

# Introduction d'interactions directes dans les processus de décision markoviens


Vincent Thomas  
Christine Bourjot  
Vincent Chevrier

# Présentation

- Travail en cours
- Systèmes multi-agents
  - Réactifs : règles stimulus-réponse
  - Sans mémoire
- Construction automatique de comportements
  - De manière décentralisée
  - Pour résoudre des problèmes collectifs
  - Dans un cadre coopératif

# Plan

- Modèles markoviens
  - MDP
  - Extensions
- Notre proposition
  - Interac-DEC-MDP
  - Formalisme
- Exemples
- Résolution
- Conclusion






# MDP

- MDP Markov Decision Process =  $\langle S, A, T, R \rangle$ 
  - S ensemble d'états
  - A ensemble d'actions
  - T matrice de transition : évolution du système stochastique
    - $T: S \times A \rightarrow P(S)$
  - R récompense : fonction à optimiser
    - $R: S \times A \rightarrow P(\text{Re})$
- Un MDP = un problème de décision Mono-agent
  - Trouver politique (comportement réactif)  $\pi: S \rightarrow P(A)$
  - Qui maximise la somme des récompenses à long terme
- Algorithmes pour construire politique
  - Planification (value iteration, ...)
  - Apprentissage (Q-learning, ...)
  - Trouve politique **optimale**


# Extensions des MDPs

- DEC-MDP : Decentralized-MDP
- Formalisme pour problème de décision Multi-agent
  - Représenter agents réactifs
    - Exécution décentralisée et simultanée
    - Observabilité partielle
    - Fonction de Observations vers Actions :  $\pi_i: S_i \mapsto P(A_i)$
  - Représenter problème sous forme d'un processus
    - Matrice de transition
      - $T : S \times A_1 \times A_2 \times A_3 \times \dots \mapsto P(S)$
    - Fonction de récompense
      - $R : S \times A_1 \times A_2 \times A_3 \times \dots \mapsto P(Re)$
  - Actions des agents vues comme influences sur processus
  - Objectif: Maximiser la somme des récompenses


# Fonctionnement (Initial)




# Fonctionnement (Observations)




# Fonctionnement (Décision)




# Fonctionnement (Action)



# Fonctionnement (Évolution)



# Fonctionnement (Récompenses)




# Difficultés dans les DEC-MDP

- Difficultés

- Couplages implicites

- Dans transitions T
      - Résultat de action dépend des autres
    - Dans récompenses R
      - Récompense dépend des autres



- Évolution dépend des comportements des autres

- Résolution

- Centralisée  $\not\Leftarrow$  mono-agent

- Explosion combinatoire

- Décentralisée


- Problème co-évolution
    - Tragédie des communs
    - Problème de « credit assignment »

Trouver un compromis

- Notre proposition



# Plan

- Modèles markoviens
  - MDP
  - Extensions
- Notre proposition
  - Interac-DEC-MDP
  - Formalisme
- Exemples
- Résolution
- Conclusion




# Proposition


- Motivation :
  - Besoins de raisonner au niveau collectif sont limités
    - Échange, Partage de ressources, ...
  - Raisonner individuel est moins coûteux
    - Gestion des ressources attribuées
- Nouveau cadre formel
  - Interac-DEC-MDP
  - Restreindre les systèmes considérés
    - Séparer les décisions collectives des décisions individuelles
    - Moins expressif
- Restriction  $\Leftarrow$  Système Factorisés




# Cadre général




- Les agents peuvent agir individuellement
  - Pas influence des autres  $\Leftarrow$  Transitions indépendantes
- Les actions des agents sont récompensées dans leur espace
  - Pas de couplage de R  $\Leftarrow$  Récompenses indépendantes
- Chaque agent à des perceptions partielles
  - Etat, Récompenses, comportements des autres



# Cadre général




- Les agents peuvent agir individuellement
  - Pas influence des autres ↯ Transitions indépendantes
- Les actions des agents sont récompensées dans leur espace
  - Pas de couplage de R ↯ Récompenses indépendantes
- Chaque agent à des perceptions partielles
  - Etat, Récompenses, comportements des autres
- Interaction entre agents
  - Seuls couplages
  - Semi-centralisée entre agents impliqués




Apprentissage Égoïste → Gestion Du collectif

# Cadre général



- Les agents peuvent agir individuellement
  - Pas influence des autres ↯ Transitions indépendantes
- Les actions des agents sont récompensées dans leur espace
  - Pas de couplage de R ↯ Récompenses indépendantes
- Chaque agent à des perceptions partielles
  - Etat, Récompenses, comportements des autres
- Interaction entre agents
  - Seuls couplages
  - Semi-centralisée entre agents impliqués




Apprentissage Égoïste → Gestion Du collectif

Gestion Du collectif ← Apprentissage Égoïste


- Mais pas trivial
  - Remise en cause du comportement individuel

# Cadre général




- Les agents peuvent agir individuellement
  - Pas influence des autres ↯ Transitions indépendantes
- Les actions des agents sont récompensées dans leur espace
  - Pas de couplage de R ↯ Récompenses indépendantes

- Chaque agent à des perceptions partielles
  - Etat, Récompenses, comportements des autres



- Interaction entre agents
  - Seuls couplages
  - Semi-centralisée entre agents impliqués
- Mais pas trivial
  - Remise en cause du comportement individuel




# Formalisme: Agents

- Chaque agent  $i$  est décrit par un MDP  $\langle S_i, A_i, T_i, R_i \rangle$ 
    - $S_i$  espace état individuel
    - $A_i$  espace action individuel
    - $T_i$  transition individuelle
    - $R_i$  récompense individuelle
  - Les agents agissent simultanément
    - Politique individuelle  $\pi_i$
  - L'objectif  $\nabla$  maximiser la somme des récompenses individuelles
    - Pour le moment, sans interaction
- $$\max \left( \sum_i V(i) \right) = \sum_i \max (V(i))$$




# Interactions directes

- Définition
  - Influences mutuelles réciproques ponctuelles
- Il s'agit des seuls couplages du système
  - Agent  $i$  peut influencer état de  $j$




- Les agents impliqués peuvent raisonner
  - Politique dépend des agents impliqués
  - Processus de négociation




# Représentation interactions

- Ajout d'instances d'interactions
  - $I_k$ : interaction k
  - $I$ =ensemble des interactions
- Interaction: différents résultats possibles
  - $R_{i_{k,l}}$ : résultat l
  - $R_i$ : ensemble des résultats de  $I_k$
- Chaque résultat: matrice de transition
  - $TR_{i_{k,l}}$



Sport collectif




# Politiques d'interaction

- Individuelle

- Déclenchement


$$\pi_{i, trig} : S \rightarrow P(I, [0..n])$$



- Collective

- Semi-centralisation
- Résolution d'interaction
  - Pour chaque couple

$$\Pi_{interac, i, n_i, i_i} : S \rightarrow P(Ri_i)$$




# Formalisme: Modèle d'exécution

- Module d'action

- Décision

$$\forall i, a_i \leftarrow \pi_i(s)$$



- Exécution

$$\forall i, r_{i,earned} \leftarrow r_i(s, \{a_k\}_k)$$

$$s \leftarrow T(s, \{a_k\}_k)$$



- Module interaction

- Pour tout agent i

- Déclenchement


$$(i_i, n_i) \leftarrow \pi_{i,trig}(s)$$

- Décision jointe

$$r_{i_i} \leftarrow \Pi_{interac,i,n_i,i_i}(s)$$

- Exécution de l'interaction

$$s \leftarrow T_{r_{i_i},i,n_i}(s)$$




# Nouveau problème

- Les agents peuvent
  - Agir
  - Interagir
- Objectif : déterminer
  - Politique d'action  $\{\pi_i\}_i$
  - Politique de déclenchement  $\{\pi_{trig,i}\}_i$
  - Politique de résolution  $\{\Pi_{interac,i,j,I_k}\}_{i,j,k}$
- De manière décentralisée
- Pour maximiser une récompense perçue partiellement par les agents


# Plan

- Modèles markoviens
  - MDP
  - Extensions
- Notre proposition
  - Interac-DEC-MDP
  - Formalisme
- Exemples
- Résolution
- Conclusion




# Exemples

- Partage de nourriture
- Partage de ressources
- Pompiers
  - Chaque agent
    - Position
    - Possède seau plein/vide
  - Action individuelles
    - Les agents ne se gênent pas
    - T indépendants
  - Un agent reçoit une récompense
    - Met de l'eau dans le feu
    - R indépendant
  - Possibilité d'échanger des seaux
    - Interaction
    - Deux résultats: échange effectif / refusé
  - Intérêt de l'interaction
    - Plus vite dans les échanges




# Exemple simple

- Deux agents
- Positions limitées




- Échanges possibles



- Conséquences
  - Agent A voit feu et récompense mais pas eau
  - Agent B voit eau mais pas le feu ni les récompenses

# Plan

- Modèles markoviens
  - MDP
  - Extensions
- Notre proposition
  - Interac-DEC-MDP
  - Formalisme
- Exemples
- Résolution
- Conclusion



# Résolution

- En cours
- Deux objectifs
  - Apprentissage individuel                      ↙                      Collectif
  - Apprentissage collectif                      ↙                      Individuel
- Représentation décentralisée des politiques
  - Apprentissage individuel                      ↙                      Collectif
  - Utilise les apprentissages individuels
    - Maximiser somme des récompenses escomptées
    - Représentation décentralisée des résolutions d'interactions

# Utilisation des $Q_{interac}$

- Chaque agent dispose de

$$Q_{interac,i} : S \times RI_{k,l} \times \{A, P\} \rightarrow \mathfrak{R}$$

- Description


- $S$  : État du système
- $RI_{k,l}$  : Résultat d'interaction
- $\{A,P\}$  : Agent Actif ou Passif

- Interaction

Introduction du collectif

$$Q_r(RI_{k,l}) = Q_{I_k,a,A}(RI_{k,l}) + Q_{I_k,b,P}(RI_{k,l})$$

$$\Pi_{interac,a,b,I_k}(s) = \operatorname{argmax}_{RI_{k,l}} (Q_r(RI_{k,l}))$$




# Approche naïve

- 3 apprentissages dépendants
  1. Apprentissage actions individuelles

$$Q(s, a_i) \leftarrow (1 - \alpha) \cdot Q(s, a_i) + \alpha \cdot (r + \max_{a'} (Q(s', a')))$$

- Q-learning individuel




# Approche naïve

- 3 apprentissages dépendants
  1. Apprentissage actions individuelles

$$Q(s, a_i) \leftarrow (1 - \alpha).Q(s, a_i) + \alpha.(r + \max_{a'}(Q(s', a')))$$

4. Apprentissage des interactions

$$Q_I(s, RI_i) \leftarrow (1 - \alpha).Q_I(s, RI_i) + \alpha.(\max_{a'}(Q(s', a')))$$



# Approche naïve

- 3 apprentissages dépendants
  1. Apprentissage actions individuelles


$$Q(s, a_i) \leftarrow (1 - \alpha).Q(s, a_i) + \alpha.(r + \max_{a'}(Q(s', a')))$$

4. Apprentissage des interactions

$$Q_I(s, RI_i) \leftarrow (1 - \alpha).Q_I(s, RI_i) + \alpha.(\max_{a'}(Q(s', a')))$$

7. Apprentissage des déclenchements

$$Q_{trig}(s, I) \leftarrow (1 - \alpha).Q_{trig}(s, I) + \alpha.(\max_{a'}(Q(s', a')))$$




Apprentissage  
Égoïste




Gestion  
Du collectif

# Problème à résoudre

- Il reste à remettre à jour comportement individuel




- B n'a rien appris
  - Solution : transfert de récompense



Apprentissage Égoïste ← Gestion Du collectif

# Essais


- Forcer la Q-valeur de l'autre agents



- Donne des résultats
  - Pour l'instant fait à la main
  - Apprentissages simultanés
  - Converge souvent
- Reste à analyser plus finement ce passage.
  - Références au MDP faiblement couplés

# Plan

- Modèles markoviens
  - MDP
  - Extensions
- Notre proposition
  - Interac-DEC-MDP
  - Formalisme
- Exemples
- Résolution
- Conclusion



# Conclusion

- Un nouveau modèle Interac-DEC-MDP
  - Actions
  - Interactions
  - Problème collectif perçu partiellement
- Séparer les décisions collectives / individuelles
  - Actions:
    - Conséquences locales
  - Interactions:
    - Conséquences plus globales
    - Décisions prises à plusieurs
- Définit une nouvelle entité
  - Ensemble d'agents
  - Transfert de récompense

# Perspectives


- Un exemple très simple
  - 2 agents
  - Perception globale
  - Mais algorithmique non triviale

- Première étape
  - Résoudre à deux agents

- Par la suite
  - Changer d'échelle (plus d'agents)
  - Perceptions partielles
  - DEC-MDP (couplages supplémentaires)

} Apprentissage  
Dans des systèmes  
Réels

# Exemple



$R_1$	$R_2$	$R_3$	
5	5	10	Peu importe
8	1	10	Clef et coffre
8	3	10	Individuelles