

Modélisation de l'incertitude (M2 MIAGE IA²)

Andrea G. B. Tettamanzi
Laboratoire I3S – Équipe SPARKS
`andrea.tettamanzi@univ-cotedazur.fr`



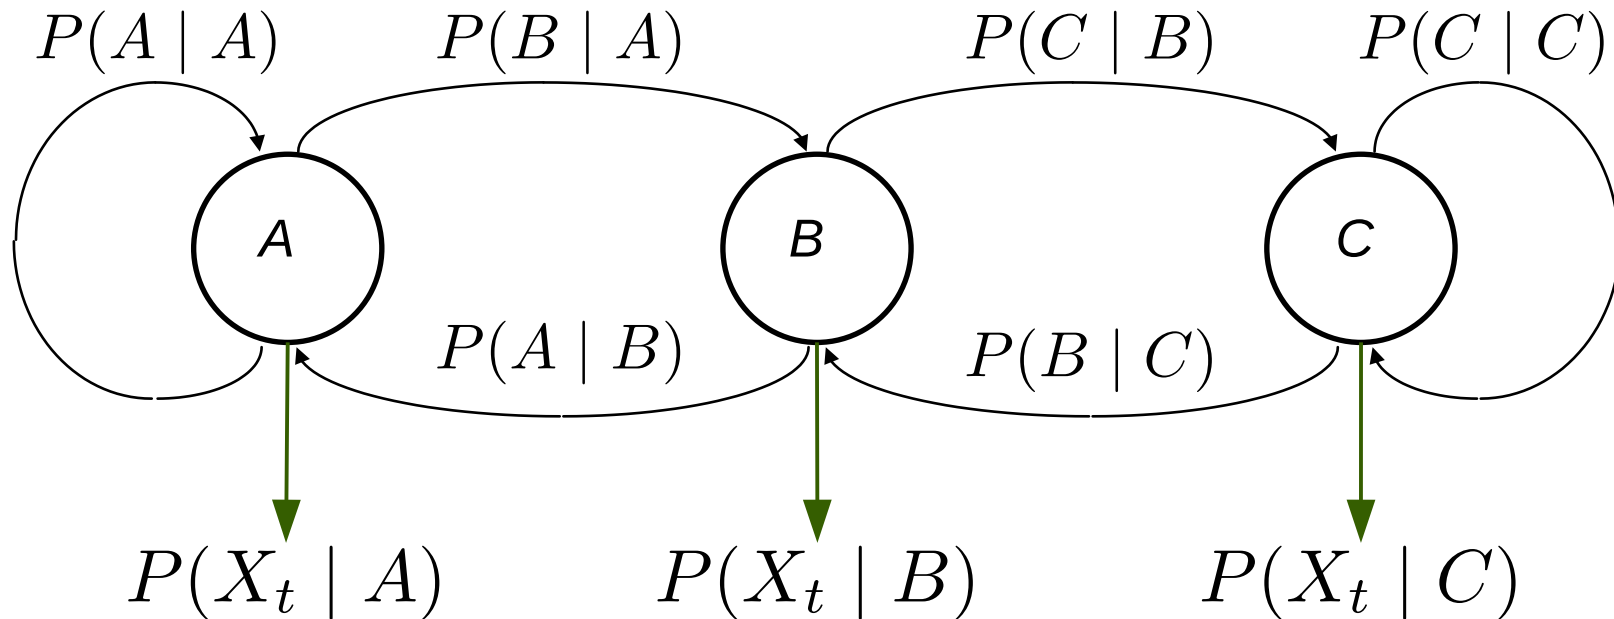
Séance 4

Modèles de Markov cachés

Dans cette séance

- Modèles de Markov cachés
- Applications des MMC
- Estimation, entraînement et décodage
- Algorithme de Viterbi
- Algorithme espérance-maximisation
- Algorithme de Baum-Welch

Modèles de Markov cachés



Processus doublement stochastique :
probabilités de transition et d'émission

Peut se mettre sous forme matricielle

Applications des MMC

- Traitement du langage
 - Reconnaissance vocale
 - Reconnaissance de l'écriture manuscrite
 - Traduction automatique
- Bio-informatique
 - Analyse de séquences d'ADN (prédiction des gènes)
- Finance
 - Prédiction d'inversion de tendance dans les séries temporelles

Problèmes dans les MMC

- Estimation :
 - trouver la probabilité d'une séquence d'observations étant donné le modèle
 - Algorithme de Baum-Welch (tous les chemins)
 - Algorithme de Viterbi (meilleur chemin)
- Entraînement :
 - Trouver les probabilités de transition & émission étant donné une topologie et des données
 - Algorithme espérance-maximisation
- Décodage :
 - Trouver la séquence d'états la plus probable étant donné une séquence d'observations
 - Algorithme de Viterbi


Programmation dynamique

- Méthode algorithmique pour résoudre des problèmes d'optimisation
- Introduite par Richard Bellman (années 1950)
- Idée : résoudre un problème en le décomposant en sous-problèmes, puis à résoudre les sous-problèmes, des plus petits aux plus grands en stockant les résultats intermédiaires
- Une solution optimale d'un problème s'obtient en combinant des solutions optimales à des sous-problèmes (principe d'optimalité de Bellman)

Exemple : nombres de Fibonacci

```
def fibonacci(n):  
    if n==0 or n==1:  
        return n  
    else:  
        return fibonacci(n - 1) + fibonacci(n - 2)
```

```
def fibonacci(n):  
    F[0] = 0  
    F[1] = 1  
    for i in range(2, n):  
        F[i] = F[i - 1] + F[i - 2]  
    return F[n]
```



Algorithme de Viterbi

$$\begin{aligned} & \max_{x_1, \dots, x_t} P(x_1, \dots, x_t, X_{t+1} \mid e_{1, \dots, t}) = \\ & \alpha P(e_{1, \dots, t} \mid X_{t+1}) \\ & \max_{x_t} \left(P(X_{t+1} \mid x_t) \max_{x_1, \dots, x_{t-1}} P(x_1, \dots, x_{t-1}, x_t \mid e_{1, \dots, t}) \right) \end{aligned}$$

Le chemin (= séquence d'observation) optimal est composé de sous-chemins optimaux

Algorithme espérance-maximisation

- On initialise le modèle aléatoirement, par exemple c centroïdes
- On affine ce modèle itérativement en alternant deux étapes
 - Espérance : affecter chaque échantillon X_i à C_j avec

$$P(X_i \in C_j) = p(C_j | X_i) = \frac{p(C_j)p(X_i | C_j)}{p(X_i)}$$

$$p(X_i | C_j) = \phi(X_i; \mu_j, \sigma_j)$$

- Maximisation : estimer les paramètres du modèle

$$\mu_k = \frac{\sum_{i=1}^N X_i P(X_i \in C_k)}{\sum_{j=1}^N P(X_i \in C_j)} \quad \sigma_k = \frac{\sum_{i=1}^N (X_i - \mu_k)^2 P(X_i \in C_k)}{\sum_{j=1}^N P(X_i \in C_j)}$$

Algorithme de Baum-Welch

- Cas particulier d'une généralisation de l'algorithme espérance-maximisation
- Déterminer le modèle qui explique le mieux une séquence d'observations donnée
- Algorithme itératif, qui permet d'estimer les paramètres du modèle qui maximisent la probabilité d'une séquence d'observables.
- Converge vers un maximum local.

