

# *Modélisation de l'incertitude (M2 MIAGE IA<sup>2</sup>)*

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



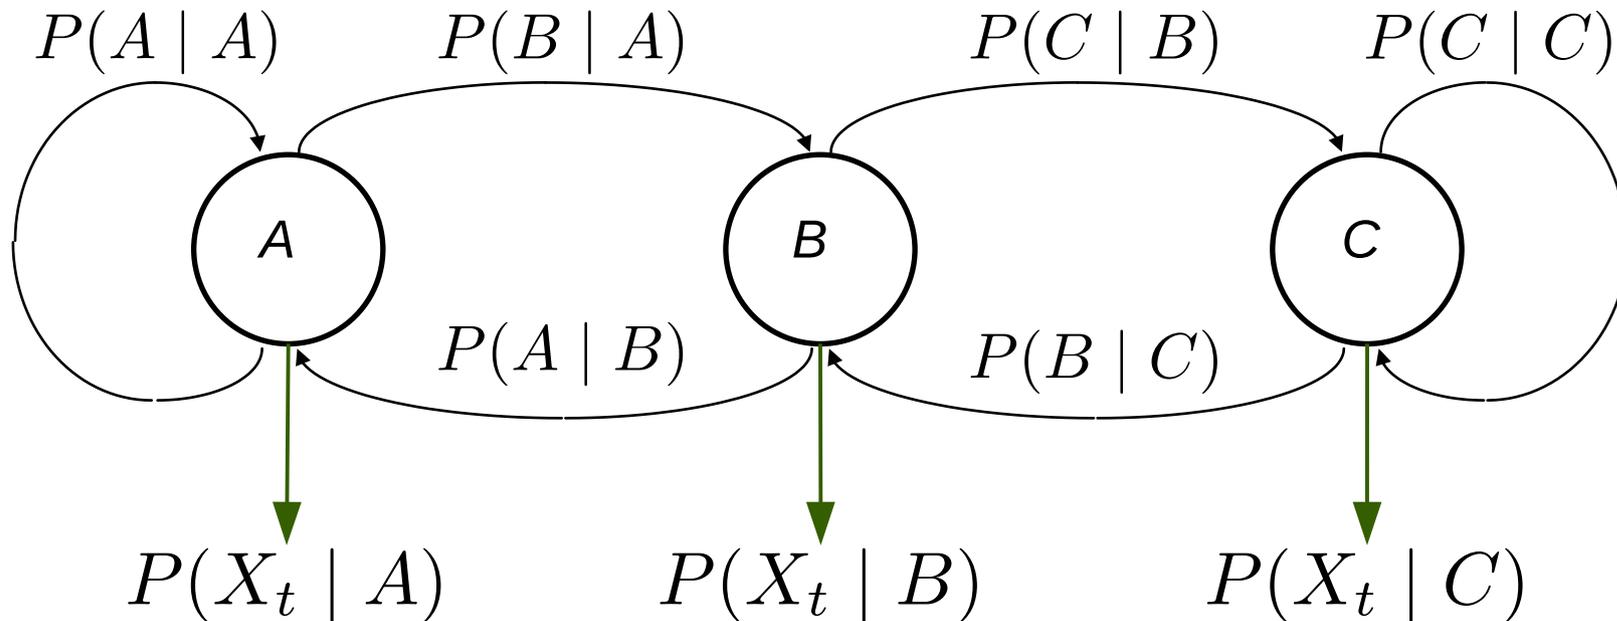
# Séance 4

## 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

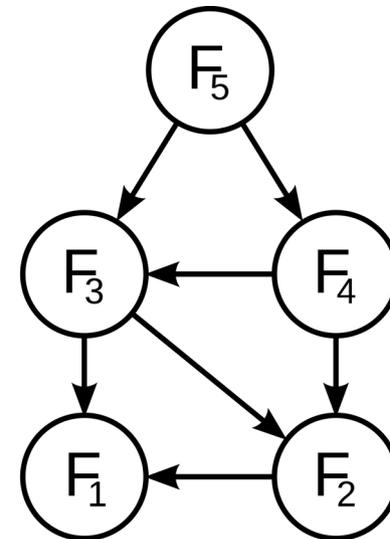
# Programmation dynamique

- 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 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.

