

IFT 615 – Intelligence artificielle

Réseaux bayésiens dynamiques

Hugo Larochelle

Département d'informatique

Université de Sherbrooke

<http://www.dmi.usherb.ca/~larocheh/cours/ift615.html>

Sujets couverts


- Qu'est-ce qu'un réseau bayésien dynamique (RBD)?
- Types d'inférence dans un RBD
- Cas particulier des modèles de Markov cachés

Réseaux bayésiens dynamiques (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

Applications

- **Reconnaissance de la parole**
 - ◆ E_t sont les éléments du signal sonore
 - ◆ X_t sont les mots prononcés



Applications

- **Traduction automatique**

- ◆ 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.



Applications

- **Suivi d'objets (*tracking*)**

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




<http://www.youtube.com/watch?v=fRowYlxKt7s>

Applications

- **Localisation de robots**

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




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

Types d'inférence dans un RBD

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

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

- ◆ ex. : quelle est la probabilité qu'il pleuve aujourd'hui ?
 - ◆ ex. : quelle est la croyance du robot par rapport à sa position actuelle ?
- **Prédiction**: calculer la distribution a posteriori sur un état futur

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

- ◆ ex. : quelle est la probabilité qu'il pleuve dans k jours ?

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** S_t dans l'état au temps t
- Le domaine de S_t est souvent un symbole (ex.: un caractère, un mot, etc.)
- Une **distribution a priori** (initiale) de probabilités sur les symboles (états) est spécifiée $\mathbf{P}(S_1)$
- Une **matrice de transition** contenant les probabilités conditionnelles $\mathbf{P}(S_{t+1} | S_t)$

Illustration




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

Probabilité de générer une chaîne

produit des probabilités, une pour
chaque terme de la séquence

$$P(S_{1:T}) = P(S_1) \prod_{t=2}^T P(S_t | S_{t-1})$$

une séquence de
symboles, allant du
temps 1 au temps T

distribution initiale
de probabilités

modèle de
transition

Visualisation d'une chaîne de Markov

Représentation matricielle

Symbole actuel

a *b* *c*

	<i>a</i>	<i>b</i>	<i>c</i>
<i>a</i>	.7	.3	0
<i>b</i>	.2	.7	.5
<i>c</i>	.1	0	.5

Prochain
symbole

Représentation graphique




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

Exemple de chaîne: *ccbbaaaaabaabacbabaaa*

Modèle de Markov caché

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

Illustration




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

Probabilité de générer une séquence cachée et une séquence visible

distribution initiale
de probabilités

modèle de
transition

$$P(S_{1:T}, H_{1:T}) = P(H_1) P(S_1 | H_1) \prod_{t=2}^T P(H_t | H_{t-1}) P(S_t | H_t)$$

séquence de nœuds
cachés et de symboles de
sortie

probabilité d'observer le
symbole S_t à partir de H_t

Simuler d'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

Illustration




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 visible

- La même séquence de sortie peut être produite par plusieurs séquences cachées différentes
- En fait, il y a un nombre exponentiel de séquences cachées possibles
- Un calcul naïf est donc très inefficace

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

Programmation dynamique pour HMM

- Une façon plus efficace de calculer la probabilité d'une séquence observée $s_{1:T}$

- Idée: utiliser la **programmation dynamique**

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

- ◆ on note la récursion

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

- ◆ on a les valeurs initiales

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

- Une fois le tableau α calculé, on obtient facilement:

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

Programmation dynamique pour HMM

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

Programmation dynamique pour HMM

- Exemple: 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					

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

Programmation dynamique pour HMM

- Exemple: 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			

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

Programmation dynamique pour HMM

- Exemple: 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



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

Programmation dynamique pour HMM

- Exemple: 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		

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

Programmation dynamique pour HMM

- Exemple: 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			

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

Programmation dynamique pour HMM

- Exemple: 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			

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

Programmation dynamique pour HMM

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

Programmation dynamique pour HMM

- Exemple: 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	0.3		

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

Programmation dynamique pour HMM

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

Programmation dynamique pour HMM

- Exemple: 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 ($t=4$)...

Filtrage dans un HMM

- Exemple: 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

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

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

Programmation dynamique pour HMM

- Le calcul des $\alpha(i,t)$ donne un balayage de gauche à droite
- On peut faire la même chose, mais de droite à gauche

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

- ◆ on note la récursion

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

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

- Une fois le tableau β calculé, on obtient facilement:

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

Programmation dynamique pour HMM

- Exemple: 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: $\beta(i,4) = 1$

Programmation dynamique pour HMM

- Exemple: 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: $\beta(i,4) = 1$

Programmation dynamique pour HMM

- Exemple: 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



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

Programmation dynamique pour HMM

- Exemple: 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 $\beta(0,3) = P(S_4=0 | H_4=0) P(H_4=0 | H_3=0) \beta(0,4) + P(S_4=0 | H_4=1) P(H_4=1 | H_3=0) \beta(1,4)$

Programmation dynamique pour HMM

- Exemple: 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

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

Programmation dynamique pour HMM

- Exemple: 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

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

Programmation dynamique pour HMM

- Exemple: 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				0.48	1

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

Programmation dynamique pour HMM

- Exemple: 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

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

Programmation dynamique pour HMM

- Exemple: 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

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

Programmation dynamique pour HMM

- Exemple: 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

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

Programmation dynamique pour HMM

- Exemple: 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		0.120249	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

$$\begin{aligned} \blacklozenge P(H_k = i \mid S_{1:T}=s_{1:T}) &= P(H_k = i, S_{1:k}=s_{1:k}, S_{k+1:T}=s_{k+1:T}) / \Upsilon \quad (\Upsilon \text{ est la normalisation}) \\ &= P(H_k = i, S_{1:k}=s_{1:k}) P(S_{k+1:T}=s_{k+1:T} \mid H_k = i) / \Upsilon \\ &= \alpha(i,k) \beta(i,k) / \Upsilon \end{aligned}$$

- On peut également faire du lissage sur deux variables cachées adjacentes

$$\begin{aligned} \blacklozenge P(H_k = i, H_{k+1} = j \mid S_{1:T}=s_{1:T}) &= P(H_k = i, H_{k+1} = j, S_{1:k}=s_{1:k}, S_{k+1:T}=s_{k+1:T}) / \Upsilon' \\ &= P(H_k = i, S_{1:k}=s_{1:k}) P(H_{k+1} = j \mid H_k = i) P(S_{k+1}=s_{k+1} \mid H_{k+1} = j) \\ &\quad P(S_{k+2:T}=s_{k+2:T} \mid H_{k+1} = j) / \Upsilon' \\ &= \alpha(i,k) \beta(j,k+1) P(H_{k+1} = j \mid H_k = i) P(S_{k+1}=s_{k+1} \mid H_{k+1} = j) / \Upsilon' \end{aligned}$$

- À noter que Υ correspond à une somme sur i seulement, tandis que Υ' est une somme sur i et j

Lissage avec un HMM

- Exemple: 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

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

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

Prédiction dans 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

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

- ◆ on note la récursion

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

- ◆ 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}

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

Prédiction dans un HMM

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

Prédiction dans un HMM

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

Prédiction dans un HMM

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

Prédiction dans un HMM

- Exemple: 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		

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

Prédiction dans un HMM

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

Prédiction dans un HMM

- Exemple: 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			

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

Prédiction dans un HMM

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

Prédiction dans un HMM

- Exemple: 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	
1	0.31534		

Arrows point from 0.33154 to 0.31534 and from 0.31534 to the right.

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

Prédiction dans un HMM

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

Prédiction dans un HMM

- Exemple: 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 ($k=2$)...

Prédiction dans un HMM

- Exemple: 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

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

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

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

- ◆ on note la récursion

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

- ◆ 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 argmax_j

Explication la plus plausible avec un HMM

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

Explication la plus plausible avec un HMM

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

Explication la plus plausible avec un HMM

- Exemple: 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			

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

Explication la plus plausible avec un HMM

- Exemple: 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



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

Explication la plus plausible avec un HMM

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

Explication la plus plausible avec un HMM

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

Explication la plus plausible avec un HMM

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

Explication la plus plausible avec un HMM

- Exemple: 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		

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

Explication la plus plausible avec un HMM

- Exemple: 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		

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

Explication la plus plausible avec un HMM

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

Explication la plus plausible avec un HMM

- Exemple: 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	0.09072	0.02449	
1	0.1	0.252	0.03024	0.01270	

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

Explication la plus plausible avec un HMM

- Exemple: 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...

Explication la plus plausible avec un HMM

- Exemple: 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	0.09072	0.02449
1		0.1	0.252	0.03024	0.01270

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

Explication la plus plausible avec un HMM

- Exemple: 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

Filtrage en ligne avec RBD

- Étant donné mon état de croyance actuel $P(X_t | e_{1:t})$
 - ◆ comment le mettre à jour après une nouvelle observation e_{t+1} en temps réel
- En appliquant la règle de Bayes et l'hypothèse markovienne, nous arrivons à:

$$P(X_{t+1} | e_{1:t+1}) = P(X_{t+1} | e_{1:t}, e_{t+1}) \quad \text{(détails page 572 du manuel de référence)}$$


α : constante de normalisation

$$= \underbrace{P(e_{t+1} | X_{t+1})}_{\text{probabilité de la nouvelle observation (disponible dans la table des probabilités)}} \sum_{x_t} \underbrace{P(X_{t+1} | x_t) P(x_t | e_{1:t})}_{\text{prédiction du prochain état en se basant sur notre état de croyance au temps } t} / \alpha$$

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: $P(R_1 | u_1) = P(u_1 | R_1) P(R_1) \propto$

Exemple de l'agent de sécurité



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

$$\begin{aligned} P(R_2 \mid u_1, u_2) &= P(u_2 \mid R_2) P(R_2 \mid u_1) / \alpha \\ &= (P(u_2 \mid R_2) \sum_{r_1} P(R_2 \mid r_1) P(r_1 \mid u_1)) / \alpha \end{aligned}$$

Améliorations sur le HMM

- Comment rendre un HMM (ou un RBD en général) plus précis?
 - ◆ **augmenter l'ordre du modèle markovien**
 - » ex.: $Rain_t$ aurait comme parents, non seulement $Rain_{t-1}$ mais aussi $Rain_{t-2}$ pour un processus markovien du second ordre
 - » ceci donnerait des prédictions plus précises
 - ◆ **permettre des interactions directes entre la variables d'observation**
 - » on pourrait avoir plutôt $\mathbf{P}(E_t \mid X_{0:t}, E_{0:t-1}) = \mathbf{P}(E_t \mid X_{t-1}, E_{t-1})$
 - » ça peut rendre l'inférence encore plus complexe

Au delà du HMM


- **Filtre de Kalman:** cas où les variables d'observation et cachées ne sont pas discrètes mais sont plutôt réelles
 - ◆ voir livre de référence, section 15.4
- **État caché avec structure complexe:** cas où il n'est pas possible de faire une sommation exacte sur toutes les configurations de l'état caché
 - ◆ on doit alors approximer l'inférence
 - ◆ **filtre particulaire** (*particle filter*): inférence approximative basée sur l'échantillonnage, où on maintient une population stochastique de configurations (particules) de l'état caché
 - ◆ à chaque temps t , on met à jour notre population de particules en tenant compte des nouvelles observations
 - ◆ voir livre de référence, section 15.5.3

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**)

Raisonnement probabiliste : pour quel type d'agent?


Simple reflex




Model-based reflex



Goal-based




Utility-based



Objectifs du cours

Algorithmes et concepts



- ✓ les RBD et le HMM sont les premiers modèles probabilistes que l'on a vu incluant **la notion de temps**
- ✓ ils vont être utiles lorsqu'on va parler de traitement de la langue et robotique

Vous devriez être capable de...

- Distinguer les différents types d'inférence
 - ◆ distribution de filtrage
 - ◆ distribution de prédiction
 - ◆ distribution de lissage
 - ◆ explication la plus plausible
- Décrire ce qu'est un modèle de Markov caché
 - ◆ connaître les définitions des tableaux α , β , π et α^* (que calcule ces tableaux?)
 - ◆ savoir utiliser des tableaux α , β , π et α^* pré-calculés
- Implémenter de l'inférence dans un modèle de Markov caché