

Plan

Chaînes de Markov

Chaînes de Markov cachées

Grammaires hors-contexte probabilistes

Deux modèles génératifs

- Permettent de générer des séquences d'observables $o = o_1 \dots o_k$
- Chaînes de Markov Cachées (HMM)
 - modèle sous jacent : automate fini
 - pas de mémoire : la probabilité de génération d'un symbole ne dépend que de l'état dans lequel se trouve l'automate
- Grammaires hors-contexte probabilistes (PCFG)
 - modèle sous jacent : automate à pile
 - la pile permet de modéliser des dépendances de longueur arbitraire

Deux modèles génératifs

Trois questions :

- 1 Comment calculer $P(o)$
- 2 Comment calculer la structure sous-jacente la plus probable pour o
 - HMM : séquence d'états de l'automate
 - PCFG : arbre syntaxique
- 3 Comment optimiser les paramètres du modèle étant donné une (longue) séquence d'observables $o_1 \dots o_N$

Processus stochastique

- Un **processus stochastique** (ou processus aléatoire) est une séquence $X_1, X_2 \dots X_N$ de variables aléatoires fondées sur le même ensemble fondamental.
- Les valeurs possibles des variables aléatoires sont appelées les **états** possibles du processus.
- La variable X_t représente l'état du processus au temps t (on dit aussi l'observation au temps t).
- Les différentes variables aléatoires ne sont en général pas indépendantes les unes des autres.
- Ce qui fait réellement l'intérêt des processus stochastiques est la dépendance entre les variables aléatoires.

Processus stochastique

- Pour spécifier entièrement un processus stochastique, il suffit de spécifier :
 - 1 la loi de probabilité de la première variable aléatoire X_1 , qui spécifie donc l'état du processus lors de la première observation.
 - 2 pour toute valeur de $t > 1$ la probabilité conditionnelle :

$$P(X_t = j | X_1 = i_1, \dots, X_{t-1} = i_{t-1})$$

Propriété de Markov

Une **chaîne de Markov** est un type particulier de processus stochastique qui vérifie deux conditions :

- L'état au temps t du processus ne dépend que de son état au temps $t - 1$:

$$P(X_t = j | X_1 = i_1, \dots, X_{t-1} = i_{t-1}) = P(X_t = j | X_{t-1} = i_{t-1})$$

- La probabilité de passage d'un état i à un état j est **constante**, elle ne varie pas avec le temps :

$$\forall t, 1 < t \leq N, P(X_t = j | X_{t-1} = i) = C$$

Processus de Markov

Un processus de Markov peut être décrit par

- une **matrice de transition** T telle que :

$$T(i, j) = P(X_t = j | X_{t-1} = i), 1 < t \leq N$$

$$\text{avec } T(i, j) \geq 0, \forall i, j$$

$$\text{et } \sum_{j=1}^N T(i, j) = 1 \forall i$$

- L'état du processus à l'instant 1 donc la loi de probabilité, notée π , de la variable X_1 :

$$\pi(i) = P(X_1 = i)$$

Processus de Markov

On peut éviter le recours à la loi π en imposant que le processus débute toujours dans le même état 0, par exemple et en utilisant les transitions depuis cet état pour représenter les probabilités π :

$$T(0, i) = \pi(i), \text{ pour tout état } i \text{ du processus}$$

Processus de Markov

Un processus de Markov peut aussi être représenté par un automate fini :

- Chaque état du processus est représenté par un état de l'automate
- Une transition de l'état i à l'état j est étiqueté par la probabilité $T(i, j)$.


Exemple

- On admet que le fait que le temps qu'il fera demain ne dépend que du temps qu'il fait aujourd'hui.
- Plus précisément, s'il pleut aujourd'hui, il pleuvra demain aussi avec une probabilité de α et s'il ne pleut pas aujourd'hui la probabilité qu'il pleuve demain est β .
- On convient de dire que le système est dans l'état 1 s'il pleut et 2 s'il ne pleut pas. La situation peut être représentée par une chaîne de Markov à deux états dont la matrice de transition est :

$$\begin{vmatrix} \alpha & 1 - \alpha \\ \beta & 1 - \beta \end{vmatrix}$$

Exemple (suite)

- De plus, la probabilité que le processus soit dans l'état 1 à l'instant 1 est égale à γ .
- Le même processus peut être représenté par l'automate :



Probabilité d'une suite d'observations

- Les propriétés de Markov permettent de calculer simplement la probabilité qu'une suite d'états particulière de longueur T soit observée (la loi de probabilité conjointe de (X_1, X_2, \dots, X_T)) :

$$\begin{aligned} P(X_1, X_2, \dots, X_T) &= \text{(r\`egle de multiplication)} \\ P(X_1)P(X_2|X_1)P(X_3|X_1, X_2) \dots P(X_T|X_1, \dots, X_{T-1}) &= \\ P(X_1)P(X_2|X_1)P(X_3|X_2) \dots P(X_T|X_{T-1}) &\text{(hypoth\`ese de Markov)} \end{aligned}$$

Exemple

- Etant donné le processus de Markov de l'exemple précédent, la probabilité d'avoir trois jours consécutifs de pluie est égale à :

$$\begin{aligned}P(X_1 = 1, X_2 = 1, X_3 = 1) &= P(X_1 = 1)P(X_2 = 1|X_1 = 1)P(X_3 = 1|X_2 = 1) \\ &= \gamma \times \alpha \times \alpha \\ &= \gamma\alpha^2\end{aligned}$$

Modèles de Markov Cachés

- Dans les chaînes de Markov, les observations correspondent aux états du processus.
- Dans un modèle de Markov caché, on ne peut observer directement les états du processus, mais des symboles (appelés aussi *observables*) émis par les états selon une certaine loi de probabilité.
- Au vu d'une séquence d'observations on ne peut savoir par quelle séquence d'états (ou *chemin*) le processus est passé, d'où le nom de modèles de Markov cachés (HMM).
- On distingue le processus $X = X_1, X_2, \dots, X_T$ qui représente l'évolution des états du HMM et le processus $O = O_1, O_2, \dots, O_T$ qui représente la suite des symboles émis par le HMM.

Eléments d'un HMM

Un HMM est défini par un quintuplet $\langle S, A, \pi, T, E \rangle$ où :

- S est l'ensemble des états : $\{1, \dots, N\}$
- A est l'alphabet des symboles émis par les états : $\{a_1, \dots, a_M\}$
- π est la loi de probabilité de l'état initial $\pi(i) = P(X_1 = i)$. π étant une loi de probabilité, on a :

$$\sum_{i=1}^N \pi(i) = 1$$

Eléments d'un HMM - 2

Un HMM est défini par un quintuplet $\langle S, A, \pi, T, E \rangle$ où :

- T est la matrice des probabilités de transition d'un état vers un autre.
- La probabilité de transition d'un état i vers un état j ($P(X_t = j | X_{t-1} = i)$) est notée $T(i, j)$.
- La somme des probabilités des transitions émanant d'un état vaut 1 :

$$\sum_{j=1}^N T(i, j) = 1, \forall i \in S$$

Eléments d'un HMM - 3

Un HMM est défini par un quintuplet $\langle S, A, \pi, T, E \rangle$ où :

- E est la matrice des probabilités d'émission des symboles de A pour chaque état.
- La probabilité que l'état i émette le symbole j ($P(O_t = j | X_t = i)$) est notée $E(i, j)$.
- Les probabilités d'émission de symboles de A pour chaque état du HMM constituent une loi de probabilité :

$$\sum_{j=1}^M E(i, o_j) = 1, \forall i \in S$$


L'ensemble constitué des probabilités initiales, des probabilités de transition et d'émission d'un HMM λ est souvent appelé les *paramètres* λ .

Exemple

$\lambda_1 = \langle \{1,2,3\}, \{a,b,c\}, \pi, T, E \rangle$ avec :

$E(1,a) = 0,6$	$E(2,a) = 0$	$E(3,a) = 0,3$	$T(1,1) = 0,3$	$T(2,1) = 0,6$	$T(3,1) = 0,2$	
$E(1,b) = 0,2$	$E(2,b) = 0,5$	$E(3,b) = 0$	et	$T(1,2) = 0,2$	$T(2,2) = 0,1$	$T(3,2) = 0,4$
$E(1,c) = 0,2$	$E(2,c) = 0,5$	$E(3,c) = 0,7$		$T(1,3) = 0,5$	$T(2,3) = 0,3$	$T(3,3) = 0,4$
			et			
			$\pi(1) = 1$	$\pi(2) = 0$	$\pi(3) = 0$	

représentation graphique



Trois questions

- Calcul de la probabilité d'une séquence d'observations o :

$$P(o) = \sum_{x \in \mathcal{C}_T} P(o, x)$$

où \mathcal{C}_T est l'ensemble des séquences de T états.

- Calcul du chemin le plus probable :

$$\hat{x} = \arg \max_{x \in \mathcal{C}_T} P(x|o)$$

- Estimation des paramètres du HMM :

$$\hat{\lambda} = \arg \max_{\lambda} P(o|\lambda)$$

Calcul de $P(o)$

- Etant donné un HMM $\lambda = \langle S, A, \pi, T, E \rangle$, la suite d'observation $o = o_1 o_2, \dots, o_T$ peut généralement être générée en suivant différents chemins dans le HMM
- La probabilité que λ émette la séquence o est égale à la somme des probabilités que la séquence o soit émise en empruntant les différents chemins pouvant émettre o .
- Ce raisonnement correspond en fait à l'application de la formule des probabilités totales à la probabilité $P(o)$

$$P(o) = \sum_{x \in \mathcal{C}_T} P(o|x)P(x)$$

où \mathcal{C}_T est l'ensemble des séquences de T états de λ et $x = x_1, \dots, x_T$ ($x_i \in S$, $1 \leq i \leq T$) une de ces séquences

Calcul de $P(o)$

- la probabilité conditionnelle que o soit générée lorsque λ passe successivement par la séquence d'états $x = x_1, \dots, x_T$ est le produit des probabilités que l'état atteint à l'instant t (x_t) émette le symbole observé à cet instant (o_t) :

$$P(o|x) = \prod_{t=1}^T E(x_t, o_t)$$

Calcul de $P(o)$

- et la probabilité que le HMM suive une séquence particulière d'états x est le produit des probabilités que λ passe de l'état x_t à l'état x_{t+1} entre les instants t et $t + 1$, comme dans un modèle de Markov *visible* :

$$P(x) = \pi(x_1) \prod_{t=1}^{T-1} T(x_t, x_{t+1})$$


- En remplaçant $P(o|x)$ et $P(x)$ dans l'équation initiale, on obtient :

$$P(o) = \sum_{x \in \mathcal{C}_T} \pi(x_1) \times \prod_{t=1}^{T-1} E(o_t, x_t) T(x_t, x_{t+1}) \times E(o_T, x_T)$$

Trellis - 1

- Le calcul précédent est particulièrement inefficace, il nécessite dans le cas général (où tous les états sont reliés entre eux par une transition et chaque état peut émettre chacun des N symboles) $2 \times T \times N^T$ multiplications (N^T chemins et $2T$ multiplications à effectuer par chemin.).
- On a recours à une méthode de programmation dynamique pour effectuer ce calcul.
- Cette méthode repose sur la représentation, sous forme d'un *treillis*, de l'évolution du HMM ayant donné lieu à une suite d'observables $o_1 \dots o_k$.

Trellis - 2



Trellis - 3

- On associe à chaque sommet (i, t) du treillis la variable $\alpha(i, t)$ qui correspond à la probabilité de se trouver dans l'état i du HMM λ à un instant t , ayant observé la suite $o_1 \dots o_{t-1}$:

$$\alpha(i, t) = P(o_1 \dots o_{t-1}, X_t = i)$$

Treillis - 4

- Le treillis permet de *résumer* au niveau d'un sommet (i, t) des informations portant sur l'ensemble des chemins menant à l'état i à l'instant t tout en ayant observé la séquence $o_1 \dots o_{t-1}$.
- Dans notre cas, cette information est la somme des probabilités de ces chemins.
- Cette particularité permet de calculer la probabilité de se trouver dans un état quelconque à un instant t en fonction de la probabilité de se trouver dans les différents états à l'instant $t - 1$
- c'est l'étape récursive de l'algorithme suivant.

Algorithme de calcul de $P(o)$

1 Initialisation :

$$\alpha(i, 1) = \pi(i), 1 \leq i \leq N$$


2 Etape récursive :

$$\alpha(j, t + 1) = \sum_{i=1}^N \alpha(i, t) E(i, o_t) T(i, j), 1 \leq t < T - 1, 1 \leq j \leq N$$

3 Calcul de la probabilité totale :

$$P(o) = \sum_{i=1}^N \alpha(i, T) E(i, o_T)$$

Calcul de $\alpha(j, t + 1)$



Cette façon de calculer $P(o)$ est bien plus économique puisqu'elle n'exige (dans le cas général) que $2N^2T$ multiplications : $N \times T$ sommets et $2N$ multiplications par sommet.

Calcul backward

- La procédure de calcul de $P(o)$ présentée ci-dessus est appelée quelquefois procédure *forward* (en avant) car le calcul de la probabilité à un instant t est effectué à partir de la probabilité à un instant $t - 1$, en parcourant le treillis de la gauche vers la droite.
- Il est aussi possible d'effectuer le calcul dans l'ordre inverse, où la probabilité à un instant t est calculée à partir de la probabilité à l'instant $t + 1$.
- On définit la variable $\beta(i, t)$ de la façon suivante :

$$\beta(i, t) = P(o_t \dots o_T | X_t = i)$$

Attention : $\alpha(i, t) = P(o_1 \dots o_{t-1}, X_t = i)$

Algorithme de calcul de $P(o)$ grâce aux probabilités *backward*

1 Initialisation :

$$\beta(i, T) = E(i, o_T), 1 \leq i \leq N$$


2 Etape réursive :

$$\beta(i, t) = \sum_{j=1}^N \beta(j, t+1) T(i, j) E(i, o_t), 1 \leq t \leq T-1, 1 \leq i \leq N$$

3 Calcul de la probabilité totale :

$$P(o) = \sum_{i=1}^N \pi(i) \beta(i, 1)$$

Calcul de $\beta(i, t)$



$$\beta(i, t) = \sum_{j=1}^N \beta(j, t+1) T(i, j) E(i, o_t), \quad 1 \leq t \leq T-1, \quad 1 \leq i \leq N$$

Combinaison des probabilités *backward* et *forward*

- Les probabilités forward et backward peuvent être combinées pour calculer $P(o)$ de la façon suivante :

$$P(o) = \sum_{i=1}^N \alpha(i, t) \beta(i, t) \quad \forall t \quad 1 \leq t \leq T$$

- Ce résultat est établi en utilisant d'une part la formule des probabilités totales :


$$P(o) = \sum_{i=1}^N P(o, X_t = i)$$

Combinaison des probabilités *backward* et *forward*


- puis en remarquant que chacun des termes de la somme peut être exprimée en fonction des probabilités forward et backward de la façon suivante :

$$\begin{aligned}P(o, X_t = i) &= P(o_1, \dots, o_T, X_t = i) \\&= P(o_1, \dots, o_{t-1}, X_t = i, o_t, \dots, o_T) \\&= P(o_1, \dots, o_{t-1}, X_t = i) \times P(o_t, \dots, o_T | o_1, \dots, o_{t-1}, X_t = i) \\&= P(o_1, \dots, o_{t-1}, X_t = i) \times P(o_t, \dots, o_T | X_t = i) \\&= \alpha(i, t)\beta(i, t)\end{aligned}$$

Combinaison des probabilités *backward* et *forward*



Probabilité de o



$$P(o) = \sum_{i=1}^N \alpha(i,t)\beta(i,t) \forall t \ 1 \leq t \leq T$$

Recherche du chemin le plus probable

- Il est souvent intéressant, étant donné un HMM λ et une séquence d'observations $o = o_1 \dots o_T$ de déterminer la séquence d'états $\hat{x} = \hat{x}_1, \hat{x}_2, \dots, \hat{x}_T$ la plus probable ayant pu générer o .
- Première solution : déterminer toutes les séquences d'états ayant pu générer o , puis calculer leur probabilités afin de déterminer la plus probable.
- Méthode particulièrement coûteuse car, dans le cas général, il existe N^T chemins possibles.
- Solution : utiliser le treillis (algorithme de Viterbi)

Algorithme de Viterbi

- Idée générale : on détermine, pour chaque sommet du treillis, le meilleur chemin (le chemin de probabilité maximale) menant à ce sommet, tout en ayant généré la suite $o_1 \dots o_t$.
- On définit pour chaque sommet (j, t) du treillis la variable $\delta(j, t)$:

$$\delta(j, t) = \max_{x \in \mathcal{C}_{t-1}} P(x, o_1 \dots o_t, X_t = j)$$

où \mathcal{C}_{t-1} est l'ensemble des séquences de $t - 1$ états de λ et x une de ces séquences.

Algorithme de Viterbi

- On définit de plus, pour chaque sommet (j, t) la variable $\psi(j, t)$ dans laquelle est stocké l'état du HMM au temps $t - 1$ qui a permis de réaliser le meilleur score, qui n'est donc autre que l'état précédent dans le meilleur chemin menant à (j, t) .

Algorithme de Viterbi

- 1 Initialisation du treillis :

$$\delta(j, 1) = \pi(j)E(j, o_1), 1 \leq j \leq N$$

- 2 Etape récursive :

$$\delta(j, t + 1) = \max_{1 \leq i \leq N} \delta(i, t)T(i, j)E(j, o_{t+1}), 1 \leq t < T, 1 \leq j \leq N$$

stockage du meilleur état précédent :

$$\psi(j, t + 1) = \arg \max_{1 \leq i \leq N} \delta(i, t)T(i, j)E(j, o_{t+1}), 1 \leq t < T, 1 \leq j \leq N$$

Algorithme de Viterbi

1 Détermination du meilleur chemin :

$$\begin{aligned}\hat{x}_T &= \arg \max_{1 \leq i \leq N} \delta(i, T) \\ \hat{x}_t &= \psi(\hat{x}_{t+1}, t + 1) \\ P(\hat{x}) &= \max_{1 \leq i \leq M} \delta(i, T)\end{aligned}$$

Estimation des paramètres d'un HMM

- Les paramètres d'un HMM ne sont généralement pas donnés par avance, ils doivent être estimés à partir de données.
- On suppose que l'on dispose d'une longue suite d'observations $o = o_1 \dots o_T$, appelée *données d'apprentissage* qui est sensée être représentative du type de données que le HMM peut produire.
- On suppose de plus que la structure du HMM (le nombre d'états et les transitions possibles entre états) est fixée.

Estimation des paramètres d'un HMM

- L'objectif est de déterminer les paramètres qui rendent le mieux compte de o , ou, en d'autres termes, de déterminer les paramètres qui, parmi l'ensemble des paramètres possibles, attribuent à o la meilleure probabilité.
- Si l'on note $P_\lambda(o)$ la probabilité qu'attribue le HMM λ à la suite o , le but de l'estimation est de déterminer le HMM $\hat{\lambda}$ qui maximise $P_\lambda(o)$:

$$\hat{\lambda} = \arg \max_{\lambda} P_\lambda(o)$$

Estimation des paramètres d'un HMM

- Nous allons supposer que la séquence o a été générée par un HMM. Ceci n'est qu'une vision de l'esprit et l'on ne connaît pas le processus qui est à l'origine de o .
- Deux cas peuvent alors se présenter :
 - données complètes** : on dispose des données d'apprentissage o et de la séquence d'états $x = x_1 \dots x_T$ ayant permis la génération de o .
 - données incomplètes** : on ne dispose que de la suite d'observation o .

Données complètes

états	$x =$	x_1	x_2	x_3	\dots	x_T
observations	$o =$	o_1	o_2	o_3	\dots	o_T

On définit les variables :

- $C_e(i) = \sum_{t=1}^T \delta_{x_t,i}$
- $C_{o,e}(a,i) = \sum_{t=1}^T \delta_{o_t,a} \times \delta_{x_t,i}$
- $C_{e,e}(i,j) = \sum_{t=2}^T \delta_{x_{t-1},i} \times \delta_{x_t,j}$

Une façon naturelle d'estimer les probabilités d'émission et de transition est :

$$E_{\hat{\lambda}}(i,a) = \frac{C_{o,e}(a,i)}{C_e(i)} \quad T_{\hat{\lambda}}(i,j) = \frac{C_{e,e}(i,j)}{C_e(i)}$$

Cette méthode d'estimation des probabilités est appelée estimation par maximum de vraisemblance.

Données incomplètes

états	$x =$?	?	?	...	?
observations	$o =$	o_1	o_2	o_2	...	o_T

- On ne dispose que des données d'apprentissage o et de la structure du HMM $\hat{\lambda}$.
- On ne connaît pas de méthode permettant de calculer directement $\hat{\lambda}$.
- Il existe une procédure, appelée algorithme de Baum-Welsh ou algorithme forward-backward qui permet de s'en approcher.
- Procédure itérative : on calcule une suite de HMM $\lambda_0, \lambda_1, \dots, \lambda_n$ où λ_{i+1} est construit à partir de λ_i et tel que :

$$P_{\lambda_{i+1}}(o) \geq P_{\lambda_i}(o)$$

Algorithme de Baum-Welsh

- On donne aux paramètres de λ_0 des valeurs arbitraires, qui peuvent être aléatoires, comme elles peuvent être guidées par la connaissance a priori que nous avons du problème.
- On considère que o a été généré par λ_0 . Cette hypothèse permet de calculer la probabilité, notée $\gamma(i, t)$, que λ_0 soit dans l'état i à l'instant t :

$$\begin{aligned}\gamma(i, t) &= P(X_t = i | o) \\ &= \frac{P(X_t = i, o)}{p(o)} \\ &= \frac{\alpha(i, t)\beta(i, t)}{\sum_{j=1}^N \alpha(j, t)\beta(j, t)}\end{aligned}$$

Algorithme de Baum-Welsh - 2

- On effectue la somme $\sum_{t=1}^T \gamma(i, t)$
- Somme des probabilités que λ_0 soit passé par l'état i aux différents instants t de la génération de o .
- Il ne s'agit pas d'une probabilité :
 - elle peut être supérieure à 1
 - on ne voit à quel événement elle correspond.
- On l'interprète comme une approximation du nombre de fois que λ_0 est passé par l'état i lors de la génération de o .
- On se retrouve dans une situation proche de l'estimation avec des données complètes.

Réestimation des probabilités d'émission

On peut calculer (on dit aussi réestimer) de nouvelles probabilités d'émission, notées E_1 , par maximum de vraisemblance :

$$\begin{aligned} E_1(i, a_j) &= \frac{\text{nombre de fois que } \lambda_0 \text{ s'est trouvé dans l'état } i \text{ et que } a \text{ a été émis}}{\text{nombre de fois que } \lambda_0 \text{ s'est trouvé dans l'état } i} \\ &= \frac{\sum_{t: o_t = a} \gamma(i, t)}{\sum_{t=1}^T \gamma(i, t)} \end{aligned}$$

Réestimation des probabilités initiales

les probabilités initiales peuvent, elles, être réestimées de la façon suivante :


$$\begin{aligned}\pi_1(i) &= \text{probabilité d'être en } i \text{ à l'instant } t = 1 \\ &= \gamma(i, 1)\end{aligned}$$

Réestimation des probabilités de transition

- On note $p_t(i, j)$ la probabilité que λ_0 soit passé de l'état i à l'état j entre les instants t et $t + 1$:

$$\begin{aligned} p_t(i, j) &= P(X_t = i, X_{t+1} = j | o) \\ &= \frac{P(X_t = i, X_{t+1} = j, o)}{P(o)} \\ &= \frac{\alpha(i, t) \times E(i, o_t) \times T(i, j) \times \beta(j, t + 1)}{\sum_{k=1}^N \alpha(k, t) \beta(k, t)} \end{aligned}$$

Réestimation des probabilités de transition - 2



Réestimation des probabilités de transition - 2

- On effectue la somme $\sum_{t=1}^T p_t(i, j)$
- Estimation du nombre de fois qu'une transition de i vers j a été empruntée lors de la génération de o
- on recalcule à partir de cette quantité des nouvelles probabilités de transition T_1 par maximum de vraisemblance :

$$\begin{aligned} T_1(i, j) &= \frac{\text{nombre de fois qu'une transition de } i \text{ vers } j \text{ a été empruntée}}{\text{nombre de fois qu'un transition émanant de } i \text{ a été empruntée}} \\ &= \frac{\sum_{t=1}^T p_t(i, j)}{\sum_{t=1}^T \gamma(i, t)} \end{aligned}$$

Réestimation des probabilités de transition - 2


- λ_1 possède la propriété remarquable d'attribuer à la séquence o une probabilité meilleure ou égale à celle que lui attribuait λ_0 :

$$P_{\lambda_1}(o) \geq P_{\lambda_0}(o)$$

- Cette propriété s'explique par le fait que lors du calcul des paramètres de λ_1 , nous avons augmenté la probabilité des transitions et des émissions qui étaient à l'origine de la génération de o , et ce faisant, diminué les autres probabilités.

Réestimation des probabilités de transition - 2

- En réitérant le processus de réestimation des probabilités, nous obtiendrons des paramètres attribuant une probabilité de plus en plus élevée à la séquence o , jusqu'à ce qu'une valeur limite soit atteinte, pour un HMM λ_n .
- λ_n n'est cependant pas le meilleur possible, il peut s'agir d'un maximum local, qui dépend de λ_0 :



Grammaires hors-contexte probabiliste

Une grammaire hors-contexte probabiliste est composée de :

- Un alphabet non terminal $\mathcal{N} = \{N^1 \dots N^n\}$
- Un alphabet terminal $\mathcal{T} = \{t^1 \dots t^m\}$
- Un axiome N^1
- Un ensemble de règles $N^i \rightarrow \alpha$ avec $\alpha \in (\mathcal{N} \cup \mathcal{T})^*$
- Une distribution de probabilité associée à tout N^i :

$$\sum_j P(N^i \rightarrow \alpha^j) = 1$$

- On fera l'hypothèse que la grammaire est sous forme normale de Chomsky.

Probabilités

- La probabilité d'une règle est la probabilité de choisir cette règle pour réécrire le symbole de la partie gauche.

$$P(N^i \rightarrow \alpha^j) = P(N^i \rightarrow \alpha^j | N^i)$$

- Probabilité d'un arbre T :

$$P(T) = \prod_{n \in T} P(r(n))$$

où $n \in \mathcal{N}$ et $r(n)$ désigne la règle ayant permis de réécrire n .

- Probabilité d'une phrase S :

$$P(S) = \sum_{T \in \mathcal{T}(S)} P(T)$$

où $\mathcal{T}(S)$ est l'ensemble des analyses de S .

Trois problèmes à résoudre

- Calcul de la probabilité d'une phrase S :

$$P(S) = \sum_{T \in \mathcal{T}(S)} P(T)$$

- Construction de l'arbre d'analyse de S le plus probable :

$$\hat{T} = \arg \max_{T \in \mathcal{T}(S)} P(T)$$

- Estimation des probabilités de G à partir de données D :

$$\hat{G} = \arg \max_G P(D|G)$$

Parallèle avec les chaînes de Markov cachées

- Calcul de la probabilité d'une séquence d'observables o :

$$P(o) = \sum_{x \in \mathcal{C}_T} P(o, x)$$

où \mathcal{C}_T est l'ensemble des séquences de T états et x une de ces séquences.

- Calcul du chemin le plus probable :

$$\hat{x} = \arg \max_{x \in \mathcal{C}_T} P(x|o)$$

- Estimation des probabilités du HMM :

$$\hat{\lambda} = \arg \max_{\lambda} P(o|\lambda)$$


Différences

- Dans le cas d'un HMM une séquence d'états peut correspondre à plusieurs séquences d'observables alors qu'un arbre de dérivation correspond à une seule séquence d'observables (de terminaux).
- Etant donné un HMM et une séquence d'observables o , il est facile de déterminer tous les chemins ayant pu générer o . Dans le cas d'une grammaire probabiliste, il faut déterminer l'ensemble $\mathcal{T}(S)$: faire l'analyse syntaxique de S .

Notations


$m_1 \dots m_n$	phrase à analyser
$m_{p,q}$	segment $m_1 \dots m_n$ de la phrase
m^i	symbole de l'alphabet terminal
N^j	symbole de l'alphabet non terminal
$N_{p,q}^j$	le symbole N^j permet de dériver le segment $m_{p,q}$

Probabilités extérieures, probabilités intérieures




$$\beta_j(p, q) \stackrel{\text{def}}{=} P(m_{p,q} | N_{p,q}^j) \quad \alpha_j(p, q) \stackrel{\text{def}}{=} P(m_{1,p-1}, N_{p,q}^j, m_{q+1,m})$$

Parallèle avec les HMM



Probabilité intérieure


$$\beta_j(p, q) \stackrel{\text{def}}{=} P(m_{p,q} | N_{p,q}^j)$$



Probabilité d'une phrase

$$\begin{aligned} P(m_{1,n}) &= P(N^1 \stackrel{*}{\Rightarrow} m_{1,n}) \\ &= P(m_{1,n} | N^1) \\ &= \beta_1(1, n) \end{aligned}$$

Calcul récursif des probabilités intérieures



- Calcul ascendant
- On calcule $\beta_j(p, q)$ à partir de $\beta_r(p, d)$ et $\beta_s(d + 1, q)$

Calcul récursif des probabilités intérieures

Relation de récurrence

$$\begin{aligned}\beta_j(p, q) &= P(m_{p,q} | N_{p,q}^j) \\ &= \sum_{r,s} \sum_{d=p}^{q-1} P(m_{p,d}, N_{p,d}^r, m_{d+1,q}, N_{d+1,q}^s | N_{p,q}^j) \\ &= \sum_{r,s} \sum_{d=p}^{q-1} P(N_{p,d}^r, N_{d+1,q}^s | N_{p,q}^j) P(m_{p,d} | N_{p,d}^r, N_{d+1,q}^s, N_{p,q}^j) \\ &\quad P(m_{d+1,q} | N_{p,d}^r, N_{d+1,q}^s, N_{p,q}^j) \\ &= \sum_{r,s} \sum_{d=p}^{q-1} P(N^j \rightarrow N^r, N^s) \beta_r(p, d) \beta_s(d+1, q)\end{aligned}$$

Calcul récursif des probabilités intérieures

Cas terminal

$$\begin{aligned}\beta_j(k, k) &= P(m_k | N_{k,k}^j) \\ &= P(N^j \rightarrow m_k)\end{aligned}$$

Relation avec l'algorithme CYK


- $N_{p,q}^j$ correspond à la présence du symbole N^j dans la case $t_{p,q}$
- On peut calculer les $\beta(p, q)$ au fur et à mesure que l'on remplit la matrice d'analyse.

Calcul de $P(S)$ façon CYK

```
pour  $q = 1$  à  $n$  faire { INITIALISATION }  
  pour  $p = q$  à  $1$  faire  
    si ( $p == q$ )  
       $\beta_j(p, p) = P(N^j \rightarrow m_p)$   
    sinon  
       $\beta_j(p, q) = 0$   
  pour  $q = 1$  à  $n$  faire  
    pour  $p = q - 1$  à  $1$  faire  
      pour  $d = p$  à  $q - 1$  faire  
         $\beta_j(p, q) = \beta_j(p, q) + P(N^j \rightarrow N^r, N^s) \beta_r(p, d) \beta_s(d + 1, q)$   
        avec  $N^r \in t_{p,d}$  et  $N^s \in t_{d+1,q}$   
 $P(S) = \beta_1(1, n)$ 
```

Probabilité extérieure


$$\alpha_j(p, q) \stackrel{\text{def}}{=} P(m_{1,p-1}, N_{p,q}^j, m_{q+1,m})$$



Calcul récursif des probabilités extérieures


- Calcul descendant
- Le calcul des probabilités extérieures fait appel au calcul des probabilités intérieures, qui doivent avoir été préalablement calculées.

Calcul récursif des probabilités extérieures



$$\alpha_j^G(p, q) = \sum_{f,g} \sum_{e=q+1}^n P(m_{1,p-1}, m_{q+1,n}, N_{p,e}^f, N_{p,q}^j, N_{q+1,e}^g)$$

Calcul récursif des probabilités extérieures



$$\alpha_j^D(p, q) = \sum_{f,g} \sum_{e=1}^{p-1} P(m_{1,p-1}, m_{q+1,n}, N_{e,q}^f, N_{e,p-1}^g, N_{p,q}^j)$$

Calcul récursif des probabilités extérieures


$$\begin{aligned}\alpha_j(p, q) &= \alpha_j^G(p, q) + \alpha_j^D(p, q) \\ &\dots \\ &= \left[\sum_{f, g \neq j} \sum_{e=q+1}^n \alpha_f(p, e) P(N^f \rightarrow N^j N^g) \beta_g(q+1, e) \right] \\ &\quad + \left[\sum_{f, g} \sum_{e=1}^{p-1} \alpha_f(e, q) P(N^f \rightarrow N^j N^g) \beta_g(e, p-1) \right]\end{aligned}$$

Calcul récursif des probabilités extérieures

Cas terminal :

$$\alpha_j(1, n) = \begin{cases} 1 & \text{si } j = 1 \\ 0 & \text{sinon} \end{cases}$$

Combinaison des probabilités extérieures et intérieures



$$\begin{aligned}\alpha_j(p, q)\beta_j(p, q) &= P(m_{1,p-1}, N_{p,q}^j, m_{q+1,n})P(m_{p,q}|N_{p,q}^j) \\ &= P(m_{1,p-1}, N_{p,q}^j, m_{q+1,n})P(m_{p,q}|m_{1,p-1}, N_{p,q}^j, m_{q+1,n}) \\ &= P(m_{1,n}, N_{p,q}^j)\end{aligned}$$

Probabilité d'un syntagme

- Etant donné une phrase $m_{1,n}$, et une grammaire G , on peut calculer la probabilité que le segment $m_{p,q}$ constitue un syntagme de type N^j :

$$P(m_{1,n}, N_{p,q}^j) = \alpha_j(p, q)\beta_j(p, q)$$

- et la probabilité que le segment $m_{p,q}$ constitue un syntagme de type quelconque :

$$P(m_{1,n}, N_{p,q}) = \sum_j \alpha_j(p, q)\beta_j(p, q)$$

- On peut aussi calculer la probabilité d'occurrence d'un syntagme de type N^j dans la phrase :

$$P(m_{1,n}, N^j) = \sum_{1 \leq p \leq q \leq n} \alpha_j(p, q)\beta_j(p, q)$$

Calcul de la probabilité de \hat{T}

$\delta_i(p, q)$ = la probabilité du sous-arbre $N_{p,q}^j$ le plus probable.

1 Initialisation

$$\delta_i(p, p) = P(N^i \rightarrow m_p)$$

2 Récurrence

$$\delta_i(p, q) = \max_{1 \leq j, k \leq n, p \leq d < q} P(N^i \rightarrow N^j N^k) \delta_j(p, d) \delta_k(d+1, q)$$

3 Fin

$$P(\hat{T}) = \delta_1(1, n)$$

Calcul de $P(\hat{T})$

```
pour  $q = 1$  à  $n$  faire { INITIALISATION }
  pour  $p = q$  à 1 faire
    si ( $p == q$ )
       $\delta_j(p, p) = P(N^j \rightarrow m_p)$ 
    sinon
       $\delta_j(p, q) = 0$ 
  pour  $q = 1$  à  $n$  faire
    pour  $p = q - 1$  à 1 faire
      pour  $d = p$  à  $q - 1$  faire
         $\delta_j(p, q) = \max(\delta_j(p, q), P(N^i \rightarrow N^j N^k) \delta_j(p, d) \delta_k(d + 1, q))$ 
        avec  $N^r \in t_{p,d}$  et  $N^s \in t_{d+1,q}$ 
 $P(\hat{T}) = \beta_1(1, n)$ 
```

Construction de \hat{T}

$\psi_i(p, q) = \langle j, k, r \rangle$ où j, k, r désignent l'application de la règle ayant réalisé le maximum $\delta_i(p, q)$

$$\psi_i(p, q) = \arg \max_{j, k, d} P(N^i \rightarrow N^j N^k) \delta_j(p, d) \delta_k(d + 1, q)$$

- racine(\hat{T}) = $N_{1,n}^1$
- si $\psi_i(p, q) = \langle j, k, r \rangle$ alors
 - fils gauche($N_{p,q}^i$) = $N_{p,r}^j$
 - fils droit($N_{p,q}^i$) = $N_{r+1,q}^k$

Estimation des probabilités de la grammaire


Deux cas :

- Données complètes : on dispose d'un ensemble de phrases et de leur analyse syntaxique (banque d'arbres).
- Données incomplètes : on ne dispose que d'un ensemble de phrases.

Exemples de banques d'arbres

corpus	Penn Treebank	corpus Paris 7
mots	1 000 000	400 000
phrases	45 000	15 000
cat. syntag.	26	13
parties de discours	36	14
règles	9 657	

Construction de la grammaire



S → *GN GV*

GN → *Det N*

GV → *V*

Det → *le*

N → *chat*

V → *dort*

Estimation des probabilités des règles

- On compte le nombre d'occurrences des symboles non terminaux A dans la banque d'arbres : $C(A)$
- On compte le nombre d'occurrences des règles $A \rightarrow \alpha$ dans la banque d'arbres : $C(A \rightarrow \alpha)$
- On estime $P(A \rightarrow \alpha)$ par maximum de vraisemblance :

$$P(A \rightarrow \alpha) = \frac{C(A \rightarrow \alpha)}{C(A)}$$

Estimation à partir de données incomplètes

- On fixe la partie algébrique de la grammaire (alphabets, règles)
- On recherche la distribution de probabilités de la grammaire qui maximise la probabilité des données d'apprentissage (des phrases dont on dispose)
- On ne sait calculer ces distributions directement, on fait appel à un algorithme itératif du type Expectation Maximization appelé algorithme intérieur-extérieur (inside-outside).

Principe de l'algorithme intérieur extérieur

- On fixe des distributions de probabilités initiales
- On calcule la probabilité des différents symboles et règles étant donné une phrase S
- On estime le nombre d'occurrences des différents symboles et règles lors des dérivations de S
 - $C(N^j)$
 - $C(N^j \rightarrow N^r N^s)$
 - $C(N^j \rightarrow m^k)$
- On calcule de nouvelles probabilités pour les règles
 - $\hat{P}(N^j \rightarrow N^r N^s)$
 - $\hat{P}(N^j \rightarrow m^k)$
- On calcule $P(S)$
- On itère tant que $P(S)$ augmente

Occurrences estimées

■ Symbole

$$C(N^j) = \sum_{p=1}^n \sum_{q=p}^n P(N_{p,q}^j) = \sum_{p=1}^n \sum_{q=p}^n \alpha_j(p, q) \beta_j(p, q)$$

■ Règles binaires

$$C(N^j \rightarrow N^r N^s) =$$

$$\sum_{p=1}^{n-1} \sum_{q=p+1}^n \sum_{d=p}^{q-1} \alpha_j(p, q) P(N^j \rightarrow N^r N^s) \beta_r(p, d) \beta_s(d+1, q)$$

■ Règles unaires

$$C(N^j \rightarrow m^k) = \sum_{h=1}^n \alpha_j(h, h) P(N^j \rightarrow m_h) P(m_h = m^k) \beta_j(h, h)$$

Nouvelles probabilités

- $\hat{P}(N^j \rightarrow N^r N^s) = \frac{C(N^j \rightarrow N^r N^s)}{C(N^j)}$
- $\hat{P}(N^j \rightarrow m^k) = \frac{C(N^j \rightarrow m^k)}{C(N^j)}$

Nouvelles probabilités (2)

$$\hat{P}(N^j \rightarrow m^k) = \frac{\sum_{h=1}^n \alpha_j(h,h) P(N^j \rightarrow m_h), P(m_h = m^k) \beta_j(h,h)}{\sum_{p=1}^n \sum_{q=p}^n \alpha_j(p,q) \beta_j(p,q)}$$
$$\hat{P}(N^j \rightarrow N^r N^s) = \frac{\sum_{p=1}^{n-1} \sum_{q=p+1}^n \sum_{d=p}^{q-1} \alpha_j(p,q) P(N^j \rightarrow N^r, N^s) \beta_r(p,d) \beta_s(d+1,q)}{\sum_{p=1}^n \sum_{q=p}^n \alpha_j(p,q) \beta_j(p,q)}$$

Problèmes de l'algorithme extérieur intérieur

- Efficacité : pour chaque phrase du corpus d'apprentissage et chaque itération, la complexité est $O(n^3V^3)$ où n est la longueur de la phrase et V le nombre de non terminaux de la grammaire.
- Maximum local : l'algorithme est très sensible aux distributions de probabilités initiales. Des distributions différentes aboutissent à des maxima différents.
- Choix du nombre de non terminaux : on ne sait pas combien de non terminaux choisir, les expériences ont montré qu'un nombre important de non terminaux améliore les résultats, ce qui augmente le problème d'efficacité.

Limites des PCFG (1)

- Indépendance lexicale

- La réécriture d'un symbole pré-terminal X ne dépend pas du contexte d'occurrence de X
- mise en défaut : la préposition introduisant un complément d'un verbe dépend de la nature lexicale du verbe

Exemple : *Jean **pense** à Marie*

- cette dépendance n'est pas modélisée :

$GV \rightarrow V GP$

$V \rightarrow pense$

$GP \rightarrow P GN$

$P \rightarrow à$

Limites des PCFG (2)

- Indépendance structurale
 - le choix d'une règle pour la réécriture d'un symbole X est indépendant du contexte d'occurrence de X
 - mise en défaut : Dans le corpus switchboard, 91% des sujets sont des pronoms alors que seule 34% des objets le sont (Francis et al 99)
 - Or il n'y a qu'une règle de la forme $GN \rightarrow Pro$
 - et une seule probabilité lui correspondant