

État de l'art de l'apprentissage par renforcement de politiques déclaratives

Ivelina Stoyanova - Romain Caillière, Nicolas Museux

Strasbourg – 07/07/2023



Les produits Thales sont la plupart du temps des systèmes critiques dont certains répondent à des problèmes de décisions séquentielles



■ Systèmes critiques avec problèmes de décision en réaction à un environnement

- Contrôle pour les systèmes autonomes,
- Reconnaissance d'activité avec mitigation des actions pour la protection des systèmes,
- Sélection d'actions tactiques pour la défense d'un théâtre d'opérations,
- Et plein d'autres.


Les techniques les plus performantes actuellement reposent sur des modèles « boîte noire » non validables/certifiables

■ A l'heure actuelle, les algorithmes de Deep Reinforcement Learning sont les techniques SOTA pour les problèmes de RL


- Explication compliquée de la décision du modèle a posteriori : **Explicabilité**
 - Il est compliqué de comprendre le lien entre les entrées et les sorties dans les systèmes « boîte noire »
- Impossibilité de lire et de comprendre le modèle pour un humain: **Interprétabilité**
 - les systèmes « boîte noire » ne sont pas composés de symboles auxquels une sémantique est associée
- Difficulté importante à **valider/certifier** de tels modèles

La gestion du trafic aérien comme exemple concret du besoin en IA validables/certifiables

Ce document ne peut être reproduit, modifié, adapté, publié, traduit, d'une quelconque façon, en tout ou partie, ni divulgué à un tiers sans l'accord préalable et écrit de THALES - © 2021 THALES, tous Droits réservés.




Conflict Detection & Resolution @ Thales



Politiques de décisions déclaratives et normalisées au niveau international (ICAO Doc 4444)

L'apprentissage par renforcement consiste à apprendre une politique/un comportement optimal au sein d'un environnement

Un apprentissage itératif




Au fur et à mesure de l'apprentissage, l'agent apprend la meilleure séquence d'associations état-action

Le comportement appris est optimal au regard :

- De la **modélisation** des états
- Des **actions** possibles
- De la **fonction** de récompense

Les politiques apprises peuvent être classées selon trois catégories



[Puiutta 2020]
[Alharin 2020]
[Heuillet 2021]
[Glanois 2021]

Les systèmes à base de règles sont un type de modèle déclaratif reposant sur des symboles auxquels sont associés une sémantique

SI Condition ALORS Conclusion

Les systèmes à base de règles sont un type de modèle déclaratif reposant sur des symboles auxquels sont associés une sémantique

SI Condition ALORS Conclusion

**Prémisse : formule logique de termes vrais ou faux
conjonction / disjonction / négation**

Les systèmes à base de règles sont un type de modèle déclaratif reposant sur des symboles auxquels sont associés une sémantique

SI Condition ALORS Conclusion

Logique

- **Propositionnelle:** constante, OR, AND, NOT
- **Predicat:** + quantifieurs, fonctions, variables
- **Temporelle:** + relations temporelles

Domaine

- **Symbolique, discret:** Logique Booléenne
- **Continue, mixte:** Logique floue
- **Evènementiel:** Logique temporelle

Règles

- **Decisionnelle:** *Si condition vraie alors faire action*
- **Deductive:** *Si formule vraie, alors déduction vraie*
- **Descriptive:** *Si propriétés vraies, alors classe est C*

Apprentissage de règles pour des domaines discrets

Logiques à valeurs de vérité Booléennes

Apprentissage de politique à base de règles basées sur la logique Booléenne

RL tabulaire : Q-Learning, SARSA, dérivés

➤ Table = base de règles : Si état = s_i ALORS action = $\text{argmax}_a(Q(s_i, a))$

CLARION : architecture cognitive [Sun, 2001]

➤ RL tabulaire = bas niveau | Règles = haut niveau (généralisation/spécialisation)

RL relationnel : description explicite des états et des actions basée sur des prédicats relationnels. [Džeroski, 2001]

Neural Logic RL : Apprentissage de règles à partir de Deep RL [Jiang, 2019, Ma 2021, Payani 2020]

=> Logique propositionnelle et/ou nécessité de l'expertise humaine en amont

L'apprentissage de politiques déclaratives via l'utilisation des machines de Tsetlin

■ **Repose sur les automates de Tsetlin (un automate/terme)** [Granmo, 2018]


■ **Se déroule en trois étapes répétées durant l'apprentissage**

- 1 L'extraction de motifs fréquents → Spécialisation
- 2 La discrimination des littéraux → Généralisation
- 3 La choix de l'action (par un vote des règles)

■ **Classification → Régression → Apprentissage par renforcement** [Gorji 2021, 2023]

■ **→ Ne s'attaque pas à des environnements complexes pour le moment, difficulté du passage à l'échelle (notamment pour l'interprétabilité)**

Introduction des Learning Classifier Systems




Proposé par John H. Holland en 1986

... a learning paradigm in which an agent learns to perform a task by evolving a population of *condition-action rules* (i.e. the classifiers) through *temporal difference learning* and *genetic algorithms*.

P.L. Lanzi 2005

Les algorithmes génétiques sont une méthode d'optimisation pour obtenir une solution approchée en un temps raisonnable



Ce document ne peut être reproduit, modifié, adapté, publié, traduit, d'une quelconque façon, en tout ou partie, ni divulgué à un tiers sans l'accord préalable et écrit de THALES - © 2021 THALES. Tous Droits réservés.

Learning Classifier System: une combinaison Apprentissage par Renforcement/Algorithme Génétique/ Système à Base de Règles

Les individus sont :

- Des règles (Michigan style)
- Des jeux de règles (Pittsburgh style)


Le jeu des algorithmes génétiques fait évoluer les règles

eXtended Classifier Systems [Butz 2000, Wilson 1995]

- Si état ALORS action prédit p

Gestion des dimensions continues [Stone 2003]

XCS-RC [Fredrianius 2015] : remplacement de l'AG par le principe de l'induction



THALES

Building a future we can all trust

Apprentissage de règles pour des domaines continus


Logiques à valeurs de vérité floues

La logique floue étend la logique booléenne classique avec des valeurs de vérités partielles

$$\chi_A(x) = \begin{cases} 1 & \text{si } x \in A \\ 0 & \text{si } x \notin A \end{cases}$$



$$\mu_{\tilde{A}}(x) \in [0, 1]$$



Ce document ne peut être reproduit, modifié, adapté, publié, traduit, d'une quelconque façon, en tout ou partie, ni divulgué à un tiers sans l'accord préalable et écrit de THALES - © 2021 THALES, Tous Droits réservés.

Fuzzy Learning Classifier Systems : les LCS reposant sur le logique floue

Trois différences principales avec les LCS [Bonarini 1999, 2007, Casillas 2007]

- Le déclenchement de la règle, grâce à l'utilisation de la fonction d'appartenance,
 - Toutes les règles se déclenchent avec un certain degré
- La manière dont les actions sont choisies
 - La meilleure prédiction moyenne
- Au niveau de l'inférence floue et de la défuzzification
 - L'action à appliquer est calculée selon les principes de la défuzzification


Apprentissage de politique à base de règles basées sur la logique floue

Modification de la conclusion des règles


- FQL : FIS pour permettre au Q-Learning d'appliquer des actions continues [Glennec 1997]
- Actor-Critic : l'acteur est modélisé par un FIS [Lee 1989]

Modification des prémisses des règles

Modification des centres
(moyenne)



Modification des largeurs
(écart-type)



[Berenji 1992, Desouky 2011, Joo Er 2004, Lin 1994, 1996, Wang 2007]

Capacité de suppression des règles inutiles [Hosoya 2012]

Le problème de l'interprétabilité des systèmes à base de règles

■ Règles ≠ Interprétable par définition

■ Lipton [C. Lipton, 2017] : Interprétabilité =

- Simulable - capacité pour un humain de saisir immédiatement le sens du modèle
- Décomposable - impliquant que les entrées, les paramètres et le calcul soient facilement appréhendables
- Algorithmiquement transparent - fournissant une garantie sur le résultat du modèle sur des données inconnues

■ [Miller 1956]: La règle des 7 plus ou moins 2.


- Un nombre maîtrisé de termes dans la prémisse
- Un nombre maîtrisé de règles dans la politique

■ L'enchaînement des règles [Glanois 2022, Trillo 2020]

Illustration via l'interprétabilité des règles apprises avec le Dynamic Fuzzy Q-Learning



• **Association symbole-sémantique** : un symbole par fonction d'appartenance



• **Distinguabilité** : capacité à repérer le terme discriminant

Réflexion sur les métriques d'interprétabilité

- Définir formellement les critères d'interprétabilité
- Intégrer ces critères à l'apprentissage par renforcement
- Apprendre un jeu de règles interprétables par construction

Validation des modèles à base de règles floues

- Utilisation des méthodes formelles pour valider le modèle à base de règles appris

Règles événementielles

- Mise au point d'un environnement spécifique
- Réflexion sur un algorithme capable d'apprendre dans ce contexte