



**HAL**  
open science

## Auto-organisation d'agents embarqués pour l'apprentissage par démonstration : principes et expérimentations

Nicolas Verstaevel, Christine Régis, Marie-Pierre Gleizes, Fabrice Robert

### ► To cite this version:

Nicolas Verstaevel, Christine Régis, Marie-Pierre Gleizes, Fabrice Robert. Auto-organisation d'agents embarqués pour l'apprentissage par démonstration : principes et expérimentations. Journées Franco-phones sur les Systèmes Multi-Agents (JFSMA 2015), Jun 2015, Rennes, France. pp.159-168. hal-04079535

**HAL Id: hal-04079535**

**<https://hal.science/hal-04079535>**

Submitted on 24 Apr 2023

**HAL** is a multi-disciplinary open access archive for the deposit and dissemination of scientific research documents, whether they are published or not. The documents may come from teaching and research institutions in France or abroad, or from public or private research centers.

L'archive ouverte pluridisciplinaire **HAL**, est destinée au dépôt et à la diffusion de documents scientifiques de niveau recherche, publiés ou non, émanant des établissements d'enseignement et de recherche français ou étrangers, des laboratoires publics ou privés.



## Open Archive TOULOUSE Archive Ouverte (OATAO)

OATAO is an open access repository that collects the work of Toulouse researchers and makes it freely available over the web where possible.

This is an author-deposited version published in : <http://oatao.univ-toulouse.fr/>  
Eprints ID : 15280

The contribution was presented at JFSMA 2015:  
<http://pfia2015.inria.fr/conference-jfsma>

**To cite this version** : Verstaevel, Nicolas and Régis, Christine and Gleizes, Marie-Pierre and Robert, Fabrice *Auto-organisation d'agents embarqués pour l'apprentissage par démonstration : principes et expérimentations*. (2015) In: Journées Francophones sur les Systèmes Multi-Agents (JFSMA 2015), 29 June 2015 - 1 July 2015 (Rennes, France).

Any correspondence concerning this service should be sent to the repository administrator: [staff-oatao@listes-diff.inp-toulouse.fr](mailto:staff-oatao@listes-diff.inp-toulouse.fr)

# Auto-organisation d'agents embarqués pour l'apprentissage par démonstration : principes et expérimentations

N. Verstaev<sup>a, b</sup>  
verstaev@irit.fr

C. Régis<sup>b</sup>  
regis@irit.fr

M.P. Gleizes<sup>b</sup>  
gleizes@irit.fr

F. Robert<sup>a</sup>  
fabrice.robert@sogeti.com

<sup>a</sup>Sogeti High Tech,  
3 Chemin de Laporte, Toulouse, France

<sup>b</sup>IRIT, Équipe SMAC,  
Université Paul Sabatier, Toulouse, France

## Résumé

*L'adaptation des systèmes ambiants aux besoins spécifiques des utilisateurs est une tâche complexe. Pour rendre l'interaction humain-système aussi naturelle que possible pendant l'adaptation, nous proposons une approche basée sur l'apprentissage par démonstration. L'apprentissage par démonstration en système ambiant requiert des techniques d'apprentissage adaptatives. Nous présentons Alex, un système multi-agent capable d'apprendre dynamiquement un comportement à partir de démonstrations réalisées par un tuteur. Les résultats d'expérimentations réalisées à la fois sur un robot réel et virtuel mettent en avant des propriétés intéressantes de notre technologie pour des applications ambiantes.*

**Mots-clés** : Robotique collective, Intelligence ambiante, Apprentissage, Auto-organisation

## Abstract

*The adaptation of an ambient system to the specific needs of its users is a challenging task. Because human-system interaction has to be as natural as possible, we propose an approach based on Learning from Demonstration (LfD). However, using LfD in ambient systems needs adaptivity of the learning technic. We present Alex, a multi-agent system able to dynamically learn and reuse contexts from demonstration made by a tutor. Results of experiments*

*performed on both a real and virtual robot show interesting properties of our technology for ambient applications.*

**Keywords**: Collective robotic, Ambient intelligence, Learning, Self-organization

## 1 Introduction

Autrefois restreinte à une science du contrôle en environnements contraints, les recherches en robotique s'intéressent maintenant à l'intégration de systèmes intelligents ou cyber-physiques autonomes dans des environnements où les tâches sont multiples, complexes et évolutives (Kaminka, 2012). La robotique de service diffère de sa version industrielle par l'intérêt à fournir des services à des utilisateurs plutôt que de satisfaire des objectifs. C'est pourquoi la communauté scientifique s'intéresse à l'utilisation de composants robotique dans des applications ambiantes (Chung, 2014). Ces systèmes ambiants se caractérisent par leur dynamique et leur complexité. Un grand nombre de dispositifs (capteurs et effecteurs) hétérogènes peuvent apparaître et disparaître pour interagir de manière opportuniste. (Russel et al, 1995) décrivent l'environnement de ces dispositifs comme :

- **Inaccessible** : chaque entité n'a qu'une observation partielle de l'environnement.
- **Continue** : le nombre d'observations et

d'actions dans le monde réel n'est pas discret.

- **Non-déterministe** : les conséquences d'une action réalisée dans le monde réel ne peuvent pas être déterminées à l'avance.

- **Dynamique** : les actions du système, l'activité des utilisateurs, l'apparition et la disparition de dispositifs peuvent changer l'environnement.

Le caractère *distribué* des systèmes ambiants ne permet pas l'utilisation d'un processus de contrôle centralisé. A l'inverse, chaque dispositif doit être doté de son propre contrôleur. La conception *ad hoc* d'un contrôleur pour un dispositif dans un système ambiant est une tâche complexe qui nécessite une forte expertise et implique des coûts de développement et de maintenance exponentielle. En effet, elle nécessite de lister *a priori* tous les cas d'utilisation du dispositif ainsi que ses différentes interactions. La tâche est d'autant plus complexe si l'on prend en compte le caractère spécifique, multiple et changeant des besoins des utilisateurs. Doter ces systèmes de la capacité d'apprendre à s'adapter aux besoins de ses utilisateurs est une tâche particulièrement difficile (Hagras, 2004) mais qui présente un intérêt certain dans la réduction des coûts de développement et de maintenance. Dans cet article, nous proposons une approche nommée « *eXtreme Sensitive robotic* » (Verstaavel, 2015). L'*XS Robotic* considère chaque fonctionnalité comme une entité autonome. Un système ambiant est donc un agrégat de plusieurs *XS Function*, globalement une pour chaque capteur et effecteur. Une *XS Function* est soit sensitive (capteur température, ultrason,...) soit active (un moteur, une LED,...). Chaque *XS Function* est conçue comme *non finale*, c'est-à-dire que la fonctionnalité doit pouvoir s'adapter. En exploitant ses capacités d'auto-observation, le système peut observer des variations dans son environnement et déclencher les mécanismes d'adaptation adéquats. Avec cette approche, la production d'un comportement complexe par un ensemble de dispositifs émerge de l'interaction entre les différentes *XS Function*

et l'environnement. Il n'y a donc pas de différence de conception entre un robot composé de plusieurs capteurs et effecteurs, une application multi-robot ou un système ambiant. Tous ces systèmes sont composés de fonctionnalités qui doivent s'adapter pour satisfaire leurs utilisateurs.

Pour être naturelle, cette adaptation doit reposer sur un procédé qui ne requiert pas d'expertise particulière pour l'utilisateur. De plus, elle nécessite à la fois d'être **générique**, pour être applicable à tout type de dispositif et pour tout utilisateur, ainsi que de respecter la propriété d'**ouverture** pour gérer l'apparition et la disparition de dispositifs. Le respect de la généricité et de l'ouverture requiert l'utilisation de techniques d'apprentissage *agnostiques* (Kearns, 1994) qui ne font peu d'hypothèses sur leur environnement. Pour respecter ces propriétés, nous proposons l'utilisation de l'apprentissage par démonstration, un paradigme permettant l'apprentissage dynamique de nouveaux comportements.

## 2 Apprentissage par démonstration

L'apprentissage par démonstration, aussi appelé « apprentissage par imitation », est un paradigme principalement étudié en robotique qui permet à un système d'apprendre dynamiquement de nouveaux comportements (Argall, 2009). L'idée principale est qu'un contrôleur adéquat peut être appris de l'observation de l'activité d'une entité externe (humaine ou virtuelle) nommée *tuteur*. Le tuteur interagit avec le système au travers d'un processus de *démonstrations*, qui consiste en la réalisation d'une succession d'actions dans des situations particulières. Le système doit alors apprendre une fonction corrélant l'observation de son environnement avec les actions réalisées par le tuteur. L'avantage principal de cette technique est qu'elle ne nécessite aucune programmation explicite et aucune expertise sur le système de la part du tuteur. Des travaux récents proposent une étude du domaine de

l'apprentissage par démonstration (Argall, 2009) (Billard, 2008) et (Billing, 2010) fournit une formalisation complète. L'apprentissage par démonstration est un problème d'imitation où une entité produit un comportement similaire à une autre entité. Un *tuteur* évoluant dans un monde  $\Omega$  peut réaliser un ensemble d'actions  $A$ . Le tuteur suit une politique  $\Pi : \Omega \rightarrow A$  qui associe à chaque situation du monde une action. Il est supposé que cette politique est optimale pour satisfaire l'utilisateur. Un imitateur (nommé *apprenant*) possède un ensemble d'observations  $O$  (nommé *espace d'observations*) sur le monde  $\Omega$  et suit une politique  $\Pi' : O \rightarrow A$  telle que  $\Pi' \equiv \Pi$ . L'apprenant doit donc trouver des corrélations entre la réalisation d'une action par son tuteur et des variations dans l'observation qu'il fait du monde.

L'application de ce paradigme aux systèmes ambiants repose sur la richesse des interactions avec leurs utilisateurs. L'utilisateur peut être vu comme tuteur du système et chacune de ses actions sur un dispositif comme une démonstration du comportement désiré. En effet, si l'utilisateur nécessite d'intervenir sur une fonctionnalité, c'est que le service fournit par cette fonctionnalité ne le satisfait plus. Le dispositif contrôlant la fonctionnalité concernée peut alors exploiter cette information pour s'adapter. Le rôle d'un dispositif est alors de corréler l'activité de l'utilisateur à l'observation qu'il fait de son environnement.

L'utilisation du paradigme multi-agent (Ferber, 1999) dans l'XS Robotic apparaît naturelle pour leur capacité à faire face à la complexité et à apprendre en interaction avec leur environnement (Panait, 2005). (Kaminka, 2012) montre l'apport des systèmes multi-agents pour la robotique. Plusieurs approches proposent dès le début des années 2000 l'utilisation de systèmes multi-agents pour permettre l'organisation d'un collectif de robots (Collinot, 1999) (Parker, 2000) (Picard, 2005) et encore de nos jours le paradigme montre l'intérêt certains pour des tâches

complexes telles que l'exploration collective (Souliman, 2014) ou l'intervention en situation de crise (Lacouture, 2012). Mais ces approches considèrent souvent le robot comme un simple agent. Dans cet article, nous soutenons que la distribution du contrôle au sein de chaque fonctionnalité composant le système permet une plus grande adaptation de celui-ci. La prochaine section présente Alex, un système multi-agent pour l'apprentissage par démonstration conçu à partir de la vision XS *Robotic*.

### 3 Alex: Adaptive Learner by EXperiments

Alex est un système multi-agent construit pour apprendre à contrôler une fonctionnalité à partir de démonstrations réalisées par un tuteur. Sa conception est basée sur l'approche des systèmes multi-agents adaptatifs (AMAS) (Gleizes, 2012) qui adresse la problématique des systèmes complexes par une approche « bottom-up » où le concept de coopération agit comme moteur de l'auto-organisation. Le théorème de l'adéquation fonctionnelle (Casper, 2003) stipule que « pour tout système fonctionnellement adéquat, il existe au moins un système à milieu interne coopératif qui réalise la même fonction dans le même environnement ». Le rôle d'un AMAS est alors d'automatiquement détecter et réparer des situations de non-coopération en s'auto-organisant pour atteindre un état fonctionnellement adéquat. La conception d'Alex suit la méthodologie ADELFE2.0 (Bonjean, 2014) qui guide le concepteur d'un système adaptatif.

#### 3.1 Context-Learning

La section 2 illustre l'impossibilité de lister *a priori* toutes les situations qu'un système ambiant peut rencontrer. Cette incapacité à spécifier complètement le système rend obligatoire son adaptation aux différents contextes d'utilisations (Makkonen, 2009). Le terme « contexte » n'a pas de définition communément admise, aussi fait-il référence

dans cet article à toute information externe à l'activité d'une entité qui affecte son activité. Cet ensemble d'informations décrit l'environnement tel que le perçoit l'entité (Guivarch, 2014). Un système capable d'exploiter des informations de son contexte est alors nommé « context-aware ». Alex est conçu pour interagir continuellement avec son environnement et apprendre dynamiquement ses différents contextes. Ainsi, il construit une politique  $\Pi$  qui associe à chaque contexte l'action adéquate à réaliser. Pour ce faire, il dispose de capacités *d'auto-observation* pour construire dynamiquement des corrélations entre la réalisation d'une action et l'effet de cette action sur l'environnement. Une instance d'Alex est composée d'un ensemble non fini d'agents contextes. Chaque agent contexte est porteur d'une corrélation associant à un état de l'environnement une action. Cet ensemble, vide au départ, est dynamiquement peuplé au fur et à mesure qu'Alex détecte de nouvelles situations. Les agents contextes s'auto-organisent pour effectuer un contrôle sur une fonctionnalité. Dans cette partie, nous décrivons la structure et le comportement des agents contextes.

Les agents contextes sont décrits en décomposant leur comportement en deux types. Le comportement *nominal* de l'agent correspond à son comportement lorsque le système se trouve dans un état fonctionnellement adéquat qui ne nécessite pas d'adaptation. Le comportement *coopératif* est une subsomption du comportement nominal qui s'exécute lorsqu'une situation non coopérative est détectée. Il conduit alors à l'auto-organisation de l'entité en interaction avec les autres entités du système afin de retourner dans un état fonctionnellement adéquat.

### 3.2.1 Comportement nominal

Un *agent contexte* associe une description bas-niveau du contexte noté  $V$  (voir section 3.2.2) à une action unique. Cette action correspond au maintien ou à l'ajustement d'une

fonctionnalité. Elle peut être une commande de haut-niveau (tel que « Avance », ou « Tourne à droite »,...) ou de bas-niveau (« vitesse à 42% », «  $x=-2$  »,...) selon la fonctionnalité à contrôler. Un agent contexte reçoit un ensemble  $O$  de signaux de son environnement qu'il utilise pour caractériser le contexte courant du système. Quand l'observation qu'il fait de l'environnement correspond à sa description  $V$ , l'agent déclenche son action  $a \in A$ , ou ne fait rien le cas échéant ( $\theta$ ). Le comportement nominal  $N$  d'un agent contexte se résume à la fonction  $N : O \times V \rightarrow a \parallel \theta$ . Le comportement  $\Pi$  du système est donc résultant de l'interaction entre les agents contextes.

### 3.2.2 Description du contexte

Pour déclencher son action, l'agent contexte a besoin de comparer la situation courante avec sa représentation bas-niveau. Cette représentation bas-niveau du contexte est réalisée grâce à des plages de valeurs (nommées *plages de validité*). Un agent contexte reçoit un ensemble d'observations  $O$  de son environnement. Chaque  $o \in O$  est une valeur continue incluse dans un espace de définition  $o \in [o_{\min}, o_{\max}]$ . Par exemple, une observation émanant d'un capteur de température  $temp \in [-20, 40]$  où -20 et 40 sont les températures minimales et maximales du capteur. Ces valeurs *min* et *max* ne sont pas connues *a priori*.

Une plage de validité  $v$  est associée à chaque observation tel que  $v_o$  correspond à la plage de validité associée à l'observation  $o$ . L'ensemble des plages de validité  $V$  forme le *domaine de validité*. Une plage de validité est composée de deux valeurs  $v_{\min}$  et  $v_{\max}$  tel que  $[v_{\min}, v_{\max}] \subseteq [o_{\min}, o_{\max}]$ . Le rôle d'une plage de validité est d'adapter dynamiquement la valeur des deux bornes  $v_{\min}$  et  $v_{\max}$ . Une plage de validité est dite *valide* si et seulement si  $o \in [v_{\min}, v_{\max}]$ , c'est-à-dire si la valeur courante de l'observation est comprise dans les bornes de la plage de validité. Le domaine de validité sera dit *valide* si toutes ses plages de validité sont *valides*. Ainsi, un agent contexte dont le

domaine de validité est *valide* déclenchera son action, considérant que le contexte courant du système correspond à sa représentation. La gestion des plages de validité se fait grâce à des trackers adaptatifs nommés Adaptive Value Trackers (AVT) (Lemouzy, 2011). Cet outil permet de trouver automatiquement une valeur à partir de feedbacks successifs. Il est à noter qu'avec cette représentation, aucune sémantique n'est associée au signal et que seul des tests d'inclusions ensemblistes sont réalisés.

### 3.2.3 Comportement coopératif

À chaque cycle, une unique action peut être réalisée, le dispositif pouvant n'être que dans un seul état à la fois. Les agents contextes *valides* doivent alors coopérer pour déterminer si leur action est la plus appropriée dans le contexte courant. Pour être dans un état fonctionnellement adéquat, deux agents contextes *valides* ne peuvent proposer d'actions antagonistes (par exemple, deux contextes proposant chacun d'allumer et d'éteindre une lumière). Cependant, en ne conservant que le comportement nominal, des situations où plusieurs agents contextes déclenchent leurs actions sont possibles. Ces situations sont des situations de **non coopérations** et doivent être résolues pour amener le système dans un état fonctionnellement adéquat. On distingue trois situations de non-coopération. La première (a) se produit lorsqu'au moins deux agents contextes proposent de réaliser une action (indépendamment de la nature de l'action). La seconde (b) se produit si l'action proposée par un agent contexte est en contradiction avec l'action réalisée par le tuteur. La dernière (c) se produit lorsqu'aucun agent contexte ne propose d'action. Pour résoudre ces situations, les agents contextes suivent un comportement coopératif.

#### 3.2.3.1 Confiance

Un agent contexte détermine un niveau de *confiance* qui représente la pertinence de la

réalisation de son action. Cette confiance permet aux agents contextes de se comparer. Si un agent contexte se trouvant *valide* veut réaliser une action alors que sa confiance est inférieure à celle d'un autre agent contexte *valide*, il doit modifier son domaine de validité en ajustant les bornes de ses plages de validité afin d'exclure la situation courante. Ainsi, la prochaine fois que la même situation se reproduira, cet agent contexte ne proposera pas son action. La confiance  $c$  d'un agent contexte est régie par une lambda fonction :

$$c_{t+1} = c_t * (1 - \alpha) + F_t * \alpha.$$

$c_{t+1}$  est la confiance de l'agent contexte à l'instant  $t+1$ .  $F_t \in [0,1]$  est la valeur de feedback et  $\alpha \in [0,1]$  est un paramètre fixé qui modélise l'importance du feedback. Chaque fois qu'un agent contexte a raison de proposer son action,  $F_t = 1$ . A l'inverse, chaque fois que cet agent fait une mauvaise proposition,  $F_t = 0$ . Dans notre implémentation,  $\alpha$  est empiriquement fixé à 0,8 et la valeur de confiance est initialisée à 0,5. La confiance des agents contextes permet de lever l'ambiguïté soulevée par la SNC (a). Plus l'agent contexte fait de bonnes propositions, plus sa confiance est élevée. A l'inverse, plus sa confiance est faible, plus l'agent a fait de mauvaises propositions. La valeur minimale de confiance est fixée à 0,1, ce qui signifie que tout contexte avec une confiance inférieure à 0,1 se retirera de l'ensemble des agents contextes.

#### 3.2.3.2 Adéquation avec le tuteur

Lorsque le tuteur agit sur un dispositif, son action est perçue par les agents contextes. Si un agent contexte est *valide* dans la situation courante mais propose une action différente de celle de l'utilisateur, il doit alors ajuster les bornes de ses plages de validité afin d'exclure la situation courante en ajustant les bornes  $v_{min}$  et  $v_{max}$ . Si l'agent contexte perçoit une donnée de l'environnement qui n'est pas encore incluse dans ses plages de validité (suite par exemple à l'ajout d'un capteur dans l'environnement), il ajoute une nouvelle plage

de valeur associée à cette observation. A l'inverse, si l'agent contexte propose une action en adéquation avec l'utilisateur, il renforce sa confiance en l'utilité de son action. Dans tous les cas, l'action de l'utilisateur sera appliquée à la fonctionnalité. Ces mécanismes permettent la résolution de la SNC (b). Le processus d'adaptation des bornes des plages de validité peut conduire à une situation où  $v_{\max} < v_{\min}$ . Si une telle situation se produit, la plage de valeur concernée ne pourra plus être valide. L'agent contexte concerné se trouvant alors dans une situation d'inutilité et s'autodétruit.

### 3.2.3.3 Anticipation et création d'agent contexte

L'état fonctionnellement adéquat du système nécessite qu'il existe un unique agent contexte dont l'action est activée par cycle de décision. Cependant, le système peut se retrouver dans des situations entièrement nouvelles où aucun agent contexte n'est *valide* et par conséquent être dans une situation d'incompétence. Deux mécanismes peuvent résoudre cette situation : étendre les bornes de validité de l'agent contexte existant ou créer un nouvel agent contexte pour représenter cette nouvelle situation.

Pour anticiper une situation d'incompétence, le concept de *validable* est introduit. Une plage de validité  $v_o$  est validable si et seulement si  $0 \notin [v_{\min}, v_{\max}]$  et  $0 \in [v_{\min} - \Delta_{\min}, v_{\max} + \Delta_{\max}]$ .  $\Delta_{\min}$  et  $\Delta_{\max}$  sont deux valeurs (une pour chaque borne) gérées dynamiquement par les AVTs pour contrôler l'évolution de chaque borne.  $\Delta$  peut-être interprété comme le prochain incrément de la borne. Avec le concept de *validable*, les agents contextes peuvent proposer leur action dans des situations où ils ne sont pas *valides* mais dont l'intégration peut se faire en un seul ajustement de bornes. Si l'action proposée par l'agent est la plus adéquate, il adapte alors ses bornes pour inclure la situation courante. A l'inverse, si la proposition n'était pas pertinente, les AVT diminueront leur  $\Delta$  pour ne pas se proposer la

prochaine fois.

Lorsqu' aucun agent contexte n'est *valide* ou *validable*, le système est face à une situation d'incompétence, il ne peut décider de l'action à réaliser. L'agent contexte *valide* à l'étape précédente (mais qui n'est plus *valide* dans la situation courante) peut alors créer un nouvel agent contexte destiné à le remplacer en lui associant l'action effectuée par le tuteur. Le contexte ainsi créé initialise ses plages de validité pour représenter la situation courante. Si le tuteur n'a pas effectué d'action, deux mécanismes peuvent se produire selon l'autonomie désirée par le tuteur. Avec une approche *collaborative*, le système peut interroger le tuteur sur l'action à réaliser. Avec une approche *autonome*, le système maintient la dernière action qu'il a su réaliser, considérant l'inaction du tuteur comme une demande de maintien de l'action courante. Ce mode peut être choisi à l'initialisation du système et être changé dynamiquement. Ces deux mécanismes, le concept de validabilité et la création d'agents contexte, permettent de résoudre la SNC (c). Dans la suite de cet article, nous proposons d'illustrer le comportement d'Alex sur une application concrète.

## 4 Expérimentations

Un robot munit de deux roues sans aucun capteur est immergé dans une arène de 2x2m composée d'une zone bleue et d'un artefact vert. Une caméra située 2m au-dessus du centre de l'arène observe la scène et peut analyser les pixels pour capturer la position des artefacts bleu et vert par rapport à la position du robot (Figure 1). Ainsi à chaque cycle, la caméra produit quatre observations sur la




Figure 1- L'expérimentation sous Webots™.



scène correspondant à la distance, et l'angle pour chaque artefact. Pour montrer la capacité à gérer l'apparition et la disparition de signaux, la camera envoie les informations de positions au robot uniquement si les artefacts se situent face au robot. À chaque étape, la caméra peut alors produire 0, 2 ou 4 observations.

Un utilisateur humain peut contrôler le robot au travers d'une manette. Chaque joystick contrôle la vitesse d'une roue (le joystick gauche contrôle la roue gauche et réciproquement). Cette valeur, comprise entre  $[-100,100]$ , correspond au pourcentage de la vitesse maximale à appliquer ainsi qu'au sens de rotation. Le but de l'expérimentation est de montrer la capacité d'Alex à apprendre des comportements complexes à partir de l'observation des actions de l'utilisateur. Pour ce faire, l'utilisateur peut montrer un ensemble de comportements dans l'arène qu'Alex doit réussir à imiter. L'expérience est réalisée à la fois sur un robot virtuel et sur un robot réel.

En accord avec la vision *XS Robotic*, une instance d'Alex est associée à chaque roue leur permettant d'agir de manière autonome. Il n'existe aucune communication explicite entre les deux roues. Le rôle d'une instance d'Alex est alors d'apprendre à contrôler une roue en corrélant l'activité de l'utilisateur aux perceptions qu'il reçoit de la caméra. À chaque étape de décision, Alex reçoit les observations de la caméra ainsi que l'action réalisée par l'utilisateur. Un cycle de décision intervient

tous les 250 ms. La même implémentation d'Alex est utilisée à la fois en simulation et dans l'application réelle. OpenCV est utilisé sur les deux applications pour effectuer le traitement d'images. L'expérience est simulée sous Webots™. L'expérience réelle a été réalisée grâce à un robot Boe-Bot basé sur une plateforme Arduino et l'utilisation d'un protocole de communication Xbee. Une des activités que l'utilisateur peut réaliser dans l'arène est une tâche de collecte d'artefacts. Le robot est muni de deux branches solides permettant la capture de petits objets. Ces branches sont fixes et ne comportent aucun capteur. Le but de l'activité est alors de capturer les artefacts verts et de les transporter dans la zone bleue. À chaque fois qu'un artefact est déposé dans la zone bleue il est soit, dans la simulation, téléporté aléatoirement dans l'arène, soit déplacé par l'utilisateur dans l'application réelle. Les résultats présentés ont été obtenus à partir des simulations et constatés sur l'expérimentation réelle. L'expérimentation se propose d'illustrer le processus d'adaptation durant les démonstrations et les phases d'autonomie.

#### 4.1 L'activité du tuteur permet la création d'agent contextes

La figure 2 montre la trajectoire suivie par le robot pendant une phase de démonstration du comportement de collecte. Dans cette démonstration, le tuteur prend le contrôle du robot et le conduit afin de capturer l'artefact




Figure 2 – Trajectoire du robot et zones de création d'agents contextes.

vert puis le ramener vers la zone bleue. Chaque point correspond à la création d'un agent contexte par l'une des deux instances d'Alex. En observant la figure, on constate que les agents contextes ne sont créés qu'au cours de changements de direction par le tuteur. A l'inverse, quand le tuteur maintient sa direction, aucun agent contexte n'est créé. Alex observe chaque action du tuteur et détermine si celle-ci appartient à un contexte existant ou à un nouveau contexte. La création de nouveaux agents contextes résulte donc de l'observation de l'activité du tuteur.

#### 4.2 L'activité du tuteur permet l'adaptation des agents contextes

La figure 3 montre la structure d'un agent contexte particulier à sa création (3.a) et à la fin d'une démonstration (3.b). Chaque ligne correspond à la structure d'une plage de validité associée à une observation. Les plages les plus claires correspondent à la zone *valide*, les plus foncées à la zone *validable*. Le curseur blanc représente la valeur courante du signal. À sa création (3.a), l'agent contexte initialise ses plages de validité pour représenter la situation courante et est associé avec l'action courante du tuteur. Tant que l'action proposée par cet agent contexte est en adéquation avec celle du tuteur, l'agent contexte adapte ses plages de validité. Les plages de validité à la fin de la démonstration (3.b) sont la résultante d'un processus d'auto-organisation initié par le tuteur et représente l'expérience vécue par cet agent contexte. En observant plus précisément l'évolution des plages de validité, on se rend compte que les plages étiquetées *BlueA* et *BlueD* sont plus larges que celles étiquetées *GreenA* et *GreenD*. Cela signifie que ce contexte particulier est bien plus sensible aux variations des données liées à l'artefact vert qu'aux données liées à l'artefact bleu. Ce contexte particulier est valide lorsque l'artefact vert est proche de l'avant du robot et que le robot est face à la zone bleue. Il est donc impliqué dans la phase de l'activité où le robot ramène l'artefact capturé dans la zone bleue.

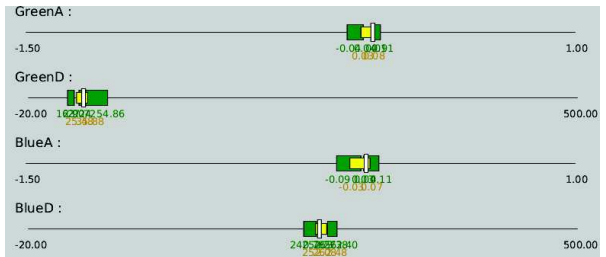


Figure 3.a – Domaine de validité d'un agent contexte à sa création

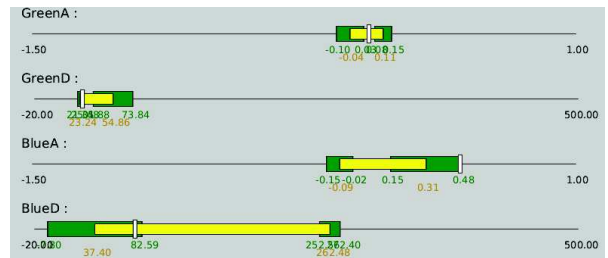


Figure 3.b – Domaine de validité du même agent contexte à la fin de la démonstration

#### 4.3 De la démonstration du tuteur naît l'autonomie

Pour observer la capacité d'Alex à imiter les performances du tuteur, celui-ci réalise une démonstration de 5 minutes au cours de laquelle un certain nombre d'artefacts (nommés *boîtes*) sont collectés. Le nombre de boîtes collecté par le tuteur sert alors de métrique pour observer la capacité d'Alex à proposer des performances semblables à celle du tuteur. Au bout de 5 minutes, le système agit de manière autonome, c'est-à-dire que le tuteur n'intervient plus sur le système. Le nombre de boîtes collectées est calculé toutes les 5 minutes.

La figure 4 montre le résultat obtenu au cours d'une de ces expérimentations. Au pire cas, le système autonome réalise la tâche aussi bien que le tuteur : 12 boîtes sont collectées. En moyenne, le système parvient à collecter 14 boîtes. Deux facteurs influencent ce résultat. Le premier vient du caractère aléatoire du déplacement de la boîte, la distance à parcourir pour collecter une boîte variant. L'autre facteur réside dans le fait que le tuteur suit un processus décisionnel plus lent que le système. Alex est ainsi capable de réagir plus vite que le




Figure 4 – Nombre de boîtes collectées toutes les 5 minutes. Le pas 0 correspond au score de référence.

tuteur à un changement de situation. De plus, le tuteur peut au cours de la démonstration se contredire. Ce phénomène est observable sur la figure 2. A la moitié du chemin entre la position de départ et l'artefact vert, on peut observer un changement de trajectoire. Ce changement est en fait une erreur de téléopération du tuteur. Les agents contextes créés pour représenter cette situation posséderont une valeur de confiance faible, leur action n'étant jamais reproduite par le tuteur. Le comportement appris par Alex ne retenant que les propositions d'action des agents les plus confiants, les agents contextes issues de ces erreurs ne seront jamais sélectionnés et permettent à Alex de réaliser la tâche de manière plus efficace.

#### 4.4 Synthèse

Cette expérimentation permet d'illustrer le mécanisme d'auto-organisation des agents contextes au micro-niveau qui conduit à la l'observation d'un comportement complexe au macro-niveau. Le processus d'auto-organisation est la résultante de l'interaction entre les instances d'Alex et le tuteur. Les expérimentations réalisées à la fois en simulation et sur un robot réel ont permis de mettre en avant des propriétés qui différencient Alex des approches traditionnelles:

**Généricité** : le processus d'apprentissage est indépendant de la tâche à réaliser et ne nécessite pas de sémantique sur les signaux.

**Ouverture** : de nouveaux signaux peuvent être dynamiquement intégrer dans le processus d'apprentissage.

**Distribution** : l'auto-observation permet à chaque fonctionnalité d'être autonome dans son apprentissage tout en restant collaborative.

**Temps réel** : l'auto-organisation est réalisée sans interrompre l'activité du système en collaboration avec le tuteur.

## 5 Conclusion

Cet article traite de l'apprentissage par démonstration en système ambiant. Il présente Alex, un système multi-agent conçu pour apprendre un comportement à partir des démonstrations réalisées par un tuteur. Les expériences réalisées montrent la capacité d'Alex à apprendre de l'interaction avec son tuteur. Cela signifie concrètement que la simple démonstration d'une activité permet à chaque système multi-agent associé à chacun des effecteurs du système de comprendre de manière autonome quelles sont les données pertinentes pour imiter collectivement le comportement de son tuteur sans aucune forme de contrôle centralisé.

L'expérimentation montre que deux instances d'Alex peuvent coopérer sans nécessité de communication directe entre elles. Le fait que chacune des instances corrèle son activité avec les variations de son environnement suffit pour que les deux systèmes agissent de manière coopérative. Cet article présente une preuve de concept illustrant qu'un système multi-agent capable d'apprendre à partir de l'auto-observation de son contexte (*context-learning*) est une réponse adéquat à la complexité inhérente aux systèmes ambiants. Cette approche présente un intérêt particulier pour des applications dont la spécification ne peut être complètement réalisée *a priori*.

Forts de ces résultats, les travaux en cours portent sur l'application de cette technologie dans un contexte industriel. Dans cette perspective et en partenariat avec plusieurs industriels, nous utilisons Alex en robotique collaborative pour le contrôle de bras robotisés dans un contexte industriel, mais aussi pour des applications grand public.

Enfin, nous désirons à la fois formaliser notre approche pour l'inclure dans une théorie de l'apprentissage multi-agent contextuelle et comparer les performances de notre approche avec d'autres techniques d'apprentissage à la pointe de l'état de l'art.

## Références

- Argall, Brenna D., Chernova, Sonia, Veloso, Manuela, et al. A survey of robot learning from demonstration. *Robotics and autonomous systems*, vol. 57, no 5, p. 469-483, 2009.
- Billard, Aude, et al. "Robot programming by demonstration." *Springer handbook of robotics*, p. 1371-1394, 2008.
- Billing, Erik A. et Hellström, Thomas. A formalism for learning from demonstration. *Paladyn*, vol. 1, no 1, p. 1-13, 2010.
- Bonjean, Noëlie, et al. "ADELFE 2.0." *Handbook on Agent-Oriented Design Processes*. Springer Berlin Heidelberg, p. 19-63, 2014.
- Capera, Davy, et al. "The AMAS theory for complex problem solving based on self-organizing cooperative agents." *Proceedings of Twelfth IEEE International Workshops on Enabling Technologies: Infrastructure for Collaborative Enterprises* IEEE, 2003.
- Collinot, A., Drogoul, A., & Benhamou, P. Agent oriented design of a soccer robot team. *In Proceedings of the Second International Conference on Multi-Agent Systems*, pp. 41-47, 1999.
- Chung, Joohyun. Ambient robotics for meaningful life of the elderly. *Advanced Construction and Building Technology for Society*, 2014.
- Ferber, J. *Multi-agent systems: an introduction to distributed artificial intelligence*, Vol. 1, 1999.
- Gleizes, Marie-Pierre. Self-adaptive complex systems. *Multi-Agent Systems*. Springer Berlin Heidelberg, p 114-128, 2012.
- Guivarch, Valérian, et al. Self-Adaptation of a Learnt Behaviour by Detecting and by Managing User's Implicit Contradictions. *Proceedings of the 2014 IEEE/WIC/ACM International Joint Conferences on Web Intelligence (WI) and Intelligent Agent Technologies (IAT)*, vol. 3. IEEE Computer Society, 2014.
- Hagras, H., Callaghan, V., Colley, M., Clarke, G., Pounds-Cornish, A., & Duman, H. Creating an ambient-intelligence environment using embedded agents. *Intelligent Systems*, IEEE, vol. 19, no 6, p.12-20, 2004.
- Kaminka, G. A. Autonomous agents research in robotics: A report from the trenches. *AAAI Spring Symposium Series*, 2012.
- Kearns, M. J., Schapire, R. E., & Sellie, L. M. Toward efficient agnostic learning. *Machine Learning*, vol. 17, no 2-3, p. 115-141, 1994.
- Lacouture, Jérôme, et al. Rosace: Agent-based systems for dynamic task allocation in crisis management. *Advances on Practical Applications of Agents and Multi-Agent Systems*. Springer Berlin Heidelberg. p. 255-259, 2012.
- Lemouzy, S., Camps, V., & Glize, P. Principles and properties of a mas learning algorithm: A comparison with standard learning algorithms applied to implicit feedback assessment. *Web Intelligence and Intelligent Agent Technology*. IEEE, vol. 2, p. 228-235, 2011.
- Makkonen Jarmo, Avdouevski Ivan, Kerminen Riitta and Visa Ari. Context Awareness. *Human-Computer Interaction*, Inaki Mautua (Ed.), ISBN: 978-953-307-022-3, InTech, DOI: 10.5772/7743, 2009.
- Panait, L., & Luke, S. Cooperative multi-agent learning: The state of the art. *Autonomous Agents and Multi-Agent Systems*, vol. 11, no 3, 387-434, 2005.
- Parker, Lynne E. Current state of the art in distributed autonomous mobile robotics. *Distributed Autonomous Robotic Systems 4*. Springer Japan, p. 3-12, 2000.
- Picard, Gauthier, and Marie Pierre Gleizes. Cooperative self-organization to design robust and adaptive collectives. *ICINCO*. 2005.
- Russell, S., Norvig, P., & Intelligence, A. A modern approach. *Artificial Intelligence*. Prentice-Hall, Englewood Cliffs, vol. 25, 1995
- Souliman, A., Joukhadar, A., Alturbeh, H., & Whidborne, J. F. Intelligent Collision Avoidance for Multi Agent Mobile Robots. *In Intelligent Systems for Science and Information*. Springer International Publishing, p. 297-315, 2014
- Verstaevl, N., Régis C., Guivarch, V., Gleizes, M.P., Robert, F. Extreme Sensitive Robotic: A Context-Aware Ubiquitous Learning. *Proceedings of the 2015 International Conference on Agents and Artificial Intelligence*, vol. 1, p. 242-248, 2015.