

# IA neuro-symbolique pour l'interprétation granulaire des données des bases STUPS© et OTARIES© : défis applicatifs et perspectives

S. Guillemin<sup>1</sup>, L. Dujourdy<sup>2</sup>, L. Journaux<sup>3</sup>, A. Roxin<sup>1</sup>

<sup>1</sup>Université de Bourgogne, Laboratoire d'Informatique de Bourgogne (LIB) EA 7534.

<sup>2</sup>Institut Agro Dijon – Cellule d'Appui à la recherche en science des données.

<sup>3</sup>Institut Agro Dijon, Laboratoire d'Informatique de Bourgogne (LIB) EA 7534.

sebastien.guillemin@u-bourgogne.fr, laurence.dujourdy@agro-dijon.fr,  
ludovic.journaux@agro-dijon.fr, ana-maria.roxin@u-bourgogne.fr

## Résumé

*Historiquement, l'intelligence artificielle (IA) s'est divisée en 2 courants selon les hypothèses faites pour modéliser l'intelligence humaine : l'IA symbolique, supposant que des symboles sont nécessaires, et l'IA statistique (plus particulièrement l'IA connexionniste) affirmant le contraire. Dernièrement, l'IA neuro-symbolique tente de réconcilier les 2. Les travaux présentés dans cet article sont en collaboration avec la Police Scientifique française, dans le contexte du Plan National Stup. Nous présentons les problématiques métiers en lien avec le projet, puis en déduisons les problématiques scientifiques. Après un rappel des domaines de l'IA et leurs limites, nous présentons un état des lieux du domaine de l'IA neuro-symbolique. Nous discutons les défis applicatifs avant de finir par une présentation des premiers travaux qui ont été conduits. Des pistes d'approches basées sur l'état des lieux de l'IA neuro-symbolique sont aussi présentées pour la suite des travaux.*

## Mots-clés

*Intelligence artificielle, IA neuro-symbolique, IA symbolique, IA connexionniste, aide à la décision.*

## Abstract

*Historically, artificial intelligence (AI) has been divided into two streams based on the assumptions made to model human intelligence: symbolic AI, which assumes that symbols are necessary, and statistical AI (more specifically, connectionist AI), which asserts the opposite. Recently, neuro-symbolic AI has attempted to reconcile the two. The work presented here is in collaboration with the French forensic police, in the context of the Stup National Plan. We present the domain-related issues involved, and then the related scientific issues. After reviewing the above-mentioned sub-domains of AI along with their limitations, we present an overview of neuro-symbolic AI. We discuss the application challenges before ending with a presentation of the first work that has been conducted. Possible approaches based on the state of the art of neuro-symbolic AI are also presented for further work.*

## Keywords

*Artificial intelligence, Symbolic AI, Connectionist AI, Neuro-symbolic AI, decision support.*

## 1 Introduction

La lutte contre le trafic de drogue est une priorité pour le gouvernement français. Le ministère de l'intérieur a érigé cette lutte en l'une de ses trois priorités dès juillet 2020 [31]. Le Plan Stup français, publié en septembre 2019, prévoit 55 mesures, parmi lesquelles l'utilisation de nouveaux indicateurs pour mieux comprendre les usages des consommateurs et les méthodes des trafiquants.

Nos travaux se déroulent dans le cadre d'une thèse financée par le Ministère de l'Enseignement Supérieur, de la Recherche et de l'Innovation (MESRI) visant à combiner des techniques de l'intelligence artificielle (IA) symbolique et de l'IA connexionniste. Ces travaux concernent le domaine de l'identification des filières de distribution de stupéfiants, plus précisément le rapprochement (ou appariement) automatique entre échantillons et la prédiction de tendances de dosage de principes actifs et de produits de coupage. Ils seront appliqués aux données contenues dans les bases STUPS© et OTARIES©. Pour en encadrer l'accès et l'usage, le projet de collaboration AI4NP (*Artificial Intelligence for Narcotic Prediction*) a été signé. Ce projet réunit le Laboratoire d'Informatique de Bourgogne (LIB), l'Institut Agro Dijon et le Service National de la Police Scientifique (SNPS).

La base de données nationale STUPS© (Système de Traitement Uniformisé des Produits Stupéfiants) du Ministère de l'Intérieur recueille des informations sur les drogues illicites circulant en France, incluant des données macroscopiques (e.g. logos de distributeurs de drogue, dimensions des produits etc.), qualitatives (e.g. noms des composants d'un échantillon de drogue) et quantitatives (e.g. dosages) ainsi que des données d'enquêtes non confidentielles (e.g. date, lieu de saisie). Cette base a été créée en 1986 et contient environ 10 millions d'entrées provenant des laboratoires de Police Scientifique du SNPS et de l'Institut de Recherche Criminelle de la

Gendarmerie Nationale. Cette base sert aux experts pour consulter des informations sur des échantillons analysés principalement pour faire le lien entre des affaires hors profilage chimique.

La base de données OTARIES© (Outil de Traitement Automatisé pour le Rapprochement InterEchantillons de Stupéfiants), créée en 2001, contient les profils chimiques des échantillons de cocaïne et d'héroïne analysés. Une méthode de profilage chimique exploite les informations issues de ces profils pour effectuer des rapprochements entre échantillons.

Cet article est structuré comme suit : la section 2 présente le contexte et les problématiques métier, par rapport auxquelles sont identifiées les problématiques scientifiques, exposées dans la section 3. La section 4 rappelle des définitions des domaines de l'IA symbolique et connexionniste ainsi que leurs limites, justifiant le choix de l'IA neuro-symbolique dont la section 5 présente un état de l'art. La section 6 discute des défis applicatifs du projet et la section 7 présente les premiers travaux ainsi que des pistes de futures approches basées sur les notions introduites dans la section 5.

## 2 Contexte et problématiques métiers

Lors d'une saisie de substances supposées illicites, des échantillons sont prélevés et analysés afin de déterminer le profil physico-chimique de la substance. L'analyse d'un échantillon s'effectue en 3 étapes, selon le processus illustré dans la Figure 1.

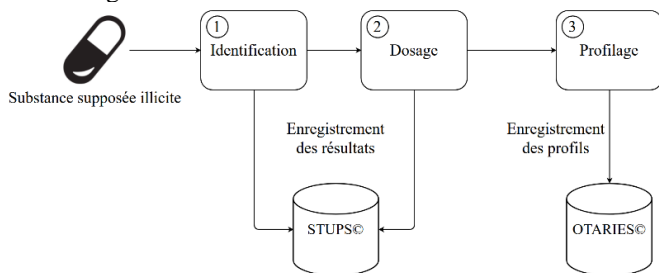


Figure 1. Processus d'analyse d'un échantillon de substance supposée illicite.

L'**identification** est la première étape. L'objectif de cette étape qualitative est de déterminer le classement des éventuelles substances illicites et d'identifier les produits de coupage (avec ou sans effet psychoactif) contenus dans l'échantillon. En complément du processus analytique pour l'identification de substance, est aussi réalisé un examen macroscopique afin de répertorier les caractéristiques physiques de l'échantillon e.g. la forme, la couleur, le logo du distributeur, etc. Cette première étape permet de statuer sur la mise en cause ou non d'une personne pour infraction liée à la Législation sur les Stupéfiants (ILS).

La seconde étape est quantitative et vise le **dosage** du ou des principes actifs et des principaux produits de coupage identifiés à l'étape précédente. Cette étape fournit des données fiables sur la pureté des produits circulant sur le territoire national à l'ensemble des acteurs impliqués dans la prévention ou dans la répression du trafic de stupéfiants. Dans certains cas, ces données permettent de renseigner le niveau de trafic auquel appartient la drogue e.g. rue, grossiste ou laboratoire. Ces données sont utilisées à des fins statistiques par les services sociaux et sanitaires e.g. OFDT (Observatoires Français des Drogues et des Tendances addictives), EMCCDA (European

Monitoring Centre for Drugs and Drug Addiction), et répressifs e.g. OFAST (Office antistupéfiants), Mission de lutte antidrogue (MILAD).

Afin de réduire le temps d'obtention des résultats, ces deux premières étapes sont souvent fusionnées en une seule pour la plupart des laboratoires nationaux. Les résultats obtenus au cours de ces étapes sont enregistrés dans la base de données STUPS©.

La troisième et dernière étape est l'étape de **profilage**. Pour un stupéfiant donné, il s'agit d'extraire les composés cibles du produit, afin d'en établir le profil chimique pour permettre le rapprochement entre saisies (notamment au travers de comparaisons de chromatogrammes de différents échantillons [11]). Plus particulièrement, deux types de profils peuvent être établis :

- Un *profil chimique* contenant les caractéristiques chimiques des composants e.g. impuretés (in)organiques, solvants résiduels, produits de coupage,
- Un *profil physique* contenant les caractéristiques macroscopiques des échantillons e.g. leur couleur, forme, emballages.

Une métrique de ressemblance entre deux échantillons est déterminée par la Police Scientifique et s'exprime en pourcentage (0% pour des échantillons totalement différents et 100% pour des échantillons identiques). Un seuil fixe le pourcentage minimal à partir duquel deux échantillons sont considérés proches. Dans ce cas, ils sont dits « liés ». Les données de profilage chimique sont enregistrées dans la base de données OTARIES©, qui intègre un algorithme de comparaison et les liens entre échantillons sont signalés ([9] et [11]). Le profilage physique est quant à lui réalisé à l'aide des données stockées dans STUPS©.

Bien que le processus décrit ci-dessus soit en place et fonctionnel, certains problèmes subsistent. Tout d'abord, concernant la base de données STUPS© très peu d'études rétrospectives ont été conduites jusqu'à présent (la dernière [10] date de 2017), principalement parce que les données antérieures à la création de la base STUPS© (1986) ne sont disponibles que sous forme manuscrite. De plus, aucune étude prospective utilisant des analyses prédictives n'a été conduite jusqu'à présent. Ces études pourraient porter, par exemple, sur l'évolution du dosage d'un produit de coupage ou l'évolution d'un réseau de distribution sur une période future et une zone géographique données. Les résultats de telles études pourraient permettre la prise de mesures de prévention proactives.

Ensuite, concernant la base de données OTARIES©, à l'instar de la base STUPS©, aucune étude prospective n'a été menée pour identifier des tendances temporelles ou géographiques sur les profils observés, l'apparition ponctuelle de profils atypiques, ou encore l'existence de catégories par origine ou recette employée. De plus, lorsque deux échantillons sont proches, selon la métrique de la Police Scientifique, les experts vérifient manuellement qu'il n'y a pas d'aberrations sur les échantillons qui réfuteraient le rapprochement. Par exemple, si la différence entre les dates de saisie des deux échantillons est supérieure à une certaine durée, les experts peuvent conclure que les échantillons ne sont en fait pas proches. Cette démarche est alors une démarche complexe, difficile à harmoniser et nécessite l'intervention d'experts métier.

D'après le contexte présenté ci-dessus, les Problématiques

Métiers (PM) suivantes ont été identifiées :

- **PM1** : Mener une étude approfondie des bases STUPS© et OTAIRES© pour en extraire une base de connaissances.
- **PM2** : Établir des modèles exploitant la base de connaissances afin de rapprocher automatiquement des profils selon les caractéristiques macroscopiques et les compositions des échantillons.
- **PM3** : Établir des modèles prédictifs, robustes statistiquement et exploitant la base de connaissances afin de caractériser au mieux les produits stupéfiants circulant en France.
- **PM4** : Comparer des compositions de produits par années, niveaux de trafic, territoires etc.

Les résultats fournis par les modèles utilisés doivent être explicables afin de servir de preuves lors d'un procès. Cela signifie qu'un expert doit pouvoir comprendre les causes amenant aux résultats d'un algorithme d'aide à la décision.

### 3 Problématiques scientifiques

Plusieurs problématiques scientifiques (PS) découlent des objectifs visés et des problématiques métiers du projet AI4NP, présentées dans la section précédente.

La première problématique (**PS1**) porte sur *la conception d'une base de connaissances réunissant les données et informations contenues dans les bases de données STUPS© et OTAIRES©*. Cette problématique scientifique est liée à la problématique métier PM1. Il s'agira d'étudier comment les approches d'IA symbolique permettent de représenter ces éléments de manière explicite et formelle.

Les problématiques métiers PM2 et PM3 soulèvent la seconde problématique scientifique (**PS2**), qui concerne *le couplage d'approches d'IA symbolique et d'IA connexionniste*. Plus précisément, il s'agit d'investiguer comment les résultats produits par des modèles d'IA connexionniste peuvent être validés et contrôlés, en utilisant les connaissances des experts. Cela permettrait de fournir des résultats conformes aux connaissances des experts, d'éviter les résultats aberrants et pourrait réduire le temps d'entraînement de ces modèles. De plus, les modèles d'IA connexionniste seraient utilisés pour enrichir la base de connaissances. En effet, la construction d'une base de connaissances est un processus itératif nécessitant des échanges avec des experts et la compréhension d'un domaine métier complexe. De ce fait, elle n'est pas complète dès la première itération. Les modèles d'IA connexionniste pourraient alors extraire des connaissances à partir des données pour faciliter le processus de création de la base de connaissances. De plus, ces nouvelles connaissances pourraient être utilisées par les experts pour identifier de nouveaux axes d'analyse. Cependant, ces connaissances doivent pouvoir être acceptées ou réfutées par les experts pour éviter de polluer la base de connaissances déjà existante.

Pour finir, la troisième et dernière problématique scientifique (**PS3**) découle de PM4 et se focalise sur *la prise en compte de différentes échelles d'analyse (ou niveaux de granularité) par les modèles d'IA connexionniste et d'IA symbolique*. L'objectif est d'étudier comment différents modèles d'IA peuvent gérer efficacement les changements d'échelle sans nécessiter de lourdes modifications telles qu'un réentraînement complet des modèles ou une nouvelle spécification de la base de connaissances. La prise en compte de plusieurs niveaux de

granularité peut permettre d'améliorer les performances des différents modèles, en éliminant les informations non pertinentes pour un niveau spécifique. En considérant, par exemple, les niveaux de distribution de drogue il est possible de faire des analyses à l'échelle de la vente en gros (avant que la drogue ne soit altérée avec des produits de coupage) jusqu'à la vente au détail (où la drogue est le plus coupée). La représentation de la connaissance à ces différents niveaux ne serait pas la même car les acteurs et les échelles temporelles et spatiales entrants en jeu seraient différentes.

Ces trois problématiques relèvent des domaines de l'IA symbolique et connexionniste ainsi que l'informatique granulaire. La section suivante donne des rappels sur les notions d'IA symbolique et connexionniste et expose les limites de ces approches. L'informatique granulaire n'a pas encore été étudié dans le cadre du projet et n'est donc pas abordé dans cet article.

### 4 IA Symbolique et connexionniste

L'intelligence artificielle est le domaine ayant pour objectif de concevoir des techniques informatiques permettant de simuler l'intelligence humaine et dont l'origine remonte au milieu des années 40 [38]. Les problématiques de la section 3 font référence à deux courants de l'IA : l'IA symbolique et l'IA connexionniste. Cette section présente succinctement ces deux courants ainsi que leurs limites justifiant le choix d'une autre voie de recherches - l'IA neuro-symbolique - dont la section 5 dresse l'état des lieux.

#### 4.1 IA Symbolique

L'IA symbolique a pour objectif de représenter et reproduire le raisonnement cognitif humain via un système de représentation des connaissances [18]. L'IA symbolique nécessite des représentations formelles et explicites d'un domaine de connaissances, couplées à des mécanismes permettant d'en déduire des connaissances implicites. Selon Studer et al [42], une ontologie est une « spécification formelle et explicite d'une conceptualisation partagée d'un domaine de connaissance ». La définition d'une ontologie se fait à l'aide de langages logiques.

La revue de l'ensemble des langages logiques sort du cadre de cet article mais l'on peut toutefois en noter deux principaux : la logique du premier ordre (FOL pour *First Order Logic*) [32] et les logiques de description (DL pour *Description Logics*) [2]. La FOL permet la modélisation de systèmes déductifs : ses règles de syntaxe permettent de définir une interprétation (une sémantique) d'une théorie (un ensemble de formules) et de déterminer si une formule est une conséquence logique d'une théorie. Toutefois elle n'est pas décidable : une procédure de décision (ou algorithme de décision) en FOL peut ne pas se terminer en un temps fini. Il existe alors les DL qui sont des sous-ensembles de FOL et sont (généralement) décidables. Un langage de la DL est caractérisé par un ensemble de constructeurs permettant d'enrichir l'expressivité du langage. Il faut noter que le gain d'expressivité d'un langage se fait au détriment du temps d'exécution des procédures de décision. Parmi les différents constructeurs on peut citer la conjonction, la négation, la disjonction ou encore le quantifieur existentiel. Les langages informatiques utilisés pour la définition d'ontologies reposent donc sur les logique de description [25]

car ils sont plus efficaces (en termes de temps d'exécution) des procédures de décision associées.

Une ontologie comprend une signature  $S$  (l'ensemble des classes, instances et propriétés utilisés pour représenter la connaissance), et un ensemble d'axiomes associés  $A$  (exprimé en DL par exemple) [17]. Généralement les termes « base de connaissances » et « ontologie » sont utilisés comme synonymes. Pour une base de connaissances, on fait la distinction entre *Terminological Box* (TBox – concepts et relations entre concepts) et la *Assertional Box* (ABox – instanciation des éléments de la Tbox). Pour une ontologie on distingue les entités conceptuelles (équivalent de TBox) et les entités concrètes (équivalent de ABox) [17]. Les procédures de décision peuvent alors être appliquées au niveau de la TBox (par exemple, pour inférer des relations entre concepts non explicitement spécifiées) ou au niveau de la ABox (par exemple, pour déduire l'appartenance d'un individu à une classe d'un concept). Les inférences produites par les algorithmes d'IA symboliques sont explicables au travers d'arbres de décision. Il est donc possible de connaître les causes amenant à un résultat.

Ainsi, l'IA symbolique est pertinente par rapport aux problématiques métiers, présentées ci-dessus, notamment pour modéliser la connaissance des experts métier et permettre l'explicabilité des déductions faites. Cette explicabilité est un point essentiel dans un contexte d'aide à la décision.

## 4.2 IA Connexionniste

Le second courant de l'IA présenté dans cette section est l'IA connexionniste (ou simplement connexionnisme) [38]. Apparue au milieu des années '80, ce courant se place en opposition à celui de l'IA symbolique [35] et réfute l'hypothèse selon laquelle le raisonnement humain ne peut être modélisé qu'en utilisant des symboles [38].

Les modèles connexionnistes n'utilisent pas de langage logique pour spécifier leurs concepts internes mais un ensemble de neurones formels connectés entre eux pour former un réseau de neurones [7]. Un neurone formel (ou simplement neurone) est une représentation mathématique d'un neurone biologique sans chercher à en être une copie conforme [23]. Un réseau de neurones est alors formé de neurones organisés en couches successives où les neurones d'une couche  $n$  sont connectés à ceux de la couche  $n+1$ . Ces réseaux de neurones ont la capacité, entre autres, d'apprendre à partir d'exemples, d'abstraire des données non structurées et d'être robustes face au bruit et aux aberrations dans les données [4], [21], [47]. Ils peuvent être utilisés en fouille de données pour identifier des patterns ou des corrélations dans un grand ensemble de données [33]. Chaque réseau a une couche d'entrée (recevant les données), une couche de sortie (donnant les résultats du réseau) et une ou plusieurs couches cachées (entre la couche d'entrée et la couche de sortie). S'il y a plus d'une couche cachée, alors le réseau est dit *profond* et est utilisé dans les approches d'apprentissage profond (*deep learning*) pour l'apprentissage de concepts plus complexes [6].

L'entraînement d'un réseau de neurones se fait en modifiant la valeur de ses poids synaptiques (modélisant l'importance des connexions entre les neurones). Il existe alors plusieurs méthodes d'apprentissage [6]. Si les données d'entraînement sont étiquetées avec le concept qu'elles représentent, on parle

d'apprentissage supervisé. Si une partie seulement des données est étiquetée, il s'agit d'apprentissage semi-supervisé. Si aucune donnée n'est étiquetée, on parle d'apprentissage non supervisé. Pour finir, l'apprentissage par renforcement [24] permet au réseau d'apprendre grâce à un système de récompense : si le réseau donne un résultat correct alors il reçoit un signal positif sinon, il reçoit un signal négatif indiquant qu'il doit corriger la valeur de ses poids synaptiques.

Ainsi, l'IA connexionniste est pertinente par rapport au contexte métier présenté ci-dessus notamment pour établir des modèles proactifs et enrichissant la base de connaissances.

## 4.3 Limites

L'IA symbolique et l'IA connexionniste, présentées ci-dessus, ont toutes deux des avantages et des caractéristiques intéressantes par rapport au contexte métier présenté en section 2. Cependant, elles présentent des limites non négligeables qui font qu'il n'est pas possible d'utiliser uniquement l'une ou l'autre de ces approches dans le cadre du projet AI4NP.

Tout d'abord, les approches issues de l'IA symbolique ne peuvent pas apprendre de nouvelles connaissances à partir d'exemples, ne peuvent manipuler des données non structurées et sont peu tolérantes aux bruits dans les données [4], [21] et [47]. Par conséquent, une base de connaissances peut difficilement s'adapter à l'évolution du domaine qu'elle représente sans intervention humaine (elle doit être enrichie à la main). Ceci est problématique car le domaine des stupéfiants est amené à changer fréquemment et les autorités doivent s'adapter rapidement aux nouvelles méthodes des trafiquants. De plus, les données issues des bases STUPS et OTARIES sont sujettes au bruit (à cause d'erreurs humaines ou de défauts matériel lors des mesures) et les réseaux de trafic forment des graphes difficilement manipulables avec de l'IA symbolique. Ensuite, malgré leur capacité d'apprentissage, les réseaux de neurones donnent des résultats qui sont difficilement explicables. On parle de modèle en boîte noire (ou black-box) i.e. la connaissance n'est pas explicitement représentée mais distribuée au sein du réseau. Il est alors presque impossible de comprendre le lien entre les valeurs d'entrée et les résultats fournis. Cette caractéristique peut poser un problème pour l'aide à la prise de décision dans les domaines sensibles car il est essentiel pour un expert, de comprendre tous les résultats fournis. De plus, la connaissance métier n'est pas prise en compte au sein de ces modèles qui peuvent alors fournir des résultats non pertinents pour les experts [4], [21], [47].

L'IA neuro-symbolique combine les deux approches présentées ci-dessus. Elle ne présente pas les limites de l'IA symboliques et de l'IA connexionniste tout en conservant leurs avantages. Un état de l'art de ce domaine est dressé dans la section 5.

## 5 État des lieux de l'IA neuro-symbolique

L'IA neuro-symbolique est un courant de l'IA cherchant à coupler des approches de l'IA symbolique avec des approches connexionnistes afin de profiter des avantages de ces deux approches sans leurs inconvénients [21]. On notera quelques différences au niveau de la sémantique des termes employés en IA neuro-symbolique par rapport à celle des termes de l'IA symbolique. Aussi dans ce qui suit, une « base de

connaissances » est à comprendre comme un ensemble d'axiomes spécifiés dans un formalisme logique, autre que la logique de description vue en section 4.1 IA Symbolique. Une « règle » est à interpréter en tant que structure SI {ensemble axiomes logiques} ALORS {ensemble axiomes logiques}.

Au fil des années, les modèles de l'IA neuro-symbolique ont été classés selon plusieurs critères. Parmi les premières classifications établies, on peut citer celle d'Hilario [20], qui distingue les modèles selon la façon dont ils sont construits et leur structure. En 2020, dans [4], les auteurs classent les modèles selon leur degré d'explicabilité i.e. la façon dont les détails d'un modèle et ses résultats sont compréhensibles. Enfin, en 2021, dans [47], les auteurs proposent une classification selon la manière dont les composants symboliques (e.g. listes de règles, arbres de décisions, ontologies etc.) et les composants connexionnistes (i.e. réseaux de neurones) sont intégrés les uns par rapport aux autres. Une présentation de ces trois classifications ainsi que des exemples de modèles est faite dans cette section. Ces classifications serviront ensuite à se positionner (cf. section 7) quant au(x) type(s) d'approches pour répondre aux différentes problématiques métiers et scientifiques (voir sections 2 et 3). Chronologiquement, la première classification, parmi celles citées plus haut, est celle de Hilario [20]. Cette classification est composée de deux catégories principales : les **approches unifiées** et les **approches hybrides** (la figure 2 illustre cette classification).

Les **approches unifiées** utilisent un réseau de neurones pour effectuer l'entièreté du traitement symbolique. Deux sous-catégories sont distinguées. On trouve d'abord le *traitement symbolique neuronal* dont l'objectif est de reproduire les hautes fonctions du cerveau. Proche de la neuroscience, les neurones utilisés pour la construction des réseaux sont des neurones imitant le fonctionnement des neurones biologiques. La construction des réseaux de neurones se fait de manière ascendante : le point de départ est le neurone, à partir duquel un réseau complexe est créé et modifié jusqu'à ce que la fonction souhaitée soit réalisée. Un exemple de ce type d'approche est le *Neural Darwinism* [12].

La seconde sous-approche est le *traitement des symboles connexionnistes*. Des réseaux de neurones basés sur des neurones formels sont utilisés pour former des architectures cognitives capables de traitements symboliques complexes. L'approche de construction des réseaux est descendante : le point de départ est la fonction symbolique à réaliser à partir de laquelle une structure connexionniste est élaborée. La représentation de la connaissance de ce type d'approche peut être locale, distribuée ou combinée (à la fois locale et distribuée). Dans une représentation locale, chaque nœud du réseau est un concept. Dans une représentation distribuée, un concept émerge de l'interaction entre plusieurs nœuds. On peut citer en exemple le modèle BoltzCONS [43].

La seconde catégorie donnée dans [20] sont les **approches hybrides**. Elles reposent sur le fait que des interactions entre les composants symboliques et connexionnistes sont nécessaires pour fournir des résultats satisfaisants. Là aussi, deux sous-catégories sont distinguées. D'abord, les *approches hybrides translationnelles*, qui utilisent un seul réseau de neurones pour le traitement symbolique mais, contrairement aux approches unifiées, ce réseau est construit à partir d'une

structure symbolique (par exemple des règles logiques). Le réseau est alors contraint par la logique et fournit des résultats en accord avec la connaissance préalable. Ce type de fonctionnement permet de réduire les données nécessaires à l'entraînement du réseau car celui-ci contient la connaissance décrite par la structure. L'entraînement du réseau permet de mettre à jour sa structure pouvant alors être utilisée pour raffiner la structure symbolique de départ [44]. On retrouve au sein de cette catégorie un certain nombre de modèles comme, les *Knowledge-Based Artificial Neural Networks* (KBANN) [45] où des règles en logique propositionnelle sont encodées dans un réseau de neurones à une couche cachée. Cet encodage définit la structure du réseau et fixe les poids synaptiques initiaux. Comme dit précédemment, cela permet de contraindre les résultats (ils ne peuvent être que les conséquences des règles logiques) et réduit le nombre d'itérations nécessaires à l'entraînement (car le réseau contient la sémantique décrite par les règles). Ce modèle a ensuite été étendu par le *Connectionist Inductive Learning and Logic Programming* (C-IL<sup>2</sup>-P) [16] pour améliorer les capacités d'apprentissages. Ceci est fait en modifiant la façon dont les règles sont encodées dans le réseau et en ajoutant des boucles de rétroaction entre les neurones d'entrée et de sortie du réseau. Le *Connectionist Inductive Learning and Logic Programming++* (CILP++) [15] est une extension du C-IL<sup>2</sup>-P pour traiter des règles en FOL. Parmi les approches plus récentes, nous pouvons citer les *Logic Tensor Networks* (LTN) [3] où une base de connaissances est traduite en *logique réelle* (logique proposée par les auteurs) dont les domaines des variables sont des nombres réels permettant ainsi de gérer des cas d'incertitude. Les réseaux utilisés sont des réseaux de tenseurs [5]. Le modèle LYRICS [30] exploite la logique floue [26] afin de gérer l'incertitude au sein des données. Ce modèle appartient à la famille de la *Differentiable Fuzzy Logic* (DFL) [27] et [28]. Dans ce type de modèle, les règles en FOL sont traduites en règles de la logique floue : les opérateurs logiques du premier ordre sont traduits en opérateurs de la logique floue (t-norm, t-conorm, S-implication et R-implication) et les prédicats sont interprétés grâce à des modèles de *deep learning* pouvant être entraînés.

La seconde sous-catégorie des approches hybrides présentée par Hilario [20], sont les *approches hybrides fonctionnelles*. Dans ce type d'approches, les composants connexionnistes et symboliques fonctionnent conjointement. Les composants peuvent être faiblement couplés, c'est-à-dire que les interactions entre les composants sont clairement localisées dans le temps et l'espace, initiées par l'un des composants ou un agent extérieur. Les données sont alors transférées d'un composant à un autre par un appel de fonction ou de procédure. Les composants peuvent aussi être fortement couplés c'est-à-dire que les données et les connaissances sont partagées entre les composants via une structure de données commune. Un changement dans la structure par l'un des composants entraîne des changements dans tous les autres composants.

Il existe aussi quatre modes (ou schémas) d'intégration spécifiant la façon dont les composants sont intégrés les uns par rapport aux autres :

- *Chainprocessing* : un des composants est le composant principal (les autres font des tâches en amont ou en aval). On peut citer en exemple ExpressGNN [50].
- *Subprocessing* : un des composants est intégré et

subordonné à l'autre composant.

- *Metaprocessing* : un composant est le composant de base chargé de résoudre le problème, l'autre agit au niveau des métadonnées (par exemple, pour contrôler les résultats).
- *Coprocessing* : tous les composant sont au même niveau.




Figure 2. Illustration de la classification d'Hilario, adaptée de [20].

La seconde classification présentée ici est celle proposée en 2020 par Calegari et al. [4]. Les différents modèles sont triés selon leur type d'interprétabilité. Cette classification est illustrée par la figure 3.

Comme précédemment, deux catégories principales sont distinguées : les **approches par intégration** et les **approches par composition**. Tout d'abord, les **approches par intégration** regroupent les modèles intégrant les connaissances du composant symbolique au sein du composant connexionniste. Deux sous-catégories sont distinguées. La première sous-catégorie est l'*intégration via des prédicteurs numériques* (comme des réseaux de neurones par exemple). On retrouve ici des modèles tels que les KBANN [45], LYRICS [30], LTN [3] ou encore la *Semantic Loss Function* (SLF) [49] où l'idée est de manipuler, grâce à de la logique, la fonction de perte utilisée dans l'entraînement d'un réseau de neurones.

La seconde sous-catégorie est l'*intégration via des approches probabilistes ou statistiques*. On y retrouve les CILP++ [15], DeepProbLog [34] ou encore la programmation logique inductive différentiable ( $\partial$ ILP pour *Differentiable Inductive Logic Programming*) [13].

La seconde catégorie, les **approches par composition**, regroupe les modèles combinant des modèles symboliques et connexionnistes. On distingue deux types de composition : l'*extraction* et l'*injection*. Premièrement, l'*extraction* regroupe les modèles qui extraient des connaissances symboliques des composants connexionnistes. Les auteurs abordent les cas de l'extraction de listes de règles (de la forme *Si ... Alors ... Sinon ...*) et de l'extraction d'arbres de décision. L'extraction de règles peut être faite selon des approches *pédagogiques* comme dans les modèles ALPA [14] et RxREN [1]. Selon ces approches, le composant connexionniste (considéré comme un oracle) est interrogé avec toutes les possibilités de valeurs pour les variables d'entrée. Chaque résultat donné par le composant est une conséquence des entrées et permet de dresser la liste des règles. L'autre type d'approches d'extraction sont les approches *décompositionnelles*. De manière générale, dans ce type d'approches, les liens entre les neurones et les fonctions d'activation des neurones sont étudiés pour former un ensemble de règles. On y trouve par exemple le modèle RX [39].

L'extraction d'arbre de décision peut être fait de plusieurs manières, entre autres, en interrogeant le composant connexionniste comme un oracle, en utilisant une

interprétation bayésienne ou en encore en analysant la structure interne du réseau. Par exemple, Schetinin et al. [40] proposent une méthode d'extraction de connaissances sous la forme de forêt aléatoire.

Deuxièmement, l'*injection* concerne les modèles où la connaissance symbolique est injectée dans le composant symbolique. Les auteurs présentent en particulier les approches injectant des graphes de connaissances comme le modèle OSCAR [19]. Ce modèle traduit les graphes dans un espace vectoriel pouvant être traité par un réseau de neurones. La prise en compte de ces graphes de connaissances permet, d'une part, d'améliorer les performances du composant connexionniste et, d'autre part, l'explicabilité par la conception car la connaissance est utilisée comme une contrainte sur le composant connexionniste.

Concernant le type d'explicabilité des catégories de cette classification, les approches par intégrations et par injection de connaissances sont explicables par la conception. Cela signifie que les modèles sont soit transparents (et donc explicables) soit des boîtes noires contraintes par la logique et de ce fait explicables. Les approches par composition ont une explication *post-hoc* ce qui signifie que les modèles doivent être manipulés pour extraire les connaissances qu'ils contiennent.

Dans [4], selon les auteurs, les modèles explicables par la conception sont les plus pertinents dans un contexte où les prises de décision sont critiques car ils mettent l'accent sur le compréhension des modèles et de leurs résultats au détriment des performances. De l'autre, les méthodes *post-hoc* permettent d'utiliser le plein potentiel des composants connexionnistes au détriment de l'explicabilité.




Figure 3. Illustration de la classification de Calegari et al., adaptée de [4].

Pour finir, Yu et al. [47], classent les modèles selon trois modes d'intégration des composants symboliques et connexionnistes. Cette classification est illustrée par la figure 4.

Le premier mode est l'**apprentissage pour le raisonnement**. Ce mode peut être vu comme un type de *chainprocessing* [20] où le premier composant est un réseau de neurones et le second est un composant symbolique. L'utilisation d'un réseau de neurones permet de prétraiter les structures de données complexes (image, texte etc.) afin de les abstraire pour qu'elles puissent être utilisées dans le raisonnement fait par un composant symbolique. Cela permet aussi de réduire l'espace de recherche améliorant ainsi les performances du composant symbolique. Il est possible de citer en exemple des modèles tels que pLogicNet [36] ou ExpressGNN [50] qui effectuent un prétraitement des graphes afin de simplifier les inférences faites sur ceux-ci.

Le second mode est le **raisonnement pour l'apprentissage**.

L'apprentissage fait par le réseau est guidé en prenant en compte la connaissance symbolique (comme dans les approches par intégration ou injection de [4]). En cas de manque de données pour l'entraînement, la connaissance peut être intégrée au réseau de neurones afin de transférer la connaissance sémantique (le temps d'apprentissage est alors réduit). Un exemple de raisonnement pour l'apprentissage est le modèle *Iterative Rule Distillation* (ou *Harnessing Deep Neural Networks with logic*) [22]. Dans ce modèle, un réseau de neurones professeur encode la connaissance et intervient dans le processus d'apprentissage d'un réseau élève qui tente de prédire le label des données d'entraînement et le résultat du réseau professeur. Il existe des modèles plus récents comme PROLONETS [41], basé sur l'apprentissage par renforcement ou *Context-Aware Zero-Shot Recognition* [29], utilisant un ensemble de données pour la reconnaissance d'objets dans un contexte de *zero-shot learning* (ZSL) [46] (i.e. prédiction de la classe d'un échantillon sans que cette classe n'ait été observée lors de la phase d'entraînement).

Le dernier mode présenté dans [47] est l'**apprentissage-raisonnement** où les composants travaillent ensemble, au même niveau. Ce mode d'intégration a pour objectif de combiner les deux modes présentés ci-dessus. D'une part, le composant symbolique contraint le réseau de neurones dans son apprentissage et, d'autre part, le composant connexionniste abstrait la représentation des données pour faciliter le raisonnement fait par le composant symbolique et peut même enrichir la connaissance symbolique. Selon la classification de Hilario [20], ce mode d'intégration serait un type de *coprocessing*. On peut donner en exemple le modèle DeepProbLog [34], extension de ProbLog [37]. Les prédicats des formules de la logique du premier ordre sont implémentés par des réseaux de neurones entraînaibles par descente de gradient. Les perceptions de bas niveau sont alors réalisées par les réseaux de neurones tandis que le raisonnement est fait au niveau de la logique. L'apprentissage par abduction (ABL pour *ABductive Learning*) [48], parfois appelé retro-production, est un autre exemple d'apprentissage-raisonnement. Des faits et des hypothèses sont inférés à partir d'une base de connaissances pour expliquer des observations.




Figure 4. Illustration de la classification de Yu et al., adaptée de [47].

## 6 Défis applicatifs

Cette section présente les défis applicatifs découlant des contraintes métiers et de l'état actuel des bases de données. Le premier défi concerne le traitement de données hétérogènes

et multivariées. Pour les bases STUPS© et OTARIES©, l'hétérogénéité est due aux nombres d'acteurs remplissant la base ainsi qu'à leur longévité (notamment pour STUPS©). En effet, différents acteurs n'auront pas toujours la même rigueur lors de l'insertion de données dans les bases et peuvent avoir des avis différents quant à la pertinence d'une donnée. De plus, tous les laboratoires n'analysent pas exactement les mêmes caractéristiques d'un échantillon de drogue (cela tend à s'uniformiser) pouvant conduire à des données manquantes. La longévité des bases peut aussi être une source d'hétérogénéité car les modifications du schéma d'une base au cours des années peuvent conduire à avoir des données manquantes (par exemple, les nouveaux champs de tables déjà existantes ne peuvent pas toujours être remplis pour les anciennes données). Cette longévité donne aussi lieu à une inconsistance dans le temps avec des périodes où le nombre de saisies dans les bases est plus ou moins important que pour d'autres périodes.

Le second défi est lié au fait que les bases de données ne contiennent pas de connaissances métier des experts de la SNPS. Sans ces connaissances, les approches neuro-symboliques ne peuvent pas être exploitées pleinement. Il faudra alors échanger avec les experts pour construire une base de connaissances. Le fait de construire la base en échangeant avec plusieurs experts pose un problème. En effet, dans des domaines où l'analyse est sujette à interprétation, si des experts différents utilisent des règles d'analyse différentes, il faut être capable de prioriser les règles rajoutant ainsi de la complexité dans l'acquisition des connaissances. Ces deux défis applicatifs sont directement reliés à la problématique métier PM1.

Le troisième défi applicatif est lié à PM4 et concerne la modélisation de plusieurs axes sous forme granulaire. En effet, il faudra d'abord identifier quels axes et niveaux de granularité sont utiles aux experts. De plus, une fois ces axes et leurs niveaux identifiés, il faudra étudier leur modélisation. En effet, faudra-t-il modéliser chaque niveau de chaque axe indépendamment ou alors des niveaux d'axes différents ensembles ?

Pour finir, ce travail d'analyse doit s'inscrire dans la durée. L'approche proposée doit pouvoir être adaptée afin que de nouvelles connaissances ou de nouveaux modèles y soient ajoutées car le domaine des stupéfiants est en constante évolution donc, un système figé ne peut pas être utilisé.

## 7 Premiers travaux et approches envisagées

En tenant compte des différents éléments présentés dans les sections précédentes, de premiers travaux ont été conduits et des pistes d'approches ont été envisagées.

Afin de répondre à la problématique PS1, nous avons conçu une ontologie pour modéliser les connaissances métier des experts de la SNPS. La TBox de cette ontologie décrit un ensemble de concepts ainsi que les conditions nécessaires et suffisantes pour que les instances peuplant la ABox appartiennent à ces concepts. La conception de l'ontologie est faite itérativement et la première version modélise les concepts de base nécessaires pour débiter nos travaux. Le concept de saisine a été modélisé en premier car il est à la base de toute analyse faite par les laboratoires de la police scientifique. Il s'agit d'un terme juridique utilisé en matière de procédure qui

désigne l'action qu'accomplit un requérant (on parle de service requérant) lorsqu'il demande l'analyse d'une saisine de drogue. Une saisine contient un ensemble de scellés, qui eux-mêmes contiennent un ou plusieurs prélèvements à partir desquels sont extraits des échantillons. Une saisine est faite dans une ville, par un service capteur, et la drogue de la saisine est à destination d'un pays pour la revente. La définition de ce concept est exprimée en DL comme suit :

$$\begin{aligned} \text{Saisine} &\equiv 1 \text{ aServiceCapteur. ServiceCapteur} \\ &\cap \exists \text{aScelle. Scelle} \cap = 1 \text{ estFaitA.Ville} \\ &\cap = 1 \text{ aPaysDestination. Pays} \\ &\cap = 1 \text{ aServiceRequerant. ServiceRequerant} \end{aligned}$$

Dans la première version de l'ontologie nous avons défini au total 43 concepts et 46 relations entre concepts. La présentation de tous ces éléments sort du cadre de cet article.

L'un des intérêts d'une ontologie est le partage et la réutilisation des connaissances qu'elle modélise. Cela évite de redéfinir des connaissances ayant déjà été modélisées dans d'autres travaux. Ainsi, dans une future version, nous allons nous appuyer sur d'autres ontologies, comme l'ontologie des unités de mesures (<https://www.ebi.ac.uk/ols/ontologies/om>). Celle-ci sera utilisée lorsqu'il sera nécessaire de préciser l'unité d'une mesure d'une caractéristique macroscopique d'un échantillon (par exemple, la masse ou les dimensions).

Au moment de l'écriture de cet article, le travail en cours porte sur l'utilisation de règles d'analyse pour faciliter le processus d'appariement d'échantillons. La métrique de ressemblance présentée dans la section 2 ne suffit pas à elle seule à rapprocher deux échantillons. En effet, les experts doivent procéder à un examen manuel des échantillons potentiellement proches afin d'éviter les faux positifs. Ainsi, pour valider ou réfuter un appariement, un ensemble de règles d'analyse sont utilisées. Par exemple, un expert peut se pencher sur les dates des saisines des échantillons et peut conclure à un faux positif si elles sont trop éloignées. L'ensemble de ces règles d'analyses ont été formalisées en utilisant la logique du premier ordre. Il reste alors à ajouter ces règles à l'ontologie actuelle afin que l'ensemble des connaissances (description du domaine métier et règles d'analyse) soit intégré au sein de la même structure symbolique. Il s'agit d'un choix que nous avons fait afin de limiter le nombre de structures à manipuler. La manière dont est faite cette intégration est en cours d'investigation. Une fois l'ontologie enrichie avec les règles d'analyse, il sera possible de construire des modèles issus de l'IA neuro-symbolique afin de répondre à la seconde problématique scientifique (PS2) - englobant les problématiques métiers PM2 et PM3.

Concernant PM2, le modèle construit servira à faciliter les analyses faites par les experts et à raffiner les règles d'analyse. Cela permettra de simplifier (voire améliorer) le processus d'appariement. Même si le choix du modèle n'est pas encore fait, il est d'ores et déjà possible de se positionner par rapport aux différentes classifications présentées dans la section 5. S'inscrivant dans un contexte d'aide à la prise de décision, le modèle retenu devra fournir des résultats compréhensibles par un humain (i.e. comprendre les causes amenant à ce résultats). De plus, la connaissance décrite au sein de l'ontologie devra être utilisée au sein du modèle pour avoir des résultats respectant la connaissance des experts.

Selon Calegari et al. [4], la connaissance symbolique peut être intégrée ou injectée dans le composant connexionniste. La prise en compte du graphe de connaissances décrit par l'ontologie semble ne pas être nécessaire pour l'appariement d'échantillons. En effet, seules les règles d'analyse pourraient être utilisées. Ainsi, nous pourrions limiter notre étude aux modèles intégrant la connaissance exprimée sous la forme de règles logique (par exemple le modèle CILP++ [15]). En revanche, si cette piste est fautive et que la prise en compte du graphe de connaissances s'avère être nécessaire alors des modèles injectant la connaissance seront à étudier. En plus de la prise en compte de la connaissance symbolique, il faut que le composant connexionniste enrichisse cette connaissance. Ce type de fonctionnement correspond à l'*apprentissage-raisonnement* présenté par Yu et al. [47]. En effet, le composant symbolique contraint le composant connexionniste qui, à son tour, va enrichir la connaissance du composant symbolique. Si l'on croise la classification [4] avec la classification [47], certains modèles peuvent être mis en évidence comme DeepProbLog [34] qui fait à la fois partie de l'*apprentissage-raisonnement* [47] et des modèles intégrant la connaissance symbolique [4]. Pour finir, selon la classification de Hilario [20], le choix le plus pertinent pour traiter PM2 semble être les approches hybrides fonctionnelles où les composants sont intégrés en *coprocessing*. En effet, les composants symboliques et connexionnistes doivent travailler ensemble au même niveau. Un couplage faible entre les composants pourra être suffisant dans la mesure où la vérification des règles par le composant symbolique sera clairement identifiée dans le temps (après l'entraînement du composant connexionniste).

Concernant la problématique métier PM3, le modèle prédictif conçu doit caractériser les produits stupéfiants en France et enrichir la base de connaissances si de nouveaux concepts pertinents sont identifiés dans les données. Comme pour la problématique métier PM2, le choix du modèle n'est pas encore fait mais il est possible de se positionner.

L'utilisation de la connaissance métier sera nécessaire afin de fournir des prédictions de qualité utiles aux experts. De fait, le type de fonctionnement entre les différents composants serait du type *apprentissage-raisonnement* [4]. En effet, le composant symbolique fournirait le graphe de connaissances de l'ontologie au composant connexionniste qui l'utiliserait pour effectuer des prédictions et potentiellement l'enrichir. Ces prédictions et l'enrichissement de la connaissance seraient alors vérifiées par le composant symbolique. Comme précédemment, il semble que les approches hybrides fonctionnelles [20] soient les plus pertinentes car les composants travailleraient ensemble au même niveau. Un couplage faible semble pouvoir être suffisant car la communication entre composants ne se ferait qu'une fois les prédictions faites. De plus, il pourrait être possible d'envisager l'affinement des prédictions grâce à l'apprentissage par renforcement. En effet, si l'on suppose le composant symbolique capable de valider ou non une prédiction (moyennant l'intervention humaine si nécessaire) alors il pourrait influencer le composant connexionniste lors de son entraînement. Par exemple, une prédiction non conforme aux connaissances métier enverrait un signal négatif au composant connexionniste qui serait en mesure de se corriger en prenant



en compte ce signal. Pour finir, l'utilisation du graphe de connaissances par le composant connexionniste pourrait être fait par une méthode d'injection de connaissances comme celles présentées dans [4]. En effet, les règles d'analyse ne seront pas nécessaires pour traiter cette problématique car elles ne sont utilisées que pour l'appariement d'échantillons.

Les catégories de modèles mises en avant pouvant répondre à la problématique PS2, ne représentent pas des conditions nécessaires pour qu'un modèle soit accepté. En d'autres termes, un modèle peut appartenir seulement à une partie des catégories envisagée ci-dessus ou à d'autres catégories.

Les pistes pour répondre à la problématique PS3, à savoir la modélisation de la connaissance sous différents niveaux de granularités, n'ont pas encore été étudiées.

## 8 Conclusion

Cet article présente les problématiques scientifiques traitées dans le cadre d'un projet de thèse financée par le MESRI. Ces problématiques scientifiques découlent des objectifs visés et des problématiques métiers du projet AI4NP.

Un état de l'art de l'intelligence artificielle neuro-symbolique est dressé à travers trois classifications de modèles. Elles classent les modèles selon leur structure, les interactions entre les différents éléments qui les composent et leur explicabilité. Les premiers travaux, menés en parallèle de l'écriture de cet article, sont présentés ainsi que des pistes d'approches pour les travaux futurs. Ces futurs travaux concerneront la conception d'un modèle servant à faciliter l'appariement d'échantillons ainsi que d'un modèle prédictif caractérisant les produits stupéfiants circulant en France.

La représentation de la connaissance sous différents niveaux de granularité sera étudiée afin de choisir des niveaux pertinents pour les experts.

Actuellement, seules des approches combinant réseaux de neurones et IA symbolique ont été étudiées afin d'identifier des éléments de réponse. À mesure que nos analyses avancent, il sera peut-être nécessaire d'investiguer d'autres modèles, par exemple, ceux basés sur des kernel machines, comme c'est le cas dans [8].

## Remerciements

Les travaux présentés se déroulent dans le cadre d'un Contrat Doctoral financé par le Ministère de l'Enseignement Supérieur, de la Recherche et de l'Innovation. Une convention de coopération tripartite réunissant l'Université de Bourgogne, l'Institut Agro Dijon et le Service National de la Police Scientifique (SNPS) accompagne ce contrat doctoral. Nous tenons à remercier le SNPS pour l'accès à ses bases de données et particulièrement à Mme Céline Charvoz, cheffe de la section Stupéfiants du laboratoire de Police Scientifique de Lyon et M. Fabrice Besacier, sous-directeur adjoint de la Sous-direction de la Stratégie, de l'Innovation et du Pilotage du SNPS pour les renseignements fournis.

## 9 Bibliographie

[1] M.G. Augasta, T. Kathirvalavakumar, Reverse engineering the neural networks for rule extraction in classification problems, *Neural processing letters*, Vol. 35(2), pp. 131–150, 2012.

- [2] F. Baader, W. Nutt, Basic description logics. In: *The description logic handbook: theory, implementation, and applications*. pp. 43–95, 2003.
- [3] S. Badreddine, A. Garcez, L. Serafini, M. Spranger, Logic tensor networks, *Artificial Intelligence*, Vol. 303, DOI : 10.1016/j.artint.2021.103649, 2022.
- [4] R. Calegari, G. Ciatto, A. Omicini, On the integration of symbolic and sub-symbolic techniques for XAI: A survey, *Intelligenza Artificiale*, Vol.14(1), pp.7–32, 2020.
- [5] R. Socher, D. Chen, C. D. Manning, A. Y. Ng, Reasoning With Neural Tensor Networks For Knowledge Base Completion, *Advances in Neural Information Processing Systems*, Vol. 26, 2013.
- [6] A. Cornuéjols, L. Miclet, V. Barra, Apprentissage artificiel : Deep learning, concepts et algorithmes, Eyrolles, 2018.
- [7] R. Dastres, M. Soori, Artificial Neural Network Systems. *International Journal of Imaging and Robotics (IJIR)*, 21 (2), pp.13–25, 2021.
- [8] M. Diligenti, M. Gori, C. Sacca, Semantic-based regularization for learning and inference, *Artificial Intelligence*, Vol. 244, pp. 143–165, 2017.
- [9] V. Dufey, L. Dujourdy, F. Besacier, H. Chaudron, A quick and automated method for profiling heroin samples for tactical intelligence purposes, *Forensic Science International*, Vol. 169(2), pp. 108–117. doi: 10.1016/j.forsciint.2006.08.003, 2007.
- [10] L. Dujourdy, F. Besacier, A study of cannabis potency in France over a 25 years period (1992–2016), *Forensic Science International*, Vol. 272, pp. 72–80. doi: 10.1016/j.forsciint.2017.01.007, 2017.
- [11] L. Dujourdy, F. Besacier, Headspace profiling of cocaine samples for intelligence purposes, *Forensic Science International*, Vol. 179(2–3), pp. 111–22. doi: 10.1016/j.forsciint.2008.04.024, 2008.
- [12] G. M. Edelman, *Bright air, brilliant fire: On the matter of the mind*, BasicBooks, 1992.
- [13] R. Evans, E. Grefenstette, Learning Explanatory Rules from Noisy Data, *Journal of Artificial Intelligence Research*, Vol. 61, pp. 1–64, DOI:10.1613/jair.5714, 2018.
- [14] E.J. de Fortuny and D. Martens, Active Learning-Based Pedagogical Rule Extraction, *IEEE Transactions on Neural Networks and Learning Systems*, Vol. 26(11), pp. 2664–2677, 2015.
- [15] M. V. França, G. Zaverucha, A. S. Garcez, Fast relational learning using bottom clause propositionalization with artificial neural networks, *Machine learning*, Vol. 94, pp. 81–104, 2014.
- [16] A. Garcez, G. Zaverucha, The connectionist inductive learning and logic programming system, *Applied Intelligence*, Vol. 11, pp. 59–77, 1999.
- [17] S. Grimm, A. Abecker, J. Völker, R. Studer, Ontologies and the semantic web. *Handbook of Semantic Web Technologies*, pp.507–579, DOI: 10.1007/978-3-540-92913-0\_13, Springer, 2011.
- [18] M. Flasiński, Symbolic Artificial Intelligence. In: *Introduction to Artificial Intelligence*. Springer, Cham.

- pp. 15-22, DOI : 10.1007/978-3-319-40022-8\_2, 2016.
- [19] T.R. Goodwin, D. Demner-Fushman, Bridging the Knowledge Gap: Enhancing Question Answering with World and Domain Knowledge, arXiv:1910.07429, 2019.
- [20] M. Hilario, An overview of strategies for neurosymbolic integration, *Connectionist-Symbolic Integration: From Unified to Hybrid Approaches*, Psychology Press, 1997.
- [21] P. Hitzler, A. Eberhart, M. Ebrahimi, M. K. Sarker, Lu Zhou, Neuro-symbolic approaches in artificial intelligence, *National Science Review*, Volume 9(6), 2022.
- [22] Z. Hu, X. Ma, Z. Liu, E. Hovy, E. Xing, *Harnessing deep neural networks with logic rules*, arXiv:1603.06318v6, 2020.
- [23] A.K. Jain, J. Mao, K.M. Mohiuddin, Artificial neural networks: A tutorial, *Computer*, Vol. 29(3), pp. 31-44, 1996.
- [24] L. P. Kaelbling, M. L. Littman, A. W. Moore, Reinforcement learning: A survey, *Journal of Artificial Intelligence Research*, Vol. 4, pp. 237-285, 1996.
- [25] C. M. Keet, An introduction to ontology engineering. V1.5, 2020. [Disponible en ligne] <https://people.cs.uct.ac.za/~mkeet/files/OEbook.pdf> [Consulté le 25/02/2023]
- [26] G. Klir, B. Yuan, *Fuzzy sets and fuzzy logic*, DOI:10.5860/choice.33-2786, Prentice Hall, 1995.
- [27] E. van Krieken, E. Acar, F. van Harmelen, *Analyzing differentiable fuzzy implications*, arXiv preprint arXiv:2006.0347, 2020.
- [28] E. van Krieken, E. Acar, F. van Harmelen, Analyzing differentiable fuzzy logic operators, *Artificial Intelligence*, Volume 302, 2022.
- [29] R. Luo, N. Zhang, B. Han, L. Yang, *Context-Aware Zero-Shot Recognition*, Proceedings of the AAAI Conference on Artificial Intelligence, Vol. 34(07), DOI: 10.1609/aaai.v34i07.6841, 2020.
- [30] G. Marra, F. Gianni, M. Diligenti, M. Gori, Lyrics: A general interface layer to integrate logic inference and deep learning, *Proceedings Of ECML PKDD 2019*, Springer International Publishing, 2020.
- [31] Plan national de lutte contre les stupéfiants, Dossier de presse, 17 septembre 2019. [Disponible en ligne] <https://www.interieur.gouv.fr/Archives/Archives-des-dossiers/Plan-national-de-lutte-contre-les-stupefiants> [Consulté le 25/02/2023]
- [32] P.D. Magnus, *forall x: An Introduction to Formal Logic*, 2017. [Disponible en ligne] <https://www.fecundity.com/codex/forallx.pdf> [Consulté le 25/02/2023]
- [33] R. Mikut, M. Reischl. Data mining tools, *Wiley interdisciplinary reviews: data mining and knowledge discovery*, Vol. 1(5), pp. 431-443, 2011.
- [34] R. Manhaeve, S. Dumancic, A. Kimmig, T. Demeester, L. De Raedt, *DeepProbLog: Neural probabilistic logic programming*, Advances in Neural Information Processing Systems, Vol. 31, 2018.
- [35] A. Newell, H.A. Simon, Computer Science as Empirical Inquiry: Symbols and Search, *Communications of the ACM*, Vol. 19 (3), pp. 113–126, doi:10.1145/360018.360022, 1976
- [36] Qu Meng et Jian Tang. Probabilistic logic neural networks for reasoning, *Advances in neural information processing systems*, Vol. 32, pp.7710-7720, 2019.
- [37] L. De Raedt, A. Kimmig, H. Toivonen, *ProbLog: A probabilistic Prolog and its application in link discovery*, International Joint Conference on Artificial Intelligence (IJCAI), 2007.
- [38] S. Russell, P. Norvig, *Intelligence Artificielle – Une approche moderne*, Traduit par L. Miclet, F. Popineau, C. Cadet, 4<sup>e</sup> éd. Pearson, 2021.
- [39] R. Setiono, Extracting Rules from Neural Networks by Pruning and Hidden-Unit Splitting, *Neural Computation*, Vol. 9(1), pp. 205–225, 1997.
- [40] V. Schetinin, J.E. Fieldsend, D. Partridge, T.J. Coats, W.J. Krzanowski, R.M. Everson, T.C. Bailey, A. Hernandez, Confident interpretation of Bayesian decision tree ensembles for clinical applications, *IEEE Transactions on Information Technology in Biomedicine*, Vol. 11(3), 2007.
- [41] A. Silva, M. Gombolay, Encoding human domain knowledge to warm start reinforcement learning, *Association for the Advancement of Artificial Intelligence (AAAI)*, Vol. 35(6), pp. 5042–5050, arXiv:1902.06007v4, 2021.
- [42] R. Studer, V.R. Benjamins, D. Fensel, Knowledge engineering: principles and methods, *Data & knowledge engineering*, Vol. 25(1), Pp.161–197, 1998
- [43] D. S. Touretzky, BoltzCONS : Dynamic symbol structures in a connectionist network, *Artificial intelligence*, Vol. 46(1-2), pp. 5-46, 1990.
- [44] G. G. Towell, Symbolic knowledge and neural networks: Insertion, refinement and extraction, 1992.
- [45] G. G. Towell, J. W. Shavlik, Knowledge-based artificial neural networks, *Artificial intelligence*, Vol. 70(1-2), pp. 119-165, 1994.
- [46] W. Wang, V. W. Zheng, H. Yu, C. Miao, *A survey of zero-shot learning: Settings, methods, and applications*, ACM Transactions on Intelligent Systems and Technology (TIST), Vol. 10(2), pp. 1-37, DOI:10.1145/3293318, 2019.
- [47] D. Yu, B. Yang, D. Liu, H. Wang, S. Pan, *Recent Advances in Neural-symbolic Systems: A Survey*, arXiv:2111.08164, 2021.
- [48] Z.-H. Zhou, *Abductive learning: towards bridging machine learning and logical reasoning*, Science China Information Sciences, Vol. 62(7), pp. 1–3, 2019.
- [49] J. Xu, Z. Zhang, T. Friedman, Y. Liang, G. Broeck, A *Semantic Loss Function for Deep Learning with Symbolic Knowledge*, 35th Conference on Machine Learning (ICML 2018), Vol. 80, pp. 5502–5511, 2018.
- [50] Y. Zhang, C. Xinshi, Y. Yuan, A. Ramamurthy, B. Li, Y. Qi et L. Song, *Efficient probabilistic logic reasoning with graph neural networks*, arXiv preprint arXiv:2001.11850 (2020).