$
$P(S_t=0   H_t)$	0.9	0.2
$P(S_t=1   H_t)$	0.1	0.8

Modèle de transition

	$H_{t-1}=0$	$H_{t-1}=1$
$P(H_t=0   H_{t-1})$	0.3	0.4
$P(H_t=1   H_{t-1})$	0.7	0.6

Distribution initiale

	$H_1=0$	$H_1=1$
$P(H_1)$	0.5	0.5

$\beta(i,t)$	$t$	1	2	3	4
0					1
1					1

◆ récursion  $\beta(0,3) = P(S_4=0 | H_4=0) P(H_4=0 | H_3=0) \beta(0,4) + P(S_4=0 | H_4=1) P(H_4=1 | H_3=0) \beta(1,4)$

# Exemple - Programmation dynamique à rebours pour un HMM

- Décoder un message binaire avec canal bruité (T=4)
  - ◆ message observé:  $S_1=0, S_2=1, S_3=0, S_4=0$

Modèle d'observation

	$H_t=0$	$H_t=1$
$P(S_t=0   H_t)$	0.9	0.2
$P(S_t=1   H_t)$	0.1	0.8

Modèle de transition

	$H_{t-1}=0$	$H_{t-1}=1$
$P(H_t=0   H_{t-1})$	0.3	0.4
$P(H_t=1   H_{t-1})$	0.7	0.6

Distribution initiale

	$H_1=0$	$H_1=1$
$P(H_1)$	0.5	0.5

$\beta(i,t)$	$i \backslash t$	1	2	3	4
0				0.41	1
1					1

- ◆ récursion  $\beta(0,3) = 0.9 \times 0.3 \times 1 + 0.2 \times 0.7 \times 1 = 0.41$

# Exemple - Programmation dynamique à rebours pour un HMM

- Décoder un message binaire avec canal bruité (T=4)
  - ◆ message observé:  $S_1=0, S_2=1, S_3=0, S_4=0$

Modèle d'observation

	$H_t=0$	$H_t=1$
$P(S_t=0   H_t)$	0.9	0.2
$P(S_t=1   H_t)$	0.1	0.8

Modèle de transition

	$H_{t-1}=0$	$H_{t-1}=1$
$P(H_t=0   H_{t-1})$	0.3	0.4
$P(H_t=1   H_{t-1})$	0.7	0.6

Distribution initiale

	$H_1=0$	$H_1=1$
$P(H_1)$	0.5	0.5

$\beta(i,t)$	$t$	1	2	3	4
0				0.41	1
1					1

◆ récursion  $\beta(1,3) = P(S_4=0 | H_4=0) P(H_4=0 | H_3=1) \beta(0,4) + P(S_4=0 | H_4=1) P(H_4=1 | H_3=1) \beta(1,4)$

# Exemple - Programmation dynamique à rebours pour un HMM

- Décoder un message binaire avec canal bruité (T=4)
  - ◆ message observé:  $S_1=0, S_2=1, S_3=0, S_4=0$

Modèle d'observation

	$H_t=0$	$H_t=1$
$P(S_t=0   H_t)$	0.9	0.2
$P(S_t=1   H_t)$	0.1	0.8

Modèle de transition

	$H_{t-1}=0$	$H_{t-1}=1$
$P(H_t=0   H_{t-1})$	0.3	0.4
$P(H_t=1   H_{t-1})$	0.7	0.6

Distribution initiale

	$H_1=0$	$H_1=1$
$P(H_1)$	0.5	0.5

$\beta(i,t)$	$t$	1	2	3	4
0				0.41	1
1				0.48	1

- ◆ récursion  $\beta(1,3) = 0.9 \times 0.4 \times 1 + 0.2 \times 0.6 \times 1 = 0.48$

# Exemple - Programmation dynamique à rebours pour un HMM

- Décoder un message binaire avec canal bruité (T=4)
  - ◆ message observé:  $S_1=0, S_2=1, S_3=0, S_4=0$

Modèle d'observation

	$H_t=0$	$H_t=1$
$P(S_t=0   H_t)$	0.9	0.2
$P(S_t=1   H_t)$	0.1	0.8

Modèle de transition

	$H_{t-1}=0$	$H_{t-1}=1$
$P(H_t=0   H_{t-1})$	0.3	0.4
$P(H_t=1   H_{t-1})$	0.7	0.6

Distribution initiale

	$H_1=0$	$H_1=1$
$P(H_1)$	0.5	0.5

$\beta(i,t)$	$t$	1	2	3	4
0				0.41	1
1				0.48	1

- ◆ récursion ( $t=3$ ):  $\beta(i,t-1) = \sum_j P(S_t = s_t | H_t = j) P(H_t = j | H_{t-1} = i) \beta(j,t)$

# Exemple - Programmation dynamique à rebours pour un HMM

- Décoder un message binaire avec canal bruité (T=4)
  - ◆ message observé:  $S_1=0, S_2=1, S_3=0, S_4=0$

Modèle d'observation

	$H_t=0$	$H_t=1$
$P(S_t=0   H_t)$	0.9	0.2
$P(S_t=1   H_t)$	0.1	0.8

Modèle de transition

	$H_{t-1}=0$	$H_{t-1}=1$
$P(H_t=0   H_{t-1})$	0.3	0.4
$P(H_t=1   H_{t-1})$	0.7	0.6

Distribution initiale

	$H_1=0$	$H_1=1$
$P(H_1)$	0.5	0.5

$\beta(i,t)$	$t$	1	2	3	4
0			←	0.41	1
1			←	0.48	1

◆ récursion  $\beta(0,2) = P(S_3=0 | H_3=0) P(H_3=0 | H_2=0) \beta(0,3) + P(S_3=0 | H_3=1) P(H_3=1 | H_2=0) \beta(1,3)$



# Exemple - Programmation dynamique à rebours pour un HMM

- Décoder un message binaire avec canal bruité (T=4)
  - ◆ message observé:  $S_1=0, S_2=1, S_3=0, S_4=0$

Modèle d'observation

	$H_t=0$	$H_t=1$
$P(S_t=0   H_t)$	0.9	0.2
$P(S_t=1   H_t)$	0.1	0.8

Modèle de transition

	$H_{t-1}=0$	$H_{t-1}=1$
$P(H_t=0   H_{t-1})$	0.3	0.4
$P(H_t=1   H_{t-1})$	0.7	0.6

Distribution initiale

	$H_1=0$	$H_1=1$
$P(H_1)$	0.5	0.5

$\beta(i,t)$	$t$	1	2	3	4
0			0.1779	0.41	1
1				0.48	1

- ◆ récursion  $\beta(0,2) = 0.9 \times 0.3 \times 0.41 + 0.2 \times 0.7 \times 0.48 = 0.1779$

# Exemple - Programmation dynamique à rebours pour un HMM

- Décoder un message binaire avec canal bruité (T=4)
  - ◆ message observé:  $S_1=0, S_2=1, S_3=0, S_4=0$

Modèle d'observation

	$H_t=0$	$H_t=1$
$P(S_t=0   H_t)$	0.9	0.2
$P(S_t=1   H_t)$	0.1	0.8

Modèle de transition

	$H_{t-1}=0$	$H_{t-1}=1$
$P(H_t=0   H_{t-1})$	0.3	0.4
$P(H_t=1   H_{t-1})$	0.7	0.6

Distribution initiale

	$H_1=0$	$H_1=1$
$P(H_1)$	0.5	0.5

$\beta(i,t)$	$t$	1	2	3	4
0		0.120249	0.1779	0.41	1
1		0.105612	0.2052	0.48	1

- ◆ on continue d'appliquer la récursion jusqu'au début (t=1)...

# Lissage avec un HMM

- Les tables  $\alpha(i,t)$  et  $\beta(i,t)$  peuvent également être utilisées pour faire du lissage
  - ◆ 
$$\begin{aligned} P(H_k = i \mid S_{1:T} = s_{1:T}) &= \Upsilon P(H_k = i, S_{1:k} = s_{1:k}, S_{k+1:T} = s_{k+1:T}) \quad (\Upsilon \text{ est la normalisation}) \\ &= \Upsilon P(H_k = i, S_{1:k} = s_{1:k}) P(S_{k+1:T} = s_{k+1:T} \mid H_k = i) \\ &= \Upsilon \alpha(i,k) \beta(i,k) \end{aligned}$$
- On peut également faire du lissage sur deux variables cachées adjacentes
  - ◆ 
$$\begin{aligned} P(H_k = i, H_{k+1} = j \mid S_{1:T} = s_{1:T}) &= \Upsilon' P(H_k = i, H_{k+1} = j, S_{1:k} = s_{1:k}, S_{k+1:T} = s_{k+1:T}) \\ &= \Upsilon' P(H_k = i, S_{1:k} = s_{1:k}) P(H_{k+1} = j \mid H_k = i) P(S_{k+1} = s_{k+1} \mid H_{k+1} = j) \\ &\quad P(S_{k+2:T} = s_{k+2:T} \mid H_{k+1} = j) \\ &= \Upsilon' \alpha(i,k) \beta(j,k+1) P(H_{k+1} = j \mid H_k = i) P(S_{k+1} = s_{k+1} \mid H_{k+1} = j) \end{aligned}$$
- À noter que  $\Upsilon$  correspond à une somme sur  $i$  seulement, tandis que  $\Upsilon'$  est une somme sur  $i$  et  $j$

# Exemple - Lissage avec un HMM

- Décoder un message binaire avec canal bruité (T=4)

◆ message observé:  $S_1=0, S_2=1, S_3=0, S_4=0$

$\alpha(i,t)$	i \ t	...	2	...
0		...	0.0175	...
1		...	0.3	...

$\beta(i,t)$	i \ t	...	2	...
0		...	0.1779	...
1		...	0.2052	...

- ◆ on peut calculer les probabilités de lissage au temps t=2

$$\begin{aligned}
 P(H_2 = 0 \mid S_1=0, S_2=1, S_3=0, S_4=0) &= \frac{\alpha(0,2) \beta(0,2)}{\sum_i \alpha(i,2) \beta(i,2)} \\
 &= \alpha(0,2) \beta(0,2) / (\alpha(0,2) \beta(0,2) + \alpha(1,2) \beta(1,2)) \\
 &= 0.0175 \times 0.1779 / (0.0175 \times 0.1779 + 0.3 \times 0.2052) \\
 &\approx 0.04813
 \end{aligned}$$

$$\begin{aligned}
 P(H_2 = 1 \mid S_1=0, S_2=1, S_3=0, S_4=0) &= 0.3 \times 0.2052 / (0.0175 \times 0.1779 + 0.3 \times 0.2052) \\
 &\approx 0.95186
 \end{aligned}$$

# Explication la plus plausible avec un HMM

- On peut également éviter une énumération exponentielle

- ◆ exemple avec  $T=3$

$$\max_{h^*_{1:3}} P(h^*_1) P(s_1|h^*_1) P(h^*_2|h^*_1) P(s_2|h^*_2) P(h^*_3|h^*_2) P(s_3|h^*_3)$$

$$= \max_{h^*_3} P(s_3|h^*_3) \max_{h^*_2} P(s_2|h^*_2) P(h^*_3|h^*_2) \max_{h^*_1} P(h^*_2|h^*_1) P(h^*_1) P(s_1|h^*_1)$$

- Solution: **programmation dynamique**, avec un **max** au lieu de la somme

- ◆ Notons  $\alpha^*(i,t) = P(S_{1:t}=s_{1:t}, H_{1:t-1} = h^*_{1:t-1}, H_t = i)$

- ◆ Récursivement, on a:

$$\begin{aligned} \alpha^*(i,t+1) &= \max_j P(S_{1:t+1}=s_{1:t+1}, H_{1:t-1} = h^*_{1:t-1}, H_t = j, H_{t+1} = i) \\ &= \max_j P(S_{t+1}=s_{t+1} \mid H_{t+1} = i) P(H_{t+1} = i \mid H_t = j) P(S_{1:t}=s_{1:t}, H_{1:t-1} = h^*_{1:t-1}, H_t = j) \\ &= P(S_{t+1}=s_{t+1} \mid H_{t+1} = i) \max_j P(H_{t+1} = i \mid H_t = j) \alpha^*(j,t) \end{aligned}$$

- ◆ On a les valeurs initiales:  $\alpha^*(i,1) = P(S_1=s_1 \mid H_1 = i) P(H_1 = i) \quad \forall i$

- On a alors que  $P(S_{1:T}=s_{1:T}, H_{1:T} = h^*_{1:T}) = \max_j \alpha^*(j,T)$

- On retrouve  $h^*_{1:T}$  à partir de tous les  $\operatorname{argmax}_j$

# Exemple - Explication la plus plausible avec un HMM

- Décoder un message binaire avec canal bruité (T=4)
  - ◆ message observé:  $S_1=0, S_2=1, S_3=0, S_4=0$

Modèle d'observation

	$H_t=0$	$H_t=1$
$P(S_t=0   H_t)$	0.9	0.2
$P(S_t=1   H_t)$	0.1	0.8

Modèle de transition

	$H_{t-1}=0$	$H_{t-1}=1$
$P(H_t=0   H_{t-1})$	0.3	0.4
$P(H_t=1   H_{t-1})$	0.7	0.6

Distribution initiale

	$H_1=0$	$H_1=1$
$P(H_1)$	0.5	0.5

$\alpha^*(i,t)$	$t$	1	2	3	4
0					
1					

- ◆ initialisation:  $\alpha^*(i,1) = P(S_1=s_1, H_1 = i) = P(S_1=s_1 | H_1 = i) P(H_1 = i)$

# Exemple - Explication la plus plausible avec un HMM

- Décoder un message binaire avec canal bruité (T=4)
  - ◆ message observé:  $S_1=0, S_2=1, S_3=0, S_4=0$

Modèle d'observation

	$H_t=0$	$H_t=1$
$P(S_t=0   H_t)$	0.9	0.2
$P(S_t=1   H_t)$	0.1	0.8

Modèle de transition

	$H_{t-1}=0$	$H_{t-1}=1$
$P(H_t=0   H_{t-1})$	0.3	0.4
$P(H_t=1   H_{t-1})$	0.7	0.6

Distribution initiale

	$H_1=0$	$H_1=1$
$P(H_1)$	0.5	0.5

$\alpha^*(i,t)$	$t$	1	2	3	4
0		0.45			
1					

- ◆ initialisation:  $\alpha^*(0,1) = P(S_1=0 | H_1=0) P(H_1=0) = 0.9 \times 0.5 = 0.45$

# Exemple - Explication la plus plausible avec un HMM

- Décoder un message binaire avec canal bruité (T=4)
  - ◆ message observé:  $S_1=0, S_2=1, S_3=0, S_4=0$

Modèle d'observation

	$H_t=0$	$H_t=1$
$P(S_t=0   H_t)$	0.9	0.2
$P(S_t=1   H_t)$	0.1	0.8

Modèle de transition

	$H_{t-1}=0$	$H_{t-1}=1$
$P(H_t=0   H_{t-1})$	0.3	0.4
$P(H_t=1   H_{t-1})$	0.7	0.6

Distribution initiale

	$H_1=0$	$H_1=1$
$P(H_1)$	0.5	0.5

$\alpha^*(i,t)$	$i \backslash t$	1	2	3	4
0		0.45			
1		0.1			

- ◆ initialisation:  $\alpha^*(1,1) = P(S_1=0 | H_1 = 1) P(H_1 = 1) = 0.2 \times 0.5 = 0.1$



# Exemple - Explication la plus plausible avec un HMM

- Décoder un message binaire avec canal bruité (T=4)
  - ◆ message observé:  $S_1=0, S_2=1, S_3=0, S_4=0$

Modèle d'observation

	$H_t=0$	$H_t=1$
$P(S_t=0   H_t)$	0.9	0.2
$P(S_t=1   H_t)$	0.1	0.8

Modèle de transition

	$H_{t-1}=0$	$H_{t-1}=1$
$P(H_t=0   H_{t-1})$	0.3	0.4
$P(H_t=1   H_{t-1})$	0.7	0.6

Distribution initiale

	$H_1=0$	$H_1=1$
$P(H_1)$	0.5	0.5

$i \backslash t$		1	2	3	4
0		0.45			
1		0.1			

Diagram illustrating the forward pass of the HMM algorithm. The table shows the values of  $\alpha^*(i,t)$  for  $t=1$  and  $t=2$ . The cells for  $t=2$  are highlighted in red. Arrows indicate the transitions from  $t=1$  to  $t=2$ : from state 0 at  $t=1$  to state 0 at  $t=2$  (value 0.45) and from state 1 at  $t=1$  to state 0 at  $t=2$  (value 0.1).

- ◆ récursion (t=1):  $\alpha^*(i,t+1) = P(S_{t+1}=s_{t+1} | H_{t+1} = i) \max_j P(H_{t+1} = i | H_t = j) \alpha^*(j,t)$

# Exemple - Explication la plus plausible avec un HMM

- Décoder un message binaire avec canal bruité (T=4)
  - ◆ message observé:  $S_1=0, S_2=1, S_3=0, S_4=0$

Modèle d'observation

	$H_t=0$	$H_t=1$
$P(S_t=0   H_t)$	0.9	0.2
$P(S_t=1   H_t)$	0.1	0.8

Modèle de transition

	$H_{t-1}=0$	$H_{t-1}=1$
$P(H_t=0   H_{t-1})$	0.3	0.4
$P(H_t=1   H_{t-1})$	0.7	0.6

Distribution initiale

	$H_1=0$	$H_1=1$
$P(H_1)$	0.5	0.5

$i \backslash t$	1	2	3	4
0	0.45			
1	0.1			

Diagram illustrating the forward pass of the HMM algorithm. The table shows the values of  $\alpha^*(i,t)$  for  $i \in \{0,1\}$  and  $t \in \{1,2,3,4\}$ . Arrows indicate the transitions from  $(i,t)$  to  $(i+1,t+1)$  and  $(i-1,t+1)$ .

- ◆ récursion:  $\alpha^*(0,2) = P(S_2=1 | H_2=0) \max\{P(H_2=0 | H_1=0) \alpha^*(0,1), P(H_2=0 | H_1=1) \alpha^*(1,1)\}$

# Exemple - Explication la plus plausible avec un HMM

- Décoder un message binaire avec canal bruité (T=4)
  - ◆ message observé:  $S_1=0, S_2=1, S_3=0, S_4=0$

Modèle d'observation

	$H_t=0$	$H_t=1$
$P(S_t=0   H_t)$	0.9	0.2
$P(S_t=1   H_t)$	0.1	0.8

Modèle de transition

	$H_{t-1}=0$	$H_{t-1}=1$
$P(H_t=0   H_{t-1})$	0.3	0.4
$P(H_t=1   H_{t-1})$	0.7	0.6

Distribution initiale

	$H_1=0$	$H_1=1$
$P(H_1)$	0.5	0.5

$\alpha^*(i,t)$	$t$	1	2	3	4
0		0.45	0.0135		
1		0.1			

- ◆ récursion:  $\alpha^*(0,2) = 0.1 \max\{ \underline{0.3 \times 0.45}, 0.4 \times 0.1 \} = 0.0135$

# Exemple - Explication la plus plausible avec un HMM

- Décoder un message binaire avec canal bruité (T=4)
  - ◆ message observé:  $S_1=0, S_2=1, S_3=0, S_4=0$

Modèle d'observation

	$H_t=0$	$H_t=1$
$P(S_t=0   H_t)$	0.9	0.2
$P(S_t=1   H_t)$	0.1	0.8

Modèle de transition

	$H_{t-1}=0$	$H_{t-1}=1$
$P(H_t=0   H_{t-1})$	0.3	0.4
$P(H_t=1   H_{t-1})$	0.7	0.6

Distribution initiale

	$H_1=0$	$H_1=1$
$P(H_1)$	0.5	0.5

$\alpha^*(i,t)$	t	1	2	3	4
0		0.45	0.0135		
1		0.1			

Diagram illustrating the forward algorithm calculation for  $\alpha^*(1,2)$ . A red arrow points from  $\alpha^*(0,1) = 0.45$  to  $\alpha^*(1,2) = 0.0135$ . A black arrow points from  $\alpha^*(1,1) = 0.1$  to the same cell. The value 0.0135 is crossed out with a red line.

- ◆ récursion:  $\alpha^*(1,2) = P(S_2=1 | H_2=1) \max\{P(H_2 = 1 | H_1 = 0) \alpha^*(0,1), P(H_2 = 1 | H_1 = 1) \alpha^*(1,1)\}$

# Exemple - Explication la plus plausible avec un HMM

- Décoder un message binaire avec canal bruité (T=4)
  - ◆ message observé:  $S_1=0, S_2=1, S_3=0, S_4=0$

Modèle d'observation

	$H_t=0$	$H_t=1$
$P(S_t=0   H_t)$	0.9	0.2
$P(S_t=1   H_t)$	0.1	0.8

Modèle de transition

	$H_{t-1}=0$	$H_{t-1}=1$
$P(H_t=0   H_{t-1})$	0.3	0.4
$P(H_t=1   H_{t-1})$	0.7	0.6

Distribution initiale

	$H_1=0$	$H_1=1$
$P(H_1)$	0.5	0.5

$\alpha^*(i,t)$	$t$	1	2	3	4
0		0.45	0.0135		
1		0.1	0.252		

*Note: Red arrows in the original image point from 0.45 to 0.0135 and from 0.1 to 0.252.*

- ◆ récursion:  $\alpha^*(1,2) = 0.8 \max\{ \underline{0.7 \times 0.45}, 0.6 \times 0.1 \} = 0.252$

# Exemple - Explication la plus plausible avec un HMM

- Décoder un message binaire avec canal bruité (T=4)
  - ◆ message observé:  $S_1=0, S_2=1, S_3=0, S_4=0$

Modèle d'observation

	$H_t=0$	$H_t=1$
$P(S_t=0   H_t)$	0.9	0.2
$P(S_t=1   H_t)$	0.1	0.8

Modèle de transition

	$H_{t-1}=0$	$H_{t-1}=1$
$P(H_t=0   H_{t-1})$	0.3	0.4
$P(H_t=1   H_{t-1})$	0.7	0.6

Distribution initiale

	$H_1=0$	$H_1=1$
$P(H_1)$	0.5	0.5

$i \backslash t$		1	2	3	4
0		0.45	0.0135		
1		0.1	0.252		

Diagram illustrating the forward algorithm for  $\alpha^*(i,t)$ . The table shows values for  $t=1$  and  $t=2$ . Red arrows indicate transitions from  $(i,t)$  to  $(j,t+1)$ . The cells for  $t=3$  are highlighted in red, indicating they are the next step in the calculation.

- ◆ récursion ( $t=2$ ):  $\alpha^*(i,t+1) = P(S_{t+1}=s_{t+1} | H_{t+1} = i) \max_j P(H_{t+1} = i | H_t = j) \alpha^*(j,t)$

# Exemple - Explication la plus plausible avec un HMM

- Décoder un message binaire avec canal bruité (T=4)
  - ◆ message observé:  $S_1=0, S_2=1, S_3=0, S_4=0$

Modèle d'observation

	$H_t=0$	$H_t=1$
$P(S_t=0   H_t)$	0.9	0.2
$P(S_t=1   H_t)$	0.1	0.8

Modèle de transition

	$H_{t-1}=0$	$H_{t-1}=1$
$P(H_t=0   H_{t-1})$	0.3	0.4
$P(H_t=1   H_{t-1})$	0.7	0.6

Distribution initiale

	$H_1=0$	$H_1=1$
$P(H_1)$	0.5	0.5

$i \backslash t$	1	2	3	4
0	0.45	0.0135	0.09072	
1	0.1	0.252		

- ◆ récursion:  $\alpha^*(0,3) = 0.9 \max\{0.3 \times 0.0135, \underline{0.4 \times 0.252}\} = 0.09072$

# Exemple - Explication la plus plausible avec un HMM

- Décoder un message binaire avec canal bruité (T=4)
  - ◆ message observé:  $S_1=0, S_2=1, S_3=0, S_4=0$

Modèle d'observation

	$H_t=0$	$H_t=1$
$P(S_t=0   H_t)$	0.9	0.2
$P(S_t=1   H_t)$	0.1	0.8

Modèle de transition

	$H_{t-1}=0$	$H_{t-1}=1$
$P(H_t=0   H_{t-1})$	0.3	0.4
$P(H_t=1   H_{t-1})$	0.7	0.6

Distribution initiale

	$H_1=0$	$H_1=1$
$P(H_1)$	0.5	0.5

$i \backslash t$		1	2	3	4
0		0.45	0.0135	0.09072	0.02449
1		0.1	0.252	0.03024	0.01270

- ◆ on continue d'appliquer la récursion jusqu'à la fin (t=4)...



# Exemple - Explication la plus plausible avec un HMM

- Décoder un message binaire avec canal bruité (T=4)
  - ◆ message observé:  $S_1=0, S_2=1, S_3=0, S_4=0$

Modèle d'observation

	$H_t=0$	$H_t=1$
$P(S_t=0   H_t)$	0.9	0.2
$P(S_t=1   H_t)$	0.1	0.8

Modèle de transition

	$H_{t-1}=0$	$H_{t-1}=1$
$P(H_t=0   H_{t-1})$	0.3	0.4
$P(H_t=1   H_{t-1})$	0.7	0.6

Distribution initiale

	$H_1=0$	$H_1=1$
$P(H_1)$	0.5	0.5

$i \backslash t$		1	2	3	4
0		0.45	0.0135	0.09072	0.02449
1		0.1	0.252	0.03024	0.01270

- ◆ on trouve le maximum à la dernière colonne...

# Exemple - Explication la plus plausible avec un HMM

- Décoder un message binaire avec canal bruité (T=4)
  - ◆ message observé:  $S_1=0, S_2=1, S_3=0, S_4=0$

Modèle d'observation

	$H_t=0$	$H_t=1$
$P(S_t=0   H_t)$	0.9	0.2
$P(S_t=1   H_t)$	0.1	0.8

Modèle de transition

	$H_{t-1}=0$	$H_{t-1}=1$
$P(H_t=0   H_{t-1})$	0.3	0.4
$P(H_t=1   H_{t-1})$	0.7	0.6

Distribution initiale

	$H_1=0$	$H_1=1$
$P(H_1)$	0.5	0.5

		t			
		1	2	3	4
$\alpha^*(i,t)$	i				
	0	0.45	0.0135	0.09072	0.02449
	1	0.1	0.252	0.03024	0.01270

- ◆ ... puis on **retrouve le chemin** qui a mené là

# Exemple - Explication la plus plausible avec un HMM

- Décoder un message binaire avec canal bruité (T=4)
  - ◆ message observé:  $S_1=0, S_2=1, S_3=0, S_4=0$

Modèle d'observation

	$H_t=0$	$H_t=1$
$P(S_t=0   H_t)$	0.9	0.2
$P(S_t=1   H_t)$	0.1	0.8

Modèle de transition

	$H_{t-1}=0$	$H_{t-1}=1$
$P(H_t=0   H_{t-1})$	0.3	0.4
$P(H_t=1   H_{t-1})$	0.7	0.6

Distribution initiale

	$H_1=0$	$H_1=1$
$P(H_1)$	0.5	0.5

$i \backslash t$	1	2	3	4
0	0.45	0.0135	0.09072	0.02449
1	0.1	0.252	0.03024	0.01270

$H_1=0$        $H_2=1$        $H_3=0$        $H_4=0$

- ◆ ce chemin nous donne la séquence des  $H_t$  la plus probable

# Simuler un HMM

- Il est facile de générer des observations d'un HMM
  - ◆ échantillonner une valeur initiale  $H_1 = h_1$  de  $\mathbf{P}(H_1)$
  - ◆ pour  $t = 2$  jusqu'à  $T$ , répéter les deux échantillonnage suivants:
    - » utiliser les probabilités de transition de l'état caché courant pour obtenir un échantillon  $h_t$  sachant l'état caché précédent:  $\mathbf{P}(H_t | H_{t-1} = h_{t-1})$
    - » utiliser les probabilités de sortie de la variable d'observation étant donné l'état caché courant, pour obtenir le symbole d'observation (émission)  $s_t$ :  $\mathbf{P}(S_t | H_t=h_t)$
- On peut aussi générer la séquence des états cachés d'abord et ensuite générer les observations
  - ◆ les variables cachées dépendent uniquement des variables cachées précédentes
  - ◆ chaque observation (émission) ne dépendra pas des autres