

SELF ORGANIZED ROBOTIC MANUFACTURING SYSTEM

Trimoulet David¹, Madeleine El Zaher¹, Irwin Issury², M'hammed Shanoun³, Céline Viazzi¹

¹ LINEACT, Laboratoire du CESI, 16 rue Magellan, 31670 Labège.

²LINEACT, Laboratoire du CESI, 60 rue de Maurian, 33290 Blanquefort

³ LINEACT, Laboratoire du CESI, 1 rue G. Marconi, 76130 Mont Saint Aignan

Mots clés : Usine du futur, Robotique, Auto-organisation, Système Multi Agents, Système Multi Robots.

Abstract : la révolution numérique touche maintenant l'industrie. Un des enjeux majeurs de cette révolution est l'utilisation massive des données et des opérateurs robotiques. De nombreux travaux de recherche visent à développer des algorithmes ou des méthodes permettant l'implantation d'opérateurs au sein de chaînes de production. Au travers de cet article, nous présentons une architecture permettant une auto-organisation des opérateurs robotiques de la chaîne de production par un algorithme de négociation par enchère. Nous utilisons également un algorithme d'apprentissage automatique pour permettre d'optimiser la négociation des robots.

1. INTRODUCTION

Notre façon de consommer a provoqué une évolution conséquente des marchés. En effet, d'une demande massive de produits standardisés les consommateurs se tournent maintenant vers la nécessité d'avoir des produits personnalisés et plus adaptés à leurs besoins. Cela a un impact sur les systèmes de production qui doivent pouvoir supporter la fabrication de produits unitaires ou de très petites séries. C'est pourquoi nous voyons émerger des systèmes de production reconfigurables et flexibles [1] :

- Une chaîne de production reconfigurable est un ensemble de machines-outils ayant la capacité de produire une famille de produits via la reconfiguration d'une ou de plusieurs machines. Elles sont donc plus polyvalentes que les systèmes de production dédiés mais elles ont un coût d'achat plus important et nécessitent une maintenance plus importante. Enfin, elles ont une cadence similaire à une chaîne de production dédiée[2].
- Une chaîne de production flexible est un ensemble de machines-outils polyvalentes de type « Computer Numerical Control » CNC. Ces machines ont la capacité de produire n'importe quel produit sans nécessité de reconfiguration. Les principaux freins à l'adoption de ces systèmes sont le fort coût d'acquisition et le faible rendement[3].

Pour aborder la notion de système de production, les opérations de manutention et de convoyage sont, entre autre, prise en considération. Ainsi, en parallèle des travaux concernant uniquement la chaîne de production, plusieurs équipes de recherche ont travaillé à l'intégration d'opérateurs robotisés destinés à des opérations de manutentions ou le remplacement de systèmes de convoyage[4]. L'utilisation de ces opérateurs permet entre autre d'optimiser le rendement et de

réduire les coûts de main d'œuvre, permettant aux opérateurs de se consacrer à des missions à plus forte valeur ajoutée[5].

Suite à ces constats, il paraît essentiel de trouver des stratégies pour le système de production qui permettront de rendre autonome l'organisation et la réalisation des opérations sur une chaîne de production flexible associant des opérateurs robotiques. En effet, il ne s'agit pas d'additionner ces deux principes mais véritablement de déterminer un mode de fonctionnement et de collaboration optimisé. Il est possible de répondre à ce besoin à l'aide d'un Système Multi Robots (SMR) composé de robots de transport, de produits intelligents et de machines flexibles. Ce Système Multi Robots aura la possibilité de s'auto-organiser et de se coordonner afin d'optimiser le rendement de la chaîne de production flexible. Plus précisément, il est possible d'appliquer les stratégies sur un processus précis de la production comme par exemple la planification, le transport ou la fabrication.

Plusieurs équipes ont travaillé à l'optimisation de l'un de ces processus comme, par exemple, des Automatic Guided Vehicles (AGV) qui assurent le transport des ressources aux machines[6] ou des Système Multi Agents (SMA) permettant d'améliorer la planification de la production et l'occupation des machines[7].

Le but de ces travaux sera de proposer l'utilisation d'un SMR qui aura la possibilité de réaliser non pas un seul, mais l'ensemble des processus de production en toute autonomie. Ainsi, l'utilisation d'opérateurs informatisés constituant le SMR permettra d'optimiser le temps de production, le rendement des machines, et le coût de fabrication.

2. MODELE ET METHODE

Le système sera basé sur une architecture complètement décentralisée, composée d'un ensemble d'agents cognitifs, à l'opposé de réactifs, ayant plusieurs missions. L'utilisation d'un SMR génère des problématiques de coordination entre robots et de partage d'environnement. Pour faire face à ces problématiques, les robots proposés doivent être capables de s'auto-organiser, de planifier, et de négocier entre eux.

Pour permettre d'évaluer notre solution, nous allons définir une architecture *d'usine du futur* dans laquelle évoluera notre flotte robotique. Ce système sera composé de 4 entités [Figure 1] :

- un planificateur qui gèrera l'ordonnancement de la production ;
- des produits intelligents qui informeront le planificateur et les robots de leurs états ;
- des robots mobiles qui déplaceront les produits ;
- des machines-outils qui communiqueront avec les robots mobiles pour gérer leur disponibilité et leur occupation.

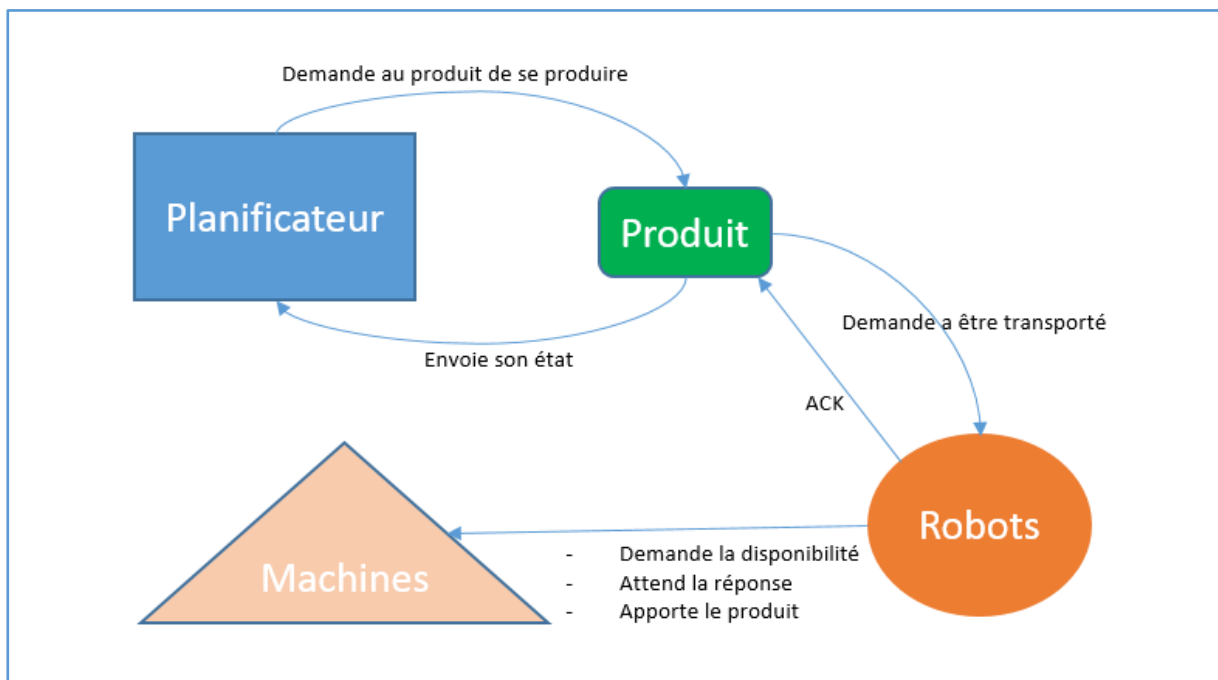


Figure 1: vue d'ensemble du modèle de l'Usine du Futur utilisé.

Dans cet article, nous nous concentrerons sur l'auto-organisation des robots de transport. Les robots de transports recevront des demandes des produits ayant 'besoin' de se faire confectionner et assureront le transport tout au long de la chaîne de production. Pour optimiser le transport de produit, les différents agents réaliseront des négociations basées sur leur localisation, leur état et leur capacité de charge. Un système multi agent cognitif[8] sera utilisé pour modéliser le comportement de ces robots et leurs interactions dans un environnement d'usine du futur.

Afin de pouvoir tester notre solution, nous utiliserons une simulation de chaîne de production flexible réalisée avec le moteur Unity 3D dans laquelle un SMR s'auto organisera pour la réalisation d'ordre de production. Dans de futurs travaux, il sera nécessaire de valider les résultats de notre simulation à l'aide d'une plateforme robotique et d'une chaîne de production flexible.

3. NEGOCIATION ET PRISE DE DECISION DES ROBOTS MOBILES

A. CADRE GENERAL

Afin de pouvoir concevoir un SMR, il est indispensable de penser aux éléments constitutifs du système. Un SMR doit prendre en compte [9-12]:

- le type de robot : manipulateurs, robots mobiles, robots humanoïdes ;
- le type du système : hétérogène ou homogène ;
- le(s) type(s) de coordination : statique/dynamique et implicite/explicite ;
- le(s) type(s) de communication : implicite ou explicite ;
- le mode d'organisation : compétitive ou collaborative ;
- le mode de prise de décision : centralisé ou décentralisé.

Pour notre étude, il est considéré que le système multi robots étudié aura les caractéristiques suivantes :

- il sera composé de robots mobiles et de manipulateurs ;
- ce sera un système hétérogène, les opérateurs n'auront pas tous les mêmes rôles et fonctionnalités ;
- la coordination sera dynamique explicite entre les robots, ils communiqueront par message et dynamique implicite avec les humains, ils réagiront à leur présence sans pour autant envoyer ou recevoir de message ;
- les communications seront implicites et explicites ;
- le mode d'organisation sera compétitif ;
- la prise de décision sera centralisée.

Afin de permettre la communication et la coordination, tous les robots sont connectés à un réseau WIFI dédié pour assurer qualité et fiabilité des échanges.

Bien que notre système soit hétérogène, nous nous baserons sur la même architecture logicielle pour tous les robots qui est détaillé dans la Figure 2.

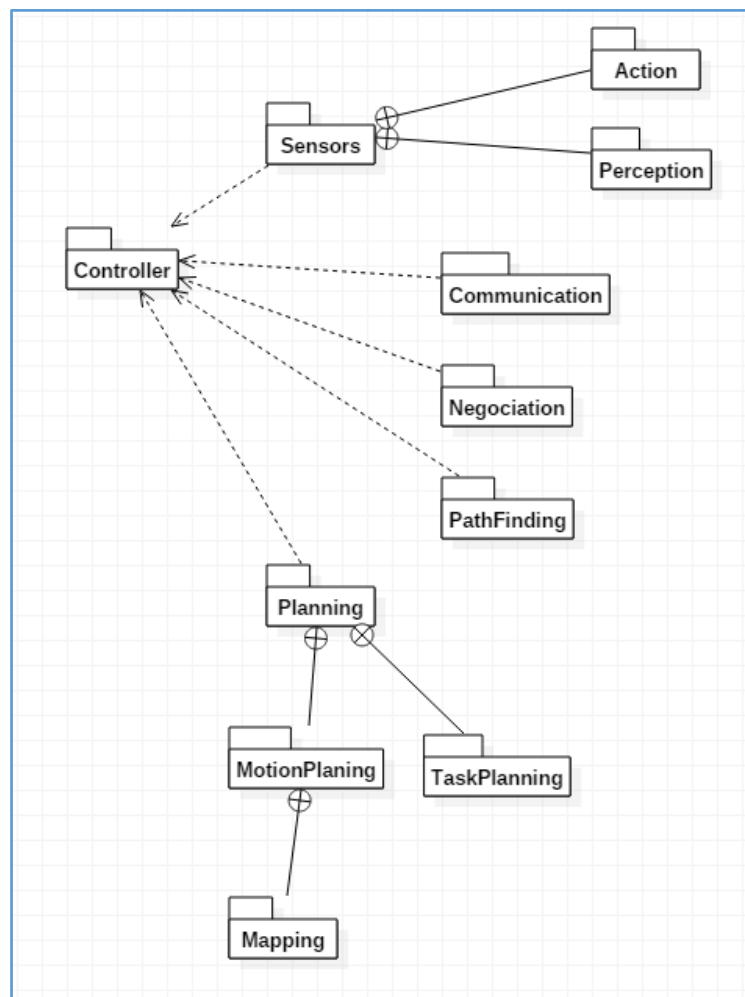


Figure 2 : diagramme de package du programme du robot.

Les robots utilisés à l'heure actuelle dans des systèmes de production sont programmés pour effectuer des parcours à partir de modèles simplifiés ne permettant pas de prendre en compte tous

les paramètres aléatoires de l'environnement. Ils sont, bien-sûr capables de stopper leur activité lorsqu'ils identifient un danger ou une non-conformité dans le processus.

Les concepts d'auto-apprentissage commencent à être exploités dans ce domaine [13-15]. C'est pourquoi ces travaux ont pour objectif de développer un algorithme de négociation entre les robots qui améliorera la performance du système de production via l'évaluation de la réussite d'un opérateur par un algorithme de *machine learning* ou d'auto-apprentissage.

B. SCENARIO

Au sein de l'usine du futur qui sera utilisée comme modèle pour cette étude, les produits définissent la cadence de production et le temps qu'ils « souhaitent » pour leur transport d'une machine de production à une autre. Les produits ont pour « besoin » d'être conçus au plus près de la cadence de production en fonction de la demande.

Le Figure 3 détaille les échanges réalisés par le produit avec les autres opérateurs de l'usine.



Figure 3: diagramme d'activité du produit.

Dans le cadre de notre système, les robots de transport sollicités par les produits devront négocier via un système d'enchères ouvertes avec plusieurs objectifs:

- minimiser la consommation d'énergie ;
- maximiser le nombre de missions réalisées ;
- minimiser l'écart entre le temps de transport par l'opérateur et le temps de transport souhaité par le produit.

Les estimations réalisées par les robots en amont de la négociation doivent être les plus précises possibles. Pour ce faire, elles doivent être capables de prendre en compte tous les événements qui peuvent se produire dans l'usine : déplacement d'un autre opérateur, point de congestion, zone difficile d'accès.

Les travaux dans le domaine [16 – 20] visent à :

- permettre aux robots de calculer la position des autres opérateurs en temps réel ;
- permettre de connaître la position actuelle et futur de tous les opérateurs par communication ;
- demander à un système centralisé de gérer les déplacements de la flotte au détriment de la fiabilité du système.

Ces différents éléments sont soit difficilement prévisibles, soit très coûteux en temps de calcul ou de transmission pour pouvoir être traités correctement par les opérateurs.

Notre approche propose d'intégrer une estimation basée sur un algorithme de *machine learning* (auto-apprentissage) pour pouvoir anticiper les perturbations que pourraient connaître le robot lors de son trajet et intégrer cette pondération dans le mécanisme de négociation. C'est donc une valeur pondérée par l'expérience qui sera utilisée.

Les bénéfices attendus sont de permettre au robot, qui sera effectivement le plus efficace, de remporter les enchères et de limiter les points de congestions dans l'usine.

Pour atteindre ces deux objectifs, nous proposons l'approche de négociation suivante :

- les enchères sont basées sur une estimation par l'agent de son niveau de réussite et sur le coût nécessaire en énergie électrique. Il s'inscrit à l'enchère et reçoit les inscriptions des autres robots ;
- il donne son estimation ayant le coût le plus faible pour réussir l'objectif et reçoit les offres des autres robots ;
- après avoir reçu les offres de tous les inscrits (ou après 2 secondes), il cherche son estimation la plus proche et supérieure à l'offre la plus haute ;
- s'il n'en a pas, il annonce qu'il quitte les enchères. Sinon il propose son estimation la plus proche et supérieure et refait une ronde ;
- le dernier robot à rester dans la liste des enchérisseurs remporte l'enchère et réalise la mission en fonction de la dernière estimation proposée.

La Figure 4 est un diagramme d'activité détaillant cet algorithme :

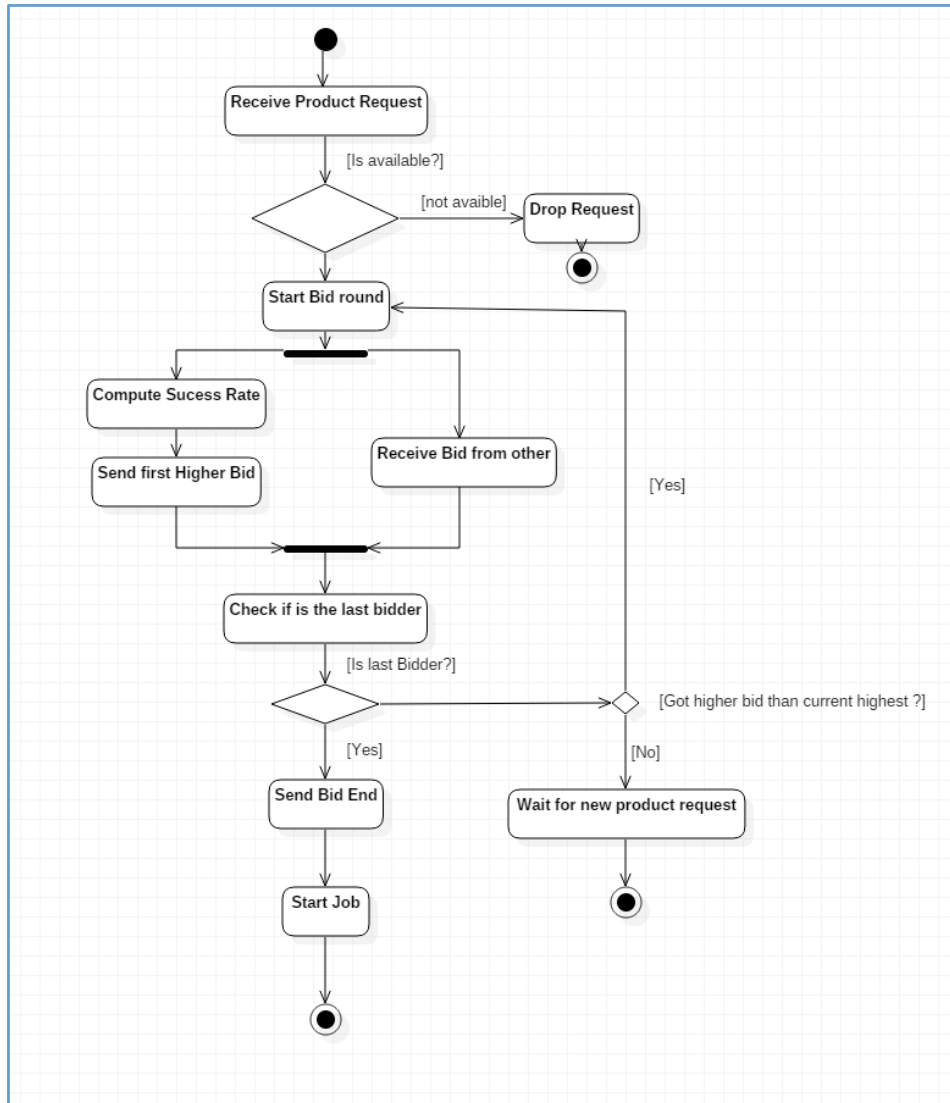


Figure 4 : diagramme d'activité des opérateurs mobiles.

C. APPLICATION

Afin de pouvoir calculer la valeur de ses enchères, le robot devra pour chaque demande établir plusieurs scénarii possibles avec les paramètres variables suivants :

- finalisation de la mission en cours ou transfert à un autre opérateur ;
- plusieurs niveaux de vitesses de réalisation (cout en énergie) ;
- 5 plus courts chemins ;
- plusieurs temps de trajet (rapport chemin / vitesse) ;
- charge actuelle et totale.

L'utilisation de cet échantillon de scénario permettra d'obtenir le meilleur ratio entre le coût de transport et le temps de transport.

Pour définir un temps de transport, l'intelligence des produits utilisera la formule suivante définie en tenant compte des opérations de traitement et des temps de transports :

$$t(n) = \frac{\left(\frac{\alpha}{n}\right) - \sum_{i=1}^n (\beta_i + \Omega_i)}{\eta}$$

t = temps de transport idéal (secondes)	β = temps de travail des machines (secondes)
n = nombre d'unités à produire	Ω = temps de transport déjà consommé
α = temps avant livraison (secondes)	η = nombre de traitement(s) restant(s) en dehors du transport ($\eta \neq 0$)

Pour calculer les valeurs des enchères, chaque robot va utiliser un algorithme de *machinelearning* pour avoir une estimation la plus réaliste possible. Le choix de cette stratégie de conception en programmation lui permettra ainsi de « prévoir » les éventuelles difficultés rencontrées et de s'appuyer sur ses connaissances ainsi que sur celles des autres robots. Pour ce faire, nous avons défini que le robot réalisera les actions suivantes :

- le robot s'appuiera sur un algorithme de PRM (Probabilistic RoadMap) via une décomposition en cellule pour définir les chemins possibles et la longueur de chaque. Le robot va décomposer la zone de travail analogique en un ensemble finit de case. Ensuite, via une approche probabiliste, il va chercher un des plus courts chemins entre son point de départ et sa destination ;
- il calculera les vitesses possibles allant de la plus lente à la plus rapide et le nombre de virage ;
- il prendra en compte le poids du produit et sa charge actuelle ;
- il obtiendra le temps théorique pour réaliser le trajet et le temps pour finaliser la mission en cours.

A partir de ces éléments, l'agent pourra prédire le coût de transport réel et l'écart avec le temps de trajet idéal. Ces deux valeurs permettront d'encoder la capacité du robot à remplir la mission en suivant la contrainte. A chaque phase d'inactivité, les robots échangeront leurs données pour enrichir l'expérience de tous.

Le problème prend donc la forme d'une équation prenant en compte les X paramètres et n coefficient θ permettant d'obtenir n résultats Y:

$$X_1 \quad X_2 \quad X_3 X_4 \quad \dots \quad X_n * \begin{matrix} \theta_1 \\ \theta_2 \end{matrix} = y_1 \quad y_2$$

Ce type de problème est résoluble par une régression linéaire multivariée, qui permettra d'obtenir les valeurs des coefficients θ à partir d'un échantillon de donnée représentatif et en minimisant l'erreur entre le jeu de donnée et les résultats obtenus. Ensuite il est possible de calculer précisément les valeurs de sortie (Y) à partir d'un échantillon de donnée et des coefficients précédemment calculés.

Les paramètres que le modèle prend en compte sont :

- longueurs du chemin (m) ;
- vitesse de trajet ($m.s^{-1}$) ;
- liste des nœuds parcourus (1 si utilisé, 0 si pas utilisé) ;
- coût de transport théorique ($COT = \frac{E}{mgd}$) théorique trajet ;
- temps avant fin de mission en cours (s) ;
- temps théorique pour réaliser la mission (s) ;
- poids du produit (kg) ;
- poids total de la charge (kg).

Résultat à évaluer

- E = Temps de trajet réel ;
- C = Coût de transport.

Chaque paramètre est normalisé pour permettre une convergence plus rapide vers la fonction de coût.

Afin de générer des données suffisantes et exploitables, les 100 premiers trajets de chaque robot utiliseront des valeurs idéales. Ces valeurs idéales seront ensuite remplacées par les données réelles à la fin de la mission.

4. Conclusion et perspectives

Le modèle théorique définit permet l'auto-organisation des différents robots au sein de l'usine et s'assure que l'opérateur qui réalisera la tâche est celui qui sera le plus efficace en fonction de la tâche à réaliser et de l'énergie consommée pour ce faire.

De plus l'approche *machine learning* ou d'auto-apprentissage qui a démontré sa pertinence dans les data science et de nombreuses autres applications, permet d'encoder simplement les incidents que peuvent rencontrer les robots dans leurs déplacements et les prendre en compte dès la planification des déplacements et la négociation de la mission. De cette manière, l'opération réalisée sera donc toujours la plus efficace avec un temps de calcul très courts.

Afin de s'assurer de la validité de l'approche et de pouvoir mesurer les résultats obtenus, il reste à pouvoir simuler (numériquement et physiquement) notre modèle.

Références

- [1] K. Y., «The global manufacturing revolution-product-process-business integration and reconfigurable systems.,» *John Wiley & Sons*, 2010.
- [2] S. M. Koren Y, «Design of reconfigurable manufacturing systems,» *Journal of Manufacturing Systems*, 2011.
- [3] D.-G. C., «A survey of flexible manufacturing systems. *Journal of Manufacturing Systems*,» 1981.

- [4] M. S. A. O. E. K. Hakan Gultekin, «Scheduling in a three-machine robotic flexible manufacturing cell,» 2005.
- [5] E. G. H.-M. e. al., «Hybrid Architecture for Coordination of AGVs in FMS,» *International Journal of Advanced Robotic Systems*, 2013.
- [6] S. G. e. al., «A distributed multi-agent production planning and scheduling framework for mobile robots,» 2012.
- [7] Y. Z. e. al., «Multi-agent based real-time production scheduling method for radio frequency identification enabled ubiquitous shopfloor environment,» 2013.
- [8] J. Ferber, «Les Syst`emes Multi Agents: vers une intelligence collective,» 1995.
- [9] S. J. R. a. P. Norvig, «Artificial Intelligence: A Modern Approach (2nd Edition),» *Prentice Hall*, 2002.
- [10] M. R. M. J. E. M. a. D. W. Gregory Dudek, «A taxonomy for multiagent robotics,» *Autonomous Robots*, pp. 375-397, 1996.
- [11] L. I. a. D. N. Alessandro Farinelli, «Multi-robot systems: A classification focused on coordination,» *IEEE Transactions on Systems, Man, and Cybernetics*, 2004.
- [12] J. d. L. a. D. M. Yadira Quinonez, «Cooperative and Competitive Behaviors in a Multi-robot System for Surveillance Tasks,» *Perception for Computer and Robots*, 2009.
- [13] M. W. Otte, «A Survey of Machine Learning Approaches to Robotic Path-Planning,» 2012.
- [14] G. B. Nicol Naidoo, «Support Vector Machine Learning in Multi-Robot Teams,» *ICAS 2015 : The Eleventh International Conference on Autonomic and Autonomous Systems*, 2015.
- [15] Y. E. B. L. D. M. a. E. M. R.C. Arkin, «MULTISTRATEGY LEARNING METHODS FOR MULTIROBOT SYSTEMS,» 2006.
- [16] B. N. M Jäger, «Decentralized collision avoidance, deadlock detection, and deadlock resolution for multiple mobile robots,» 2001.
- [17] P. T. J. S. V. R. a. A. S. Hugo Costa, «Simulation of a system architecture for cooperative Robotic Planning,» *Robot 2015: Second Iberian Robotics Conference: Advances in Robotics*, 2015.
- [18] L. S. M. a. L. Chaimowicz, «Traffic control for a swarm of robots: Avoiding group Conflicts,» 2009.
- [19] R. L. a. K. E. Bekris, «Efficient and complete centralized multi-robot path planning,» 2011.
- [20] A. F. F. a. P. E. Trahanias, «Predictive autonomous robot navigation,» 2002.

Contact principal : Trimoulet David

Coordonnées : dtrimoulet@cesi.fr