

Intelligence Artificielle Modulaire et Hybride Orientée par les Objectifs : Application à la Simulation d'un Calculateur Booléen Plasmonique

Ouassila Labbani Narsis¹, Erik Dujardin², Christophe Nicolle¹

¹ CIAD UR 7533, Université de Bourgogne, UB, F-21000 Dijon, France

² ICB CNRS UMR 6303, Université de Bourgogne, UB, F-21000 Dijon, France

{ouassila.narsis, erik.dujardin, cnicolle}@u-bourgogne.fr

Cet article résume les travaux de recherche publiés lors d'une conférence internationale [5].

L'intelligence artificielle hybride est en plein essor, notamment les approches combinant des ontologies et des modèles d'apprentissage automatique [2]. Les modèles hybrides proposés dans la littérature promettent des systèmes performants en matière d'apprentissage à partir de données, tout en possédant également des connaissances structurées et des capacités d'inférence leur permettant de prendre des décisions éclairées. De manière globale et simplifiée, les modèles d'hybridation peuvent être regroupés en trois grandes catégories : *Learning and Reasoning System*, *Semantic Data Mining* et *Learning-Enhanced Ontology* [4].

La catégorie **Learning and Reasoning System** regroupe les travaux combinant l'apprentissage automatique et les ontologies pour résoudre des problèmes complexes et effectuer des tâches spécifiques dans le même domaine. Ces systèmes se divisent en deux principales sous-catégories : *Expert System Embedded Learning* et *Hybrid Application*. La sous-catégorie *Expert System Embedded Learning* utilise l'apprentissage automatique comme un sous-programme pour analyser et apprendre à partir des données en vue d'améliorer le fonctionnement global du système, tandis que la sous-catégorie *Hybrid Application* propose des approches qui relient l'apprentissage automatique aux connaissances ontologiques pour classifier les données, peupler l'ontologie ou raisonner sur les données pour analyser, valider et corriger les résultats d'apprentissage. D'autres approches transforment les entités ontologiques en données manipulables par les algorithmes d'apprentissage automatique et utilisent les relations sémantiques de l'ontologie pour former des réseaux neuronaux experts.

Les études de la catégorie **Semantic Data Mining** visent à intégrer des connaissances du domaine dans le processus d'apprentissage automatique afin d'améliorer son efficacité. Elles se divisent en deux principales sous-catégories : *Informed Machine Learning* et *Ontologies Explain Black-Box*. La sous-catégorie *Informed Machine Learning* intègre les connaissances préalables dans différentes phases de l'apprentissage automatique, telles que la sélection, l'extraction ou l'augmentation des caractéristiques, ainsi que dans

le choix de la structure du modèle. Les connaissances préalables sont représentées dans une ontologie et utilisées pour enrichir le processus d'apprentissage. La sous-catégorie *Ontologies Explain Black-Box* a pour objectif d'ajouter a posteriori de l'explicabilité aux modèles d'apprentissage en utilisant les connaissances d'une ontologie. L'explication peut être sur la prise de décision globale par le modèle ou localement pour chaque individu.

La catégorie **Learning-Enhanced Ontology** regroupe les travaux visant à améliorer l'utilisation des ontologies grâce à l'apprentissage automatique. Elle se divise en trois sous-catégories principales. La première est l'*Ontology Learning* où la création et la maintenance des ontologies sont (en partie) automatisées grâce à l'apprentissage machine. La seconde sous-catégorie, *Ontology Mapping*, cherche à améliorer l'alignement des ontologies grâce à l'apprentissage automatique, en garantissant une interopérabilité entre les deux modèles. La troisième sous-catégorie *Learning-based Reasoning* regroupe les approches visant à faciliter le raisonnement déductif d'une ontologie grâce à l'apprentissage automatique.

Cette étude des travaux existants met en évidence l'importance et la nature évolutive des approches d'hybridation en intelligence artificielle intégrant l'apprentissage automatique et le raisonnement ontologique. Malgré les avancées dans ce domaine, cette combinaison soulève le défi de leur intégration efficace due à la rigidité des modèles existants [2, 6]. Ces derniers, souvent basés sur un pipeline séquentiel et une ontologie globale, peinent à s'adapter à des contextes variés et à évoluer selon les besoins [1]. Il est souvent difficile de modifier ces approches existantes pour tenir compte des nouveaux besoins ou des changements dans les données et les connaissances.

Pour répondre à ces limites, nous proposons une approche modulaire et hybride visant à améliorer l'adaptabilité et la flexibilité par l'intégration de multiples modèles d'apprentissage et d'ontologies selon les spécificités des tâches. Cette stratégie a pour but de créer des modèles d'intelligence artificielle hybrides centrés sur les objectifs plutôt que sur l'ensemble du système. Elle vise également à faciliter la maintenance et l'évolution des différentes tâches de

l'application de manière indépendante, tout en simplifiant le choix des technologies d'intelligence artificielle adaptées à chaque module. Ce concept est illustré dans le cadre de la conception d'une unité arithmétique et logique plasmonique complexe et reconfigurable (projet [ANR DALHAI](#)). Il est appliqué dans le développement d'une architecture hybride qui visent à découvrir les meilleures configurations géométriques (formes), ainsi que les paramètres physiques d'excitation (propagation lumineuse), afin de détecter les portes logiques appropriées. Il s'agit dans ce cas d'un problème d'optimisation multi-objectifs qui implique une modélisation précise et une évaluation attentive des solutions proposées [3]. La résolution de ce type de problèmes implique l'utilisation de méthodes d'optimisation et de techniques d'apprentissage automatique pour trouver des solutions possibles et de les évaluer en fonction de critères de performance spécifiques et de contraintes du domaine. Notre architecture modulaire et hybride est composée de modèles d'apprentissage automatique, pour la génération de solutions optimales, et de modèles de raisonnement ontologique pour vérifier si la solution sélectionnée est réalisable selon les connaissances et les contraintes physiques définies par les experts du domaine. Dans ce cas, la partie d'apprentissage automatique peut être vue comme un *générateur* qui propose des solutions, tandis que la partie ontologique peut être assimilée à un *discriminateur* qui évalue la faisabilité de la solution et, si nécessaire, propose des ajustements au modèle d'apprentissage. Nous avons choisi d'utiliser un algorithme génétique évolutionnaire [7], adapté aux problèmes d'optimisation multi-objectifs, pour optimiser la forme et les paramètres d'excitation. Selon les portes logiques souhaitées, l'algorithme génère une forme sur laquelle sera appliquée une simulation numérique de la propagation du champ laser sur la structure en utilisant l'outil *PyGDM*. Cet algorithme inclut un deuxième algorithme évolutionnaire dont le rôle est d'optimiser les paramètres d'excitation (la position, la polarisation et la phase du laser) pour une forme particulière. Chaque solution fournie par l'algorithme génétique doit respecter les contraintes de la physique définies par les experts du domaine afin d'assurer la reproduction des résultats en expérimentation. Nous avons identifié trois principaux types de connaissances à mettre en place pour la définition de : (1) la forme, (2) les paramètres d'excitation, et (3) les paramètres de détection des portes logiques. Ceci nous a conduit à la définition de trois ontologies pouvant être développées et évoluées séparément. La première, *Ontologie de forme*, rassemble les connaissances et les contraintes liées à la description de la forme selon les contraintes imposées par la physique. La deuxième ontologie, *Ontologie de paramètres d'excitation*, concerne les paramètres d'excitation (points d'entrée, paramètres de laser, points de sorties, etc.). Elle correspond aux connaissances physiques liées à la faisabilité réelle de l'expérimentation, comme l'emplacement des deux lasers qui doivent respecter une certaine distance l'un par rapport à l'autre, ou la différence entre deux polarisations permettant d'encoder les états binaires en entrée, sans ambiguïté. La troisième ontologie, *Ontologie de porte logique*, est uti-

lisée pour capturer les connaissances sur les portes logiques (leur table de vérité) et leur assemblage (dans le cas où la fonction logique requiert plusieurs valeurs binaires simultanées en sortie). Son objectif est de vérifier l'assemblage correct entre les points d'entrée et de sortie afin de s'assurer que le résultat obtenu correspond bien aux portes logiques souhaitées. Le résultat de raisonnement des trois ontologies peut être également utilisé pour apporter des ajustements aux paramètres de modèle d'apprentissage, permettant ainsi d'avoir un modèle de raisonnement hybride performant, efficace et plus rapide, favorisant l'utilisation des techniques d'intelligence artificielle les mieux adaptées sur un sous-ensemble de données et de connaissances spécifiques à chacune de ses étapes de fonctionnement. Les résultats de l'application de notre approche modulaire et hybride dans le cadre de ce projet sont accessibles à ce [lien](#).

Remerciements

Les auteurs souhaitent remercier le projet DALHAI (Design of plasmonic ALU by Hybrid Artificial Intelligence), financé par l'Agence Nationale de la Recherche (ANR-20-CE240001 DALHAI).

Références

- [1] Fernando Almaguer-Angeles, John Murphy, Liam Murphy, and A Omar Portillo-Dominguez. Choosing machine learning algorithms for anomaly detection in smart building iot scenarios. In *2019 IEEE 5th World Forum on Internet of Things (WF-IoT)*, pages 491–495. IEEE, 2019.
- [2] Anna Breit, Laura Waltersdorfer, Fajar J Ekaputra, Marta Sabou, Andreas Ekelhart, Andreea Iana, Heiko Paulheim, Jan Portisch, Artem Revenko, Annette ten Teije, et al. Combining machine learning and semantic web : A systematic mapping study. *ACM Computing Surveys*, 2023.
- [3] Yann Collette and Patrick Siarry. *Optimisation multiobjectif : Algorithmes*. Editions Eyrolles, 2011.
- [4] Sarah Ghidalia, Ouassila Labbani Narsis, Aurélie Bertaux, and Christophe Nicolle. Combining machine learning and ontology : A systematic literature review. *arXiv preprint arXiv :2401.07744*, 2024.
- [5] Ouassila Labbani Narsis, Erik Dujardin, and Christophe Nicolle. Objective-driven modular and hybrid approach combining machine learning and ontology. In *2023 15th International Congress on Advanced Applied Informatics Winter (IIAI-AAI-Winter)*, pages 300–305. IEEE, 2023. <https://hal.science/hal-04573042>.
- [6] Yuan Ren, Jeff Z Pan, and Yuting Zhao. Towards scalable reasoning on ontology streams via syntactic approximation. *Proc. of IWOD*, 2010.
- [7] Ryoji Tanabe and Hisao Ishibuchi. A review of evolutionary multimodal multiobjective optimization. *IEEE Transactions on Evolutionary Computation*, 24(1) :193–200, 2019.