



**HAL**  
open science

# Modélisation d'une assistance décisionnelle basée sur l'intelligence artificielle pour les systèmes cyber-physiques : Application à la maintenance dans le domaine du Transport

Issam Mallouk

► **To cite this version:**

Issam Mallouk. Modélisation d'une assistance décisionnelle basée sur l'intelligence artificielle pour les systèmes cyber-physiques : Application à la maintenance dans le domaine du Transport. Automatique / Robotique. Université Polytechnique Hauts-de-France; Université Mohammed V (Rabat), 2023. Français. NNT : 2023UPHF0025 . tel-04442410

**HAL Id: tel-04442410**

**<https://theses.hal.science/tel-04442410>**

Submitted on 6 Feb 2024

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

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

## **Thèse de Doctorat en Cotutelle Internationale**

Pour obtenir le grade de :

### **DOCTEUR DE L'UNIVERSITE POLYTECHNIQUE HAUTS-DE-FRANCE ET L'INSA HAUTS-DE-FRANCE**

Discipline : Automatique et Informatique Industrielle

Et le grade de :

### **DOCTEUR DE L'UNIVERSITE MOHAMMED V**

Discipline : Informatique

**Présentée et soutenue par Issam MALLOUK**

**Le 15/12/2023, à Rabat**

#### **Ecole doctorale :**

L'Ecole Doctorale Polytechnique Hauts-de-France (ED PHF n°635)  
Centre d'Études Doctorales en Sciences et Technologies de la FSR. Centre de Recherches  
Mathématiques et Applications de Rabat

#### **Equipe de recherche, Laboratoire :**

Laboratoire d'Automatique, de Mécanique et d'Informatique Industrielles et Humaines (LAMIH– UMR 8201)  
Laboratoire de Mathématiques, Statistique et Applications, Equipe de calcul stochastique, statistique et  
numérique

## **Modélisation d'une assistance décisionnelle basée sur l'intelligence artificielle pour les systèmes cyber-physiques :**

### **Application à la maintenance dans le domaine du Transport**

#### **JURY**

##### **Présidente du jury**

Mme. Malika ZAZI

Professeure, ENSAM-Rabat, Université Mohammed V de Rabat

##### **Rapporteurs**

M. Philippe THOMAS

Maître de Conférences, HDR, Université de Lorraine

M. Hassan EL GHAZI

Professeur, Institut National des postes et télécommunications de Rabat

##### **Examineurs**

Mme. Hasna CHAMLAL

Professeure Habilité, FSAC, Université Hassan II de Casablanca

Mme. Malika ZAZI

Professeure, ENSAM-Rabat, Université Mohammed V de Rabat

M. Olivier SENECHAL

Professeur, Université Polytechnique Hauts-de-France

Mme. Maroua NOUIRI

Maîtresse de Conférences, Université de Nantes

##### **Directeurs de thèse**

M. Yves SALLEZ

Professeur, Université Polytechnique Hauts-de-France

M. Badr ABOU EL MAJD

Professeur, FSR, Université Mohammed V, Rabat

## ***LICENSE :***

Modélisation d'une assistance décisionnelle basée sur l'intelligence artificielle pour les systèmes cyber-physiques : Application à la maintenance dans le domaine du Transport © 2023 by Mallouk Issam is licensed under Attribution-NonCommercial 4.0 International. To view a copy of this license, visit <http://creativecommons.org/licenses/by-nc/4.0/>

## ***Remerciement***

Tout d'abord, je tiens à exprimer ma profonde gratitude et mes plus vifs remerciements aux directeurs de cette thèse, M. Yves SALLEZ et M. Badr ABOU EL MAJD. Leur rôle dans l'élaboration de ce travail dépasse largement le cadre d'une simple supervision académique. Leur engagement constant, leur expertise scientifique, leurs qualités humaines et soutien inconditionnel m'ont créé un environnement de travail positif et stimulant, sans lesquels la réalisation de ce travail n'aurait pas été possible. Je tiens à remercier particulièrement M. Thierry BERGER pour son soutien et aide pour la compréhension et l'élaboration de plusieurs approches utilisées dans le présent travail. Je tiens à remercier sincèrement M. Philippe THOMAS, Mme Hasna CHAMLAL, Mme. Malika ZAZI et M. Hassan EL GHAZI qui m'ont fait l'honneur d'accepter de juger ce travail et d'en être les rapporteurs et examinateur. Je remercie également Mme. Maroua NOURI et M. Olivier SENECHAL d'avoir accepté d'examiner mon mémoire et de faire partie du jury.

Je remercie infiniment, Kamal ABDERRAZAK CHANE, directeur général de la société STMF, pour sa précieuse assistance, sa disponibilité, ainsi que pour avoir mis à ma disposition les données et les outils nécessaires qui ont grandement contribué à la réalisation des résultats de cette thèse. Je tiens aussi à remercier Mustapha CHIGUER pour ses directives et ses orientations précieuses et pour son soutien inconditionnel. Je souhaite également remercier sincèrement Reynald COPIN, Christophe LANDSHEERE et Damien BAERT pour leur soutien et leur encadrement tout au long de la réalisation du projet de recherche en collaboration avec Alstom.

Je remercie également tous les membres du LAMIH et du LMSA. Je remercie particulièrement Vivien BASSELOT, Tarik CHARGUI, Miratul Khusna MUFIDA, Chaima ZORMATI, Damien TRENTESAUX, Abdessamad AIT EL CADI, Abdelghani BEKRAR, Sondes CHAABANE, Simon ENJALBERT, Eric DUCHENNE, Isabelle OLIVEIRA-MACHADO, Maureen COURBEZ, Melanie LECQ, Corinne AUREGGI. Je tiens à remercier aussi mon cher ami, frère et maître Omar TIKAT, pour son encouragement et son soutien et conseil précieux avant et durant la thèse. Je remercie aussi mes deux amis et frères Soufiane BENDHIBA et IssamEddine EL HASSANI pour leurs soutiens et conseils.

Enfin, je tiens à exprimer mon humble gratitude et reconnaissance envers toutes les personnes qui me sont les plus chères, et qui ont apporté une contribution inestimable depuis toujours et durant ce voyage académique. De manière spéciale, je voudrais dédier ce travail à ma mère, Aicha. Elle a été une source constante d'encouragement tout au long de ma carrière de recherche scientifique et c'est elle qui a suscité en moi un amour pour la recherche, la découverte et l'innovation et cela dès mon plus jeune âge et avec sa manière authentique et originale. Je voudrais également exprimer ma profonde reconnaissance envers mon père, El Makki, pour son soutien et encouragement permanent et pour ses sacrifices considérables durant chaque étape de ma vie, aussi envers mon grand frère Khalil qui est ma référence d'excellence, mes sœurs Sana et Imane qui ont été présentes à mes côtés à de nombreuses occasions. Je tiens à adresser des remerciements tout particuliers à ma femme Ahlam pour son sacrifice et sa patience tout au long de ma thèse. Ses encouragements, sa compréhension et son soutien ont été la lumière qui a guidé mes pas dans les moments les plus difficiles. Finalement, je remercie mon fils, Younes, qui est arrivé au début de ma thèse, illuminant cette période avec sa présence et avec son sourire magnifique. Sa présence et ses regards m'ont apporté un soutien émotionnel spécial.



## **Résumé Français :**

Les systèmes cyber-physiques (SCP) sont des systèmes complexes et interconnectés, où les technologies numériques convergent avec le monde physique, ayant révolutionné de nombreux secteurs d'activités. L'Internet des objets (IOT) a également favorisé la collecte massive de données participant ainsi au développement du "Big Data". Le développement de l'IOT et des SCP a cependant engendré des défis, principalement liés à la gestion massive de données et à la prise de décision. Le développement d'approches telles que le Data Analytics et le Machine Learning offre cependant des solutions en identifiant des modèles ou caractéristiques « cachés » au sein de ces données massives.

Le présent mémoire adresse cette problématique de prise de décision en utilisant les approches et techniques de l'Intelligence Artificielle et s'intéresse plus particulièrement au domaine applicatif du Transport. Les systèmes de transport modernes, considérés comme des Systèmes cyber physiques complexes, intègrent une grande variété d'équipements mécatroniques. Ils sont de plus en plus autonomes, dotés de capteurs leur permettant de percevoir leur environnement et de moyens permettant l'interaction avec les gestionnaires de la flotte. Une approche globale de gestion de la flotte permet d'améliorer diverses fonctions telles que la planification de la maintenance et la gestion des opérations.

La thèse s'intéresse aux boucles cybernétiques associées à l'exploitation des systèmes cyber physiques, en mettant l'accent sur l'activité de maintenance. Elle propose une assistance décisionnelle en caractérisant les boucles cybernétiques, spécifiant les besoins des décideurs, et développant des approches de Machine Learning tout en respectant des exigences de généricité et d'indépendance technologique. La modélisation de cette assistance repose sur une décomposition holonique du SCP et fait appel à la typologie de Rasmussen au niveau des traitements décisionnels. Un guide méthodologique accompagne cette démarche.

Les concepts proposés dans ces travaux de thèse ont été validés au travers de deux collaborations industrielles. Une première collaboration avec la société marocaine STMF a permis d'optimiser la maintenance d'une flotte de camions de transport de matières dangereuses. Une seconde collaboration avec ALSTOM vise à améliorer la croissance de fiabilité du matériel roulant ferroviaire en détectant des signaux avant-coureurs d'une défaillance.

**Mots clés :** Assistance décisionnelle, Système cyber-physique, Boucles cybernétiques, Intelligence artificielle, Maintenance.

## **Résumé anglais :**

Cyber-physical systems (PCS) are complex and interconnected systems, where digital technologies converge with the physical world, having revolutionized many sectors of activity. The Internet of Things (IOT) has also encouraged the massive collection of data, thus contributing to the development of "Big Data". However, the development of IOT and SCPs has created challenges, mainly related to massive data management and decision-making. The development of approaches such as Data Analytics and Machine Learning, however, offers solutions by identifying "hidden" patterns or characteristics within this massive data.

This thesis addresses the problem of decision-making by using the approaches and techniques of Artificial Intelligence and is particularly interested in the Transportation applicative field. Modern transport systems, considered as complex Cyber Physical Systems, incorporate a wide variety of mechatronic equipment. They are increasingly autonomous, equipped with sensors allowing them to perceive their environment and means allowing interaction with fleet managers. A holistic approach to fleet management helps improve various functions such as maintenance planning and operations management.

The thesis focuses on the cyber loops associated with the operation of cyber physical systems, with a focus on the maintenance activity. It offers decision-making assistance by characterizing cybernetic loops, specifying the needs of decision-makers, and developing Machine Learning approaches while respecting the requirements of genericity and technological independence. The modeling of this assistance is based on a holonic decomposition of the SCP and uses Rasmussen's typology at the level of decision making. A methodological guide accompanies this approach.

The concepts proposed in this thesis work have been validated through two industrial collaborations. A first collaboration with the Moroccan company STMF has made it possible to optimize the maintenance of a fleet of trucks transporting hazardous materials. A second collaboration with ALSTOM aims to improve the reliability growth of railway rolling stock by detecting warning signs of a failure.

**Keywords :** Decision support, Cyber-physical systems, Cybernetic loops, Artificial intelligence, Maintenance.

## **Table des Matières :**

<b>Introduction générale</b> .....	<b>11</b>
<b>Chapitre I Mise en contexte et exposé des problématiques</b> .....	<b>14</b>
Introduction .....	14
I/ Les systèmes cyber-physiques .....	14
I-1/ Notion de système cyber-physique et définitions .....	14
I-2/ Principes de fonctionnement .....	15
I-3/ Les systèmes cyber-physiques dans le domaine du transport .....	18
II/ Cycle de vie d'un système cyber-physique.....	19
II-1/ Notion de cycle de vie.....	19
II-2/ Gestion du cycle de vie et problématiques associées.....	21
II-3/ Focus sur la phase MOL .....	24
II-3-1/ Les différentes catégories de boucles cybernétiques .....	24
II-3-2/ L'activité de maintenance .....	26
III/ Analyse des boucles cybernétiques : l'IOT, le Big Data, le Data Analytics et le Machine Learning.....	27
III-1/ L'IOT.....	28
III-2/ Le Big Data.....	29
III-3/ Le Data Analytics .....	30
III-4/ Le Machine Learning et le Deep Learning .....	32
IV/ Problématiques scientifiques et contexte applicatif .....	33
IV-1/ Contexte industriel .....	33
IV-2/ Contribution scientifique de la thèse .....	34
V/ Conclusion du chapitre .....	36
<b>Chapitre II Etat de l'art</b> .....	<b>37</b>
Introduction .....	37
I/ Les outils analytics classiques.....	37
II/ Le Machine Learning .....	38
II-1/ L'apprentissage supervisé .....	40
II-2/ L'apprentissage non supervisé .....	42
II-3/ L'apprentissage par renforcement .....	45
III/ Le Deep Learning .....	46
IV/ Les outils IA pour la maintenance.....	49
IV-1/ Les différentes facettes analytics.....	49

IV-2/ Proposition d'un cadre tridimensionnel pour la modélisation et la classification des travaux.....	50
IV-3/ Les applications des outils analytics pour la maintenance .....	52
IV-3-1/ Maintenance prédictive .....	52
IV-3-2/ Détection d'anomalies .....	55
IV-3-3/ Optimisation de la maintenance.....	56
V/ Conclusion du chapitre .....	63
<b>Chapitre III Modélisation des processus décisionnels associés aux boucles cybernétiques</b>	<b>64</b>
Introduction .....	64
I/ Description d'un Système Humain-Cyber-Physique .....	64
I-1/ Fonctions primaires .....	65
I-2/ Fonctions secondaires .....	66
I-3/ Exemple illustratif.....	66
II/ Modélisation d'un Système Humain-Cyber-Physique .....	68
II-1/ Modèles associés à l'Humain et à la machine .....	68
II-2/ Modèles associés à la tâche.....	69
II-2-1/ Le modèle SRK .....	70
II-2-2/ Le modèle DIK.....	71
II-2-3/ Le modèle AADA.....	72
III/ Modélisation générique des processus décisionnels et de l'assistance associée .....	72
III-1/ Architecture holonique du système .....	73
III-1-1/ Principes de base de la modélisation holonique.....	73
III-2/ Modélisation de la boucle cybernétique associée à une fonction secondaire.....	75
III-3/ La place de l'assistance dans le processus décisionnel .....	77
III-4/ Exemples illustratifs .....	79
III-4-1/ Exemple n°1 : Assistance de type « reactive-based ».....	79
III-4-2/ Exemple n°2 : Assistance de type « Rule-based ».....	81
III-4-3/ Exemple n°3 : Assistance de type « Knowledge based » .....	83
IV/ Guide méthodologique .....	86
V/ Conclusion du chapitre .....	88
<b>Chapitre IV Conception de l'assistance décisionnelle</b> .....	<b>90</b>
Introduction .....	90
I/ Le cycle de développement de l'assistance.....	90
I-1/ La méthodologie KDD .....	90
I-2/ La méthodologie SEMMA .....	91

I-3/ La méthodologie CRISP-DM.....	92
I-4/ La méthodologie CPMAI.....	93
II/ Choix des algorithmes permettant l’obtention du modèle.....	96
II-1/ Approches exploitant des guides de choix.....	96
II-2/ L’approche Automated Machine Learning (AutoML).....	98
II-2-1/ Le principe de fonctionnement.....	98
II-2-2/ Exemples d’utilisation.....	101
II-2-3/ Architecture de développement de l’assistance avec AutoML.....	101
III/ Conclusion du chapitre.....	103
<b>Chapitre V Applications des concepts.....</b>	<b>104</b>
Introduction.....	104
I/ Application n°1 : Optimisation de la maintenance pour STMF.....	104
I-1/ Application du guide méthodologique et analyse des fonctions secondaires.....	106
I-1-1/ Etape 1 : Identification du système et des sous-systèmes ciblés.....	106
I-1-2/ Etape 2 : Identification des stakeholders.....	107
I-1-3/ Etape 3 : Détermination des besoins pour chaque stakeholder.....	108
I-2/ Itération sur besoin 1.....	110
I-2-1/ Analyse de la fonction secondaire liée au besoin 1.....	110
I-2-2/ La génération de l’assistance décisionnelle relative au besoin 1.....	112
I-2-3/ L’exploitation de l’assistance décisionnelle et la coopération Humain-Système- Cyber-Physique relative au besoin 1.....	115
I-3/ Itération sur besoin 2.....	116
I-3-1/ Analyse de la fonction secondaire liée au besoin 2.....	116
I-3-2/ La génération de l’assistance décisionnelle relative au besoin 2.....	117
I-3-3/ L’exploitation de l’assistance décisionnelle et la coopération Humain-Système- Cyber-Physique relative au besoin 2.....	121
I-3-4/ Expérimentation de l’assistance décisionnelle.....	121
II/ Application n°2 : Amélioration de la croissance de fiabilité pour Alstom.....	125
II-1/ Application du guide méthodologique et analyse des fonctions secondaires.....	126
II-1-1/ Etape 1 : Identification du système et des sous-systèmes ciblés.....	126
II-1-2/ Etape 2 : Identification des stakeholders.....	127
II-1-3/ Etape 3 : Détermination des besoins de l’ingénieur « Fiabiliste ».....	127
II-1-4/ Etape 4 : Identification de la catégorie associée à la boucle cybernétique.....	127
II-1-5/ Etape 5 : Caractérisation de l’activité décisionnelle.....	127
II-1-6/ Etape 6 : Caractérisation de l’assistance décisionnelle.....	128

II-1-7/ Etape 7 : Caractérisation du partage d'activités Humain / Machine .....	128
II-1-8/ Etape 8 : Description des éléments informationnels .....	128
II-2/ La génération de l'assistance décisionnelle relative au besoin .....	129
II-2-1/ Présentation et compréhension du jeu de données .....	129
II-2-2/ Les événements HVAC .....	132
II-2-3/ Les événements INFS des écrans .....	132
II-2-4/ Lien entre HVAC, INFS et DCU .....	133
II-2-5/ Préparation des données .....	134
II-2-6/ Développement du modèle .....	138
II-3/ L'exploitation de l'assistance décisionnelle et la coopération Humain-Système-Cyber-Physique .....	138
III/ Conclusion du chapitre .....	140
<b>Conclusion générale</b> .....	<b>142</b>
<b>Références</b> .....	<b>144</b>

## **Table des figures :**

Figure 0-1: La structure du présent mémoire .....	12
Figure I-1 Principe d'un système cyber-physique d'après (F.-Y. Wang 2010) .....	15
Figure I-2: Illustration d'un système cyber-physique industriel (extrait de (Cardin, Derigent, and Trentesaux 2022)) .....	16
Figure I-3: L'architecture 5C proposée dans (J. Lee, Bagheri, and Kao 2015) .....	17
Figure I-4: Système cyber physique de Transport (Exemple Thalès) .....	19
Figure I-5: Cycle de vie d'un système cyber-physique (vu comme un produit) .....	21
Figure I-6 : Les différents flux dans une approche Closed-loop PLM .....	24
Figure I-7: Les trois types de boucles cybernétiques .....	25
Figure I-8: Contraintes associées à la maintenance d'une flotte de SCP dans le domaine du transport (J. W. Mbuli 2019) .....	27
Figure I-9: Positionnement des différentes approches vis-à-vis d'une boucle cybernétique ...	28
Figure I-10: Les différentes couches de l'architecture IoT (Bandyopadhyay and Sen 2011)..	29
Figure I-11: Illustration des 3 V (Volume / Variété / Vitesse) .....	30
Figure I-12 : Les différentes facettes du Data Analytics (Delen and Ram 2018) .....	31
Figure I-13: Positionnement du Machine Learning et du Deep Learning .....	32
Figure I-14: Illustration des problématiques scientifiques .....	35
Figure II-1: les différents types du Machine Learning .....	39
Figure II-2: Le principe de fonctionnement de l'apprentissage supervisé .....	40
Figure II-3: Le principe de fonctionnement de l'apprentissage non supervisé .....	42
Figure II-4: Exemple de classification hiérarchique (Barutcuoglu and DeCoro 2006) .....	43
Figure II-5: Le principe de fonctionnement du l'apprentissage par renforcement .....	45
Figure II-6: Le principe de fonctionnement de l'apprentissage semi-supervisé .....	46
Figure II-7: Schéma d'un réseau de neurones récurrents à une unité de l'entrée à la sortie du réseau .....	48
Figure II-8: Schéma général d'un GAN .....	48

Figure II-9: Niveaux de maturité et de complexité de la gestion basée sur la connaissance ...	49
Figure II-10: Cadre tridimensionnel pour l'analyse des travaux scientifiques .....	51
Figure II-11: Taxonomie de la maintenance prédictive .....	53
Figure II-12: Instanciation du cadre d'analyse pour le travail (Haddad, Sandborn, and Pecht 2014).....	54
Figure II-13: L'architecture proposée par (Bampoula et al. 2021).....	54
Figure II-14: Instanciation du cadre d'analyse pour le travail (Yang et al. 2022).....	55
Figure II-15: L'architecture proposée par (Javed et al. 2021) .....	56
Figure II-16: L'approche proposée par (Morariu et al. 2020) .....	57
Figure II-17: Instanciation du cadre d'analyse pour le travail (Morariu et al. 2020) .....	58
Figure II-18: Instanciation du cadre d'analyse pour le travail (Ridwan and Purnomo 2022) ..	58
Figure II-19: L'architecture proposée par (Lopes Gerum, Altay, and Baykal-Gürsoy 2019) ..	59
Figure III-1: Illustration d'un Système Humain-Cyber-Physique.....	65
Figure III-2: Instanciation du modèle SHCP dans le cadre d'une application de transport routier .....	67
Figure III-3: Modèles génériques : Humain (à droite) et machine (à gauche).....	69
Figure III-4: Articulation des trois modèles DIK, SRK et AADA.....	70
Figure III-5: Modèle de Rasmussen simplifié (Waterson, Le Coze, and Andersen 2017) .....	71
Figure III-6: Illustration de la décomposition d'un système $S_1$ en sous-systèmes .....	73
Figure III-7: Illustration d'un holon $H_i$ pour un système $S_i$ non décomposable .....	74
Figure III-8: Architecture holonique appliquée à un système ferroviaire .....	75
Figure III-9: Modèle de la boucle cybernétique associée à un holon $H_i$ .....	77
Figure III-10: Illustration des phases de conception et d'exploitation de l'assistance.....	78
Figure III-11: Détection de défauts par vision embarquée.....	80
Figure III-12: Modèle AADA relatif à l'exemple n°1 .....	80
Figure III-13: Approche holonique de surveillance / diagnostic.....	81
Figure III-14: Génération des règles d'inhibition (d'après (Le Mortellec 2013)).....	82
Figure III-15: Modèle AADA relatif à l'exemple n°2 .....	83
Figure III-16: Mise en évidence de liens sémantiques .....	84
Figure III-17: Architecture de surveillance / diagnostic .....	84
Figure III-18: Modèle AADA relatif à l'exemple n°3 .....	85
Figure III-19: Visualisation d'une instance de l'ontologie .....	85
Figure III-20: Les huit étapes du guide méthodologique .....	88
Figure IV-1: Vue d'ensemble des étapes du processus KDD (Fayyad, Piatetsky-Shapiro, and Smyth 1996).....	91
Figure IV-2: Les étapes de la méthode SEMMA .....	91
Figure IV-3: Le cycle de vie de la génération de la connaissance selon CRISP-DM.....	92
Figure IV-4: Les différentes étapes de la méthodologie CPMAI.....	94
Figure IV-5: Guide de choix d'algorithme ML proposé par Scikit-Learn.....	97
Figure IV-6: Guide de choix d'algorithme pour un Modèle ML proposé par Microsoft .....	98
Figure IV-7: Le workflow AutoML par rapport au workflow du Machine Learning traditionnel. ....	99
Figure IV-8: Les étapes successives du processus AutoML .....	100
Figure IV-9: Phase de conception via AutoML et d'exploitation de l'assistance .....	102
Figure V-1: Des véhicules citerne de STMF.....	105
Figure V-2: Arbre de décomposition .....	106
Figure V-3: Architecture holonique associée au système et aux sous-systèmes ciblés .....	107

Figure V-4: Exemple de jauge d'usure pour pneus .....	108
Figure V-5: Les différents types d'usure sur essieux remorque.....	109
Figure V-6: Les stratégies de permutation possibles .....	109
Figure V-7: Logigramme décrivant l'activité reactive-based du Besoin 1 STMF.....	111
Figure V-8: Modèle AADA pour le Besoin 1 .....	111
Figure V-9: Extrait de la base de données historique des interventions montage/démontage des pneus.....	112
Figure V-10: Illustration du paramétrage AutoML selon le besoin 1 du cas applicatif STMF .....	113
Figure V-11: Code associé au développement du modèle AutoML pour le besoin 1 .....	114
Figure V-12: Comparaison entre les données réelles et les données prédites avec le modèle proposé par le processus AutoML.....	114
Figure V-13: Modèle SHCP relatif au besoin 1 .....	115
Figure V-14: Modèle AADA pour le besoin 2.....	116
Figure V-15: Extrait de la base de données historique des interventions de permutation des pneus.....	117
Figure V-16: Illustration du paramétrage AutoML pour le besoin 2 du cas applicatif STMF .....	119
Figure V-17: Code associé au développement du modèle autoML pour le besoin 2.....	119
Figure V-18: L'arbre de décision généré et extrait des règles .....	120
Figure V-19: Modèle HCP relatif au besoin 2 .....	121
Figure V-20: Interface de l'outil de simulation .....	122
Figure V-21 : La profondeur des sculptures sur un même essieu .....	123
Figure V-22: Le flux des données brutes - Informations via Alstom. Inspiré de (Dubé 2007) .....	125
Figure V-23: Exemple de systèmes surveillés .....	126
Figure V-24: Modèle holonique appliqué au système cible DCU .....	127
Figure V-25: Modèle AADA pour le besoin d'Alstom .....	128
Figure V-26: Capture du système d'exploitation des données d'Alstom.....	129
Figure V-27: Capture du jeu de données.....	130
Figure V-28: Fréquence des autres systèmes par rapport aux évènements DCU .....	130
Figure V-29: Représentation géographique de la fréquence des événements.....	131
Figure V-30: Nombre d'évènement DCU et HVAC sur les 30 jours.....	132
Figure V-31: Fréquence des Event INFS et DCU .....	132
Figure V-32: Groupes de fréquence INFS-DCU.....	133
Figure V-33: Fréquence par jour des événements HVAC, INFS et DCU .....	133
Figure V-34: Lien entre HVAC, INFS et DCU .....	134
Figure V-35: Fréquence des évènements par jours .....	135
Figure V-36: Tableau croisé des fréquences Jour/Système.....	136
Figure V-37: Proportion des systèmes (DCU = 1,34%).....	137
Figure V-38: Jeu de données pour l'apprentissage .....	137
Figure V-39: Comparaison des critères d'évaluation du modèle prédictif.....	138
Figure V-40: La matrice de confusion liée au modèle prédictif.....	138
Figure V-41: Modèle HCP relatif au besoin d'Alstom .....	139
Figure V-42: Outil mise à la disposition du stakeholder pour l'interprétation des connaissances .....	140

## Introduction générale

Les systèmes cyber-physiques (SCP) représentent un domaine émergent et en constante évolution, où les technologies numériques se fondent avec le monde physique pour créer des systèmes complexes et interconnectés. Les SCP ont révolutionné de nombreux domaines, mais ont également généré de nouveaux défis, en particulier en raison de la génération massive de données. L'émergence de l'Internet des objets (IoT) a permis une collecte massive de données provenant des SCP, donnant naissance au concept de "Big Data". La quantité et la complexité de ces données peuvent rapidement dépasser la capacité humaine à les analyser efficacement, rendant la prise de décision difficile et sujette à l'erreur.

Tout au long de leur cycle de vie, les SCP interagissent avec de nombreux acteurs ou parties prenantes (dénommés "stakeholders" dans la suite du mémoire). Ces derniers sont confrontés à un défi majeur lorsqu'il s'agit de prendre des décisions dans un contexte où les données sont abondantes et variées. Les décideurs peuvent cependant s'appuyer sur des technologies avancées telles que le Data Analytics et le Machine Learning. Ces approches permettent de traiter de grands volumes de données et de découvrir des modèles cachés, facilitant ainsi la prise de décision. L'analyse des données provenant de multiples sources, comme les instances d'utilisation du SCP, les retours clients et les expériences passées, offre une vue globale et approfondie du système, permettant aux décideurs d'agir en connaissance de cause.

Le présent mémoire s'intéresse plus particulièrement au domaine applicatif du Transport. Les systèmes de transport modernes peuvent être qualifiés de systèmes cyber-physiques complexes, composés de multiples sous-systèmes interconnectés. Ces systèmes intègrent une grande variété d'équipements mécatroniques et se déploient sur de vastes zones géographiques, ce qui pose des défis de connectivité réseau et de gestion à distance. Ils sont de plus en plus autonomes, dotés d'intelligence artificielle, de capteurs leur permettant de percevoir leur environnement et de moyens permettant l'interaction avec les gestionnaires de flotte. Une approche globale de gestion de la flotte permet d'améliorer diverses fonctions telles que la planification de la maintenance et la gestion des opérations.

La présente thèse se concentre sur les boucles cybernétiques reliant un système cible et les différents acteurs concernés pendant sa phase d'utilisation, en se focalisant principalement sur les préoccupations liées à la maintenance. La contribution scientifique porte principalement sur la proposition d'une assistance décisionnelle aux acteurs impliqués dans ces boucles cybernétiques. Pour cela, il est nécessaire de caractériser ces boucles en identifiant les stakeholders et en définissant les flux d'information. Ensuite, il faut spécifier les besoins en assistance des acteurs en prenant en compte les aspects matériels et logiciels de l'assistance ainsi que les aspects humains. Enfin, il faut proposer des approches de Machine Learning pour développer cette assistance décisionnelle tout en respectant des exigences de généricité, d'applicabilité et d'indépendance technologique. Un guide méthodologique accompagnera cette démarche tout au long de l'analyse des boucles cybernétiques et des assistances décisionnelles associées.

Dans le domaine applicatif du Transport, cette thèse a donné lieu à deux collaborations industrielles permettant d'instancier la contribution scientifique. La première concerne la société STMF, leader marocain du transport de matières dangereuses, qui cherche à optimiser la gestion de sa flotte de camions et de pneumatiques pour améliorer la sécurité et réduire les coûts d'exploitation. Un outil d'assistance décisionnelle a été développé pour aider le

responsable de la maintenance à prendre des décisions éclairées. La seconde collaboration, avec la société Alstom, vise à accroître la fiabilité du matériel roulant ferroviaire. Les constructeurs sont confrontés à la nécessité de garantir une fiabilité élevée dès le début de la mise en service pour répondre aux besoins de leurs clients. Les travaux se sont concentrés sur l'analyse des données de pannes pour détecter des signaux avant-coureurs de défaillance, permettant ainsi d'améliorer le processus de conception de nouveaux matériels ferroviaires.

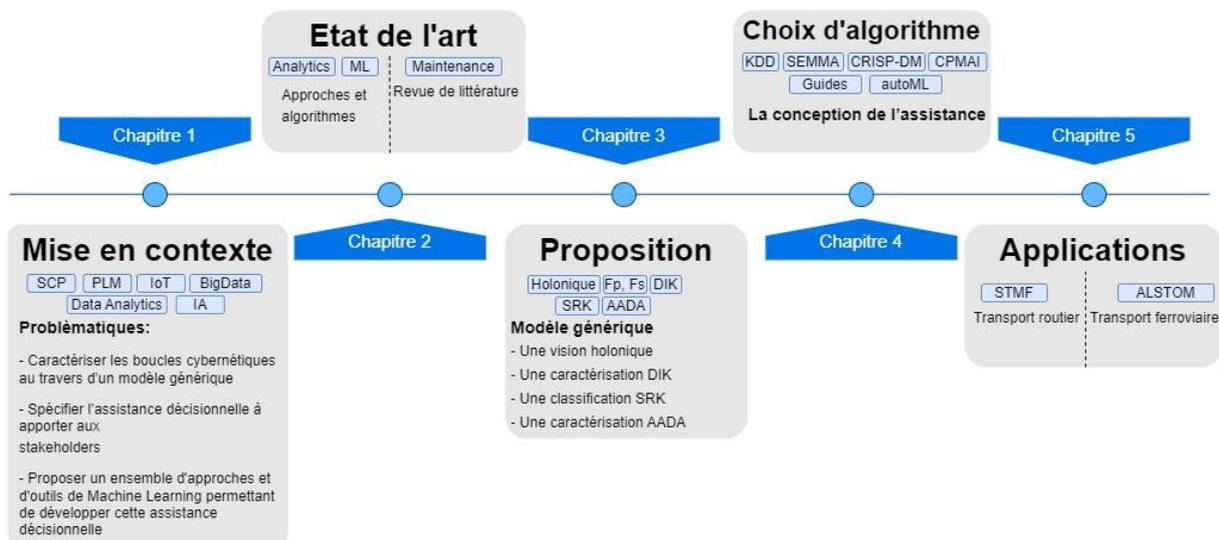


Figure 0-1: La structure du présent mémoire

La figure ci-dessus présente la structure du présent mémoire qui se compose de cinq chapitres :

Le premier chapitre précise le contexte de l'étude. Les systèmes cyber-physiques (SCP) et leur principe de fonctionnement sont présentés. L'accent est mis sur les systèmes de transport modernes pouvant être qualifiés de systèmes cyber-physiques complexes. Les problématiques associées à la gestion du cycle de vie de ces systèmes cyber-physiques sont également mises en évidence. Les approches IOT, Big Data, Data Analytics ou Machine Learning au niveau des boucles cybernétiques, permettant aux différents stakeholders de prendre des décisions au regard d'un SCP, sont positionnées. Le premier chapitre se conclut par une présentation des problématiques industrielle et scientifique. La problématique scientifique s'intéressant à la conception et à la mise en œuvre d'une assistance décisionnelle pour les stakeholders est décomposée en un ensemble de questionnements à considérer dans le cadre d'une approche générique.

Le deuxième chapitre est dédié à un approfondissement des approches Analytics introduites très succinctement dans le premier chapitre. Les outils analytics classiques sont d'abord brièvement présentés. Une présentation des approches de Machine Learning et des techniques du Deep Learning est ensuite réalisée. Enfin, un cadre d'analyse est proposé en support d'une revue de la littérature consacrée aux applications des outils Analytics dans le domaine de la maintenance.

Le troisième chapitre est consacré à la présentation de notre proposition qui se veut un prolongement et un approfondissement de travaux antérieurs menés au sein de l'équipe. Dans le cadre de ces travaux de thèse, l'accent est mis sur le développement d'une assistance

décisionnelle pouvant être apportée aux stakeholders. Le produit considéré est un SCP tel que décrit au premier chapitre. Un guide méthodologique est également proposé servant de cadre conceptuel pour le déploiement des approches proposées.

Après avoir présenté dans le troisième chapitre le positionnement de l'assistance décisionnelle au sein des boucles cybernétiques, le quatrième chapitre est consacré aux différentes approches permettant de concevoir cette assistance. Les méthodologies classiques, les guides de choix et une nouvelle approche nommée « Automated Machine Learning » (AutoML) sont successivement présentés. L'accent est plus particulièrement mis sur la présentation de l'approche novatrice AutoML permettant à un stakeholder de développer une assistance sans connaissance approfondie des différentes méthodes de Machine Learning.

Le cinquième chapitre présente deux cas applicatifs relevant du domaine du transport routier et ferroviaire réalisés en partenariat avec les sociétés STMF et Alstom. Le guide méthodologique est instancié et les concepts et méthodes présentés dans les chapitres précédents sont déployés.

Enfin, après un rappel et une synthèse des apports de nos travaux, un ensemble de perspectives de recherche, à court et moyen termes, est proposé dans la conclusion générale.

# Chapitre I

## Mise en contexte et exposé des problématiques

### Introduction

L'objectif de ce premier chapitre est de présenter le contexte de nos travaux et d'introduire les concepts et approches usités dans le domaine encore récent des systèmes cyber-physiques. L'accent sera mis sur la présence dans ces systèmes de boucles cybernétiques permettant de positionner nos travaux dans les domaines du Data Analytics et du Machine Learning.

La première partie de ce chapitre est dédiée à une présentation du concept de système cyber-physique (abrégé en SCP dans la suite du mémoire). Quelques définitions et les principes globaux de fonctionnement d'un SCP sont successivement présentés. L'accent est mis sur l'utilisation des SCP dans le domaine du Transport qui constitue le champ applicatif de nos travaux.

La seconde partie se concentre sur le cycle de vie d'un SCP, les problématiques associées et donne un aperçu de l'approche Closed-loop PLM. L'emphase est mise sur la phase d'usage du SCP et plus particulièrement sur les activités de maintenance.

Dans la troisième partie, sont présentés les approches IOT, Big Data, Data Analytics et Machine Learning utilisées dans la mise en œuvre des boucles cybernétiques associées au SCP.

Enfin dans la dernière partie, la problématique industrielle ainsi que les problématiques scientifiques de Recherche attendantes sont détaillées.

### I/ Les systèmes cyber-physiques

#### I-1/ Notion de système cyber-physique et définitions

La notion de système cyber-physique est apparue lors de la première décennie des années 2000 (E. A. Lee 2006) et a connu un réel engouement au sein de la communauté internationale. Un SCP repose sur le principe consistant à combiner des systèmes embarqués, des entités physiques et informationnelles ainsi que des humains en les connectant via internet (Becker and Stern 2016). Il résulte globalement de la convergence entre les technologies liées au contrôle et à l'automatisation des systèmes (i.e. OT : Operational Technology) et les technologies de l'information (i.e. IT : Information Technology) ayant usuellement Internet comme support des communications.

Les systèmes cyber-physiques sont considérés comme un levier permettant de mettre en œuvre la prochaine révolution sociétale et industrielle (Rajkumar et al. 2010) et ont des applications dans nombre de domaines : les transports (ex : développement des véhicules autonomes), l'énergie (ex : exploitation de smart grids), l'industrie (ex : systèmes de production reconfigurables), la santé (ex : surveillance du circuit du médicament) ou encore le secteur du bâtiment (ex : développement de bâtiments « intelligents »).

Le concept de SCP s'est affiné au fil des travaux de Recherche et plusieurs caractérisations et définitions ont été proposées :

Dans (E. A. Lee 2006), l'auteur argue que les SCP interagissent avec leur environnement, captent des données, les traitent et au travers d'une boucle de rétroaction contrôlent ou influencent le processus auquel ils sont associés. Il précise que les SCP peuvent être considérés selon différentes échelles, de systèmes de petite dimension (ex : pace maker) jusqu'à des systèmes de grande dimension (ex : smart-grid pour la distribution d'énergie).

D'après (F.-Y. Wang 2010), le concept de système cyber-physique est défini comme résultant du couplage de trois éléments (voir Figure I-1) :

- Des caractéristiques de « Communication » (ex. filaires, sans-fils, sécurisés, temps-réel, Homme-Machine...).
- Des traitements « Computing » (ex. analyse statistique, approches utilisant l'Intelligence artificielle, aide à la décision...).
- Des contrôles « Control » (ex. commande, pilotage...) autour d'un système réel / physique qui est généralement le siège d'un phénomène physique.

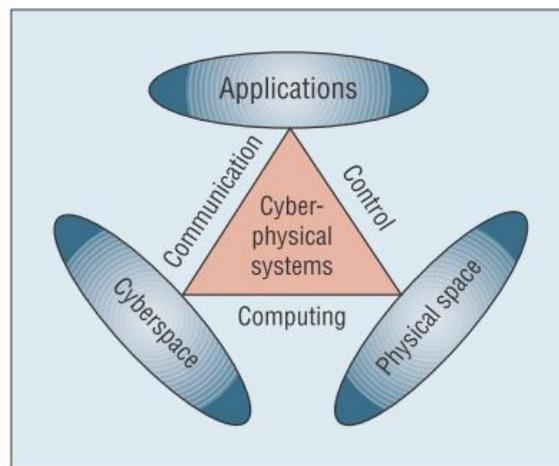


Figure I-1 Principe d'un système cyber-physique d'après (F.-Y. Wang 2010)

Dans (Monostori 2014), le concept de service est également introduit : « Les SCP sont des systèmes composés d'entités collaboratives, dotées de capacités de calculs, qui sont liées au monde physique et aux phénomènes qui s'y produisent, fournissant et utilisant à la fois les services de mise à disposition et de traitement de données disponibles sur le réseau ».

Plus récemment, dans (Cardin, Derigent, and Trentesaux 2022), les auteurs proposent la définition suivante d'un Système Cyber-Physique Industriel :

« Les systèmes cyber-physiques industriels sont constitués d'éléments physiques avec leurs systèmes de contrôle, offrant et consommant des services le long d'une chaîne de valeur, intégrés à des systèmes numériques avec des moyens d'analyse et de reconfiguration en ligne de ces éléments ».

Cette dernière définition trouve tout son sens en se référant à la Figure I-2 qui offre une modélisation relativement générique d'un système cyber-physique industriel.

## I-2/ Principes de fonctionnement

Dans la représentation donnée à la Figure I-2, extraite de (Cardin, Derigent, and Trentesaux 2022), la partie physique et la partie cyber sont clairement découplées et leurs objectifs différenciés :

- La partie « physique » assure le contrôle en temps réel de l'activité associée au système cyber-physique. On y distingue la partie « opérative » constituée de différentes entités assurant l'activité proprement dite (ex : fabrication dans le cas de SCP de production) et la partie « commande » assurant le contrôle / commande de la partie opérative.
- La partie « cyber » effectue une évaluation dynamique des performances de la partie « physique » et peut au besoin modifier (ex. ajustement de paramètres) ou reconfigurer (ex. modifications fonctionnelles) la partie Commande et/ou reconfigurer la partie Opérative (ex : systèmes de production reconfigurables).

Au sein de la partie « physique », l'accent est mis sur les constituants artificiels et humains de la partie opérative à contrôler in fine. Dépendant du domaine applicatif, ces constituants sont des ressources (ex : machines, véhicules, etc.), des produits (produits manufacturés, médicaments, matériaux de construction, colis, etc.) et des êtres humains (opérateurs, utilisateurs, etc.). Ces derniers contribuent à la gestion opérationnelle de la partie opérative. A partir de ces constituants, des données sont envoyées à un système de contrôle, par exemple via des capteurs ou des entrées informatiques (ex. clavier, écran tactile). Ce système de contrôle envoie à son tour un ensemble de consignes et d'ordres aux constituants artificiels et humains afin d'atteindre les objectifs souhaités au niveau du système cyber-physique industriel.

De cette partie « physique », un ensemble de données remonte vers la partie « cyber ». Après traitement, correspondant généralement à une extraction de connaissances, les données et/ou connaissances sont mises à disposition d'un processus d'analyse, qui peut généralement faire appel à une expertise humaine. Le but de ce processus d'analyse est d'évaluer si le pilotage ou la configuration, tant physique que logicielle, de la partie physique est adéquate à la situation rencontrée. Si ce n'est pas le cas, une décision de reconfiguration de tout ou partie de la partie « physique » (éléments physiques ou système de contrôle) peut être alors prise.

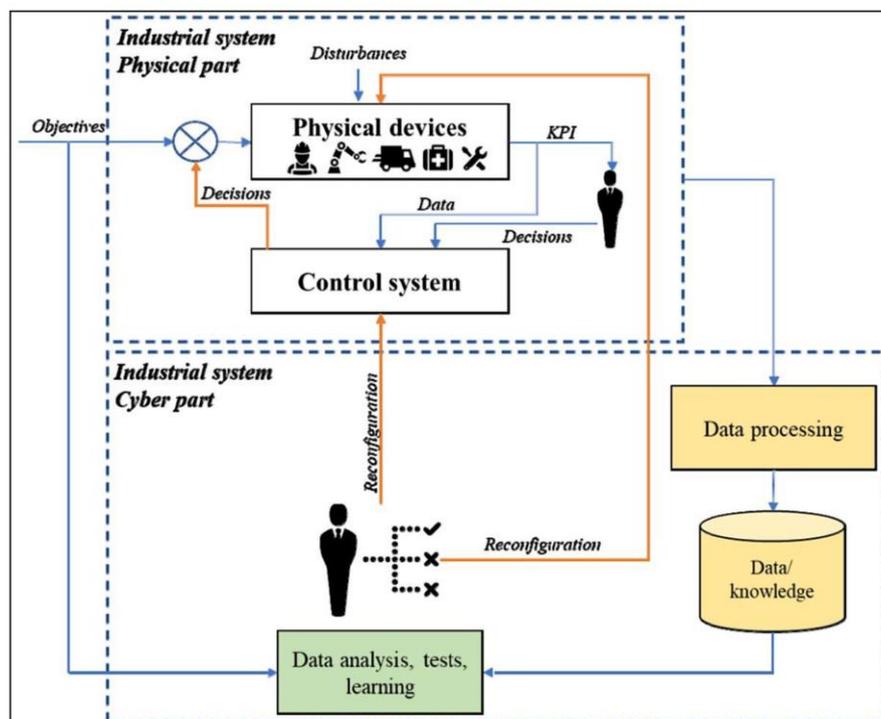


Figure I-2: Illustration d'un système cyber-physique industriel (extrait de (Cardin, Derigent, and Trentesaux 2022))

L'architecture 5C proposée dans (J. Lee, Bagheri, and Kao 2015) reprend les principes de fonctionnement d'un SCP en distinguant cinq niveaux afin d'établir une typologie (Figure I-3) :

- Au niveau Connexion, l'accent est mis sur l'acquisition de données précises et fiables à partir d'éléments de la partie « physique » (ex : machine), de leurs composants ou de réseaux de capteurs.
- Le niveau Conversion vise à traiter les données acquises et à les transformer en informations de plus haut niveau.
- Au niveau Cyber, le SCP est capable d'interagir en réseau avec le niveau « conversion » d'autres SCP afin d'enrichir le traitement des informations.
- En ce qui concerne le niveau Cognition, le SCP est capable de générer une connaissance approfondie du système surveillé, d'établir un diagnostic et de les présenter à des utilisateurs experts de façon à prendre une décision.
- Enfin, le niveau Configuration correspond à un niveau où le SCP est suffisamment évolué pour pouvoir s'adapter en cas de perturbation et éventuellement se reconfigurer.

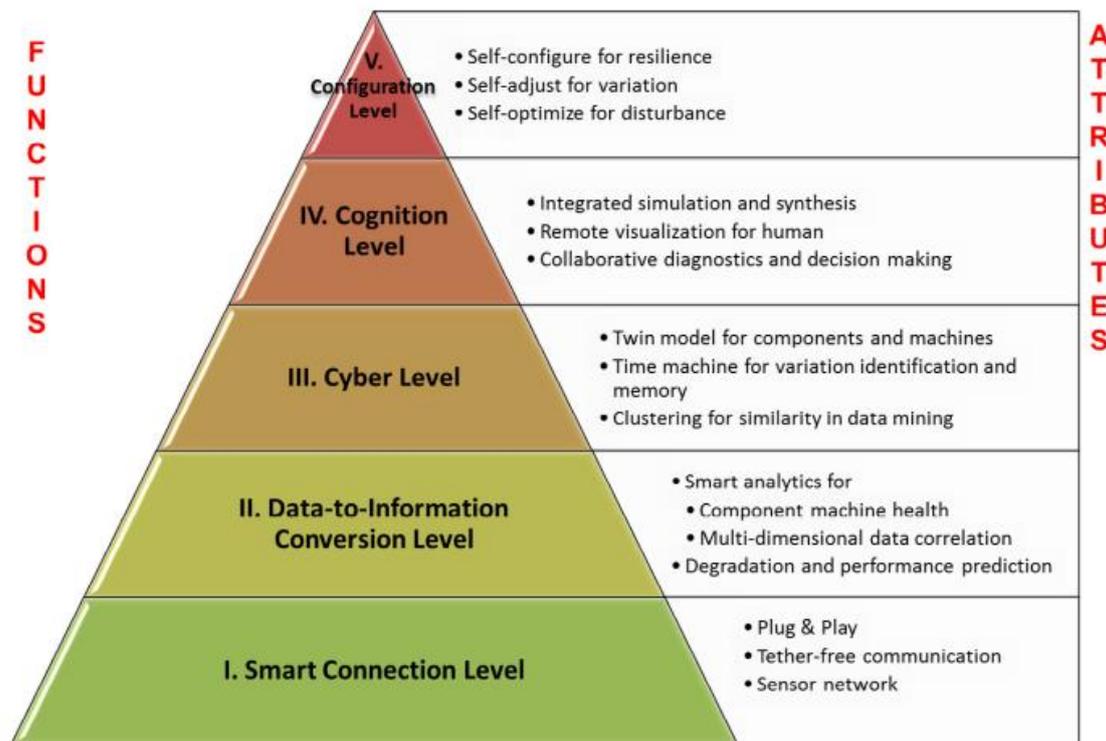


Figure I-3: L'architecture 5C proposée dans (J. Lee, Bagheri, and Kao 2015)

Un système cyber-physique, quel que soit le domaine d'application (manufacturier, transport ou autre), est donc avant tout un système, qui est le siège de boucles cybernétiques selon Wiener (1948). Le concept mature de boucle cybernétique est pertinent pour de nombreux types de systèmes (par exemple, mécaniques, physiques, biologiques, cognitifs, sociaux...). Une boucle existe à partir du moment où un acteur a une préoccupation vis-à-vis du système ou d'un de ses composants ou sur une propriété ou performance de ce système. Au sein d'un système (qui peut être composé récursivement de sous-systèmes), ces boucles cybernétiques sont supportées par des technologies et/ou des humains.

Par conséquent, il existe de nombreuses boucles, mises en œuvre à la fois dans les parties « physique » et « cyber ». Au sein de la partie « physique », ces boucles sont liées au contrôle-

commande du système et sont largement étudiées et généralement bien maîtrisées. Au sein de la partie « cyber », les boucles permettent d'évaluer et éventuellement de faire évoluer le système de contrôle, via par exemple des approches basées sur la simulation. Ces boucles, idéalement réalisées automatiquement, permettent de différencier un système cyber-physique d'un système plus classique.

Les boucles au niveau « cyber » font l'objet actuellement d'importants efforts de Recherche et nos travaux de thèse s'inscrivent dans ce cadre. Nous nous intéresserons plus particulièrement à des flottes de systèmes cyber-physiques utilisés dans le domaine du transport (ex : flotte de camions, flotte de trains de voyageurs). Ces derniers font l'objet de la section suivante.

### **I-3/ Les systèmes cyber-physiques dans le domaine du transport**

Les systèmes de transport modernes peuvent être qualifiés de systèmes cyber-physiques complexes (Deka et al. 2018). Une flotte de SCP peut être considérée comme un ensemble/système de plusieurs SCP, chaque SCP étant composé de sous-systèmes ou d'équipements similaires (J. Mbuli et al. 2018). Dans (Cardin, Derigent, and Trentesaux 2022), les auteurs mettent en évidence plusieurs facteurs de complexité au niveau d'une flotte de SCP :

- Les systèmes de transport sont des systèmes d'ingénierie complexes qui intègrent divers équipements mécatronique (ex : portes automatiques, systèmes de traction, climatisations...). Une flotte entière de systèmes de transport peut être considérée comme un « système de systèmes ».
- Les systèmes de transport sont mobiles et communicants. Ils évoluent bien souvent sur une large zone géographique, dans des environnements non contrôlés et ouverts. Cette mobilité entraîne des problèmes supplémentaires pour assurer une bonne connectivité réseau entre les SCP et les systèmes de gestion de la flotte situés à distance.
- Ces systèmes de transport intègrent de plus en plus d'intelligence et sont désormais capables d'exhiber un degré important d'autonomie. La Figure I-4 illustre la vision de la société Thalès dans le domaine novateur des trains « autonomes ». Bardés de capteurs capables d'appréhender leur environnement, et pilotés « localement » par des systèmes embarqués utilisant des approches issues du domaine de l'Intelligence Artificielle, ces systèmes communiquent également abondamment avec les gestionnaires de flotte situés à distance.

La gestion de ces systèmes mobiles doit être appréhendée au niveau « global » de la flotte. Cette gestion globale est considérée comme particulièrement pertinente car elle permet d'améliorer les fonctions d'acquisition, de diagnostic, de pronostic, de planification de la maintenance, d'allocation des ressources et de gestion des opérations (D. Trentesaux et al. 2015; J. Mbuli et al. 2018; Fadil, Trentesaux, and Branger 2019).

Cependant l'adoption de l'approche SCP dans le domaine du transport soulève nombre de difficultés : cybersécurité des données et des informations de pilotage mais aussi retour sur investissement. En effet, le déploiement d'un espace « cyber » au niveau d'une flotte de SCP est coûteux. Il est donc important que d'importants gains sur le plan financier (ex : réduction des coûts d'exploitation) ou environnemental (ex : réduction des émissions polluantes) puissent être dégagés.

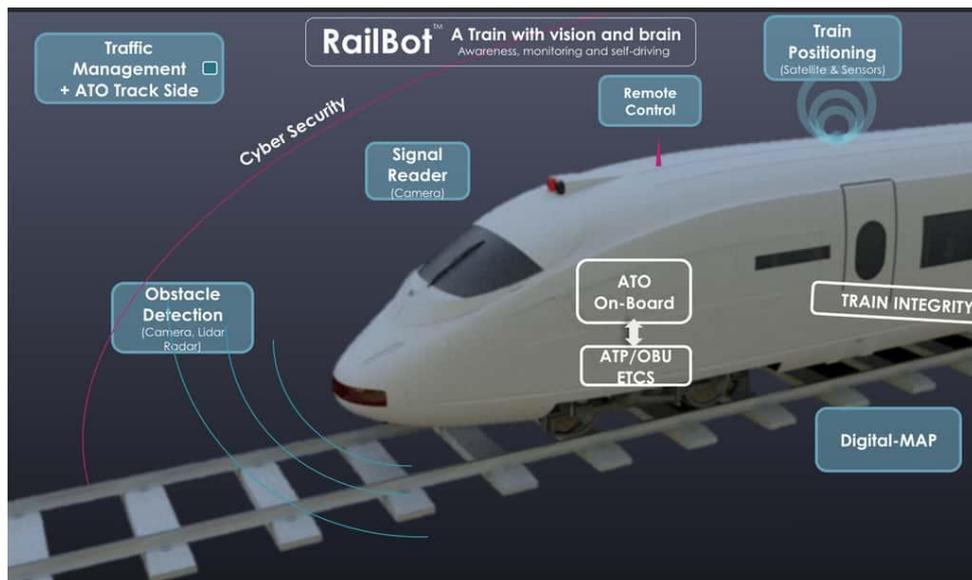


Figure I-4: Système cyber physique de Transport (Exemple Thalès)

## II/ Cycle de vie d'un système cyber-physique

### II-1/ Notion de cycle de vie

Dans le cadre du cycle de vie d'un système cyber-physique, comme d'un produit en général, trois phases peuvent être considérées (Lämmer and Theiss 2015; Terzi et al. 2010) :

- Le début de vie (BOL : Beginning Of Life) regroupe l'ensemble des activités liées au design préliminaire, à la conception et à fabrication.
- Le milieu de vie (MOL : Middle Of Life) comprenant les étapes de distribution/logistique et bien sûr d'utilisation. Cette phase inclut également les services de support (incluant la maintenance) assurant la pérennité du système.
- La fin de vie (EOL : End Of Life) comportant les étapes de logistique inverse (collecte), de reconditionnement (démontage et autres traitements) et de recyclage.

La Figure I-5 à la page suivante illustre ces différentes phases en faisant apparaître les différentes entités et acteurs qui gravitent autour de ce cycle de vie. En cohérence avec l'approche « produit actif » proposée dans (Sallez 2012), un SCP peut être considéré comme une entité ou produit interagissant, tout au long de son cycle de vie, avec différents systèmes de soutien. Ces derniers peuvent être définis comme des organisations (ex : service Maintenance d'un exploitant, entreprise spécialisée dans le recyclage...) capables d'intervenir sur le produit pour lui fournir un ou des services (ex : opération de maintenance, activité de désassemblage).

Le système cyber-physique n'est réellement opérationnel que durant sa phase MOL, où il devient alors « producteur » de services pour ses utilisateurs. Lors de cette phase, il est également « consommateur » de services au niveau de sa maintenance et de l'approvisionnement en consommables lui permettant d'assurer son fonctionnement.

Lors des phases BOL et EOL, il n'est pas opérationnel et se trouve être uniquement « consommateur » des services fournis par les différents systèmes de soutien. Il est à noter que selon leur complexité, ces derniers peuvent à leur tour être considérés comme des systèmes cyber-physiques (ex : Systèmes cyber-physiques de production durant la phase de fabrication).

La Figure I-5 décrit les différentes boucles cybernétiques instaurées entre le SCP et les systèmes de soutien. Chaque boucle cybernétique se compose d'une partie « ascendante » permettant de constituer un flux informationnel depuis le produit vers le système de soutien. Au vu des éléments remontés, ce dernier peut être amené à déclencher des interventions, constituant la partie « descendante » de la boucle.

Comme souligné dans (Barbosa et al. 2016), une synergie peut résulter du couplage de deux approches :

- L'approche « système cyber-physique » fournit des concepts intéressants pour la conception de systèmes innovants connectés en réseaux prenant en charge des systèmes complexes. Cependant, elle se focalise sur une seule phase du cycle de vie (ex : phase de production, phase d'utilisation), et correspond à un point de vue « vertical » par rapport au cycle de vie.
- L'approche « produit intelligent » (Cardin, Derigent, and Trentesaux 2022) fournit quant à elle les concepts permettant d'appréhender de manière plus « horizontale » les phases successives du cycle de vie en permettant un transfert d'informations entre phases.

Au vu de la complexité et de la diversité des interactions associées au cycle de vie, une gestion efficace doit être réalisée. Les problématiques inhérentes à cette gestion sont abordées ci-après.

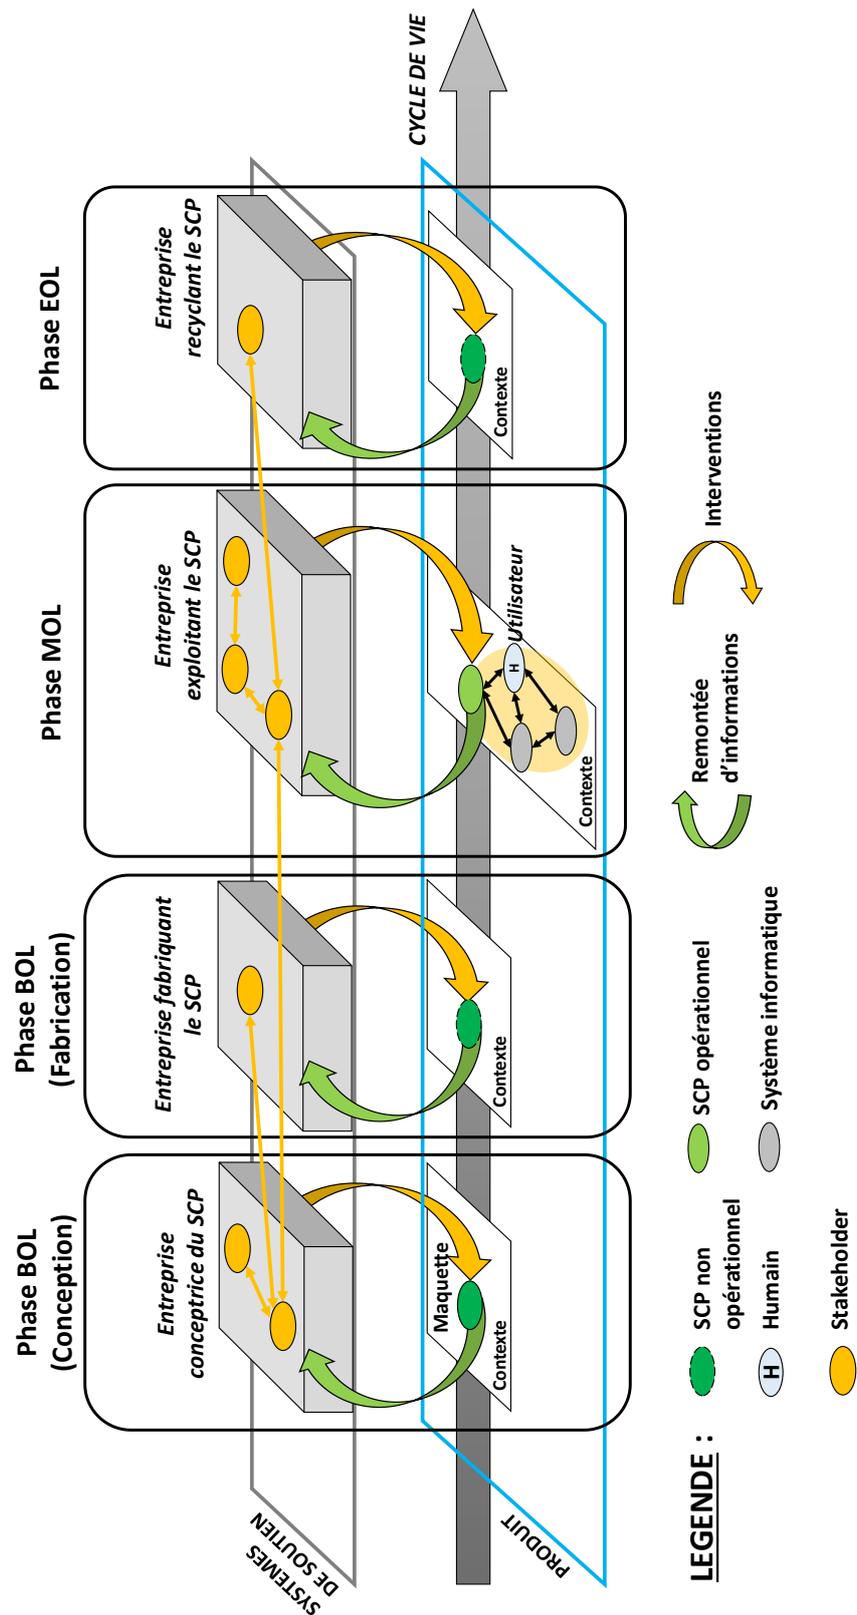


Figure I-5: Cycle de vie d'un système cyber-physique (vu comme un produit)

## II-2/ Gestion du cycle de vie et problématiques associées

Dans (Scott 2011), la gestion du cycle de vie (Product Lifecycle Management (PLM)) est définie comme suit : « Le PLM est l'activité métier qui consiste à gérer de la manière la plus

*efficace possible les produits d'une entreprise tout au long de leur cycle de vie ; depuis la toute première idée d'un produit jusqu'à son retrait et son recyclage». Selon (Jun, Kiritsis, and Xirouchakis 2007), une bonne gestion du cycle de vie nécessite de prendre en charge les éléments suivants :*

- (1) La gestion des « objets » du cycle de vie, tels que les activités liées au cycle de vie du produit, les données relatives au produit et aux ressources.
- (2) La collaboration entre les acteurs impliqués dans les différentes phases du cycle de vie (clients, fabricants, sous-traitants, fournisseurs...).
- (3) La capacité à détecter les goulets d'étranglement et à prendre des décisions à leur sujet.

Apparu dans les années 1990, le PLM s'est enrichi au fur et à mesure des développements des systèmes d'informations associés aux produits et aux différents systèmes de soutien :

- Au niveau du SCP (vu comme un produit) : les premiers développements en PLM se sont focalisés sur la gestion des « informations produit » via le concept de PDM (Product Data Management) (Philpotts 1996). Lors des différentes étapes de conception et de fabrication, les données générées et utilisées par les logiciels de CAO ou de CFAO sont stockées et gérées via ce PDM (Philpotts 1996).
- Au niveau des systèmes de soutien : le PLM s'est également complexifié avec la prise en compte des flux informationnels associés aux systèmes ERP (Entreprise Ressource Planning), MES (Manufacturing Execution System) et SCM (Supply Chain Management).

Les logiciels, prenant en charge le PLM, assurent ainsi la centralisation, le partage et la sécurisation des données dans l'objectif de réduire le temps de développement des produits, de fluidifier la communication entre les différents acteurs et de capitaliser les informations et connaissances relatives au produit. Cette gestion du cycle de vie se heurte cependant à certaines difficultés. Parmi les plus prégnantes, il est possible de distinguer :

- Les problématiques d'interopérabilité : Ce problème bien connu fait référence au phénomène « Tour de Babel », induit par la diversité et l'hétérogénéité des applications (ex. systèmes de CAO, MES, ERP...) intervenant dans le cycle de vie. La conséquence est une perte d'information pouvant conduire à un manque de cohérence (Dassisti, Panetto, and Tursi 2006).
- La multiplicité des acteurs : Compte tenu de la complexité de certains produits, tels que les SCP dans le domaine du transport, un grand nombre d'acteurs ou de parties prenantes sont impliqués tout au long du cycle de vie. Parmi ces acteurs, il est possible de distinguer, par exemple, les sous-traitants prenant en charge une partie de la conception du système (ex : société de développement logiciel), les fournisseurs de composants, les exploitants du SCP, les maintenanciers... A titre d'exemple, la Table I-1, extraite de (Nabati, Thoben, and Daudi 2017), liste l'ensemble des acteurs recensés lors de la phase d'usage d'une éolienne off-shore. Outre l'entreprise fabriquant l'éolienne, y apparaissent les sociétés fournissant les composants, assurant l'installation et exploitant l'énergie produite. Viennent s'y ajouter d'autres organismes du domaine tertiaire ou juridique (ex. sociétés d'assurance, ou de financement, organismes de réglementation). Cette importante diversité au niveau des acteurs entraîne une complexification de la collecte des informations tout au long du cycle de vie.

Note : Dans la suite de ce mémoire, nous utiliserons l'anglicisme « Stakeholder » pour désigner toute « entité » (humaine ou artificielle), appartenant à une organisation, ayant besoin d'informations / connaissances pour prendre des décisions en vue d'améliorer la chaîne de valeur associée au SCP.

<i>Stakeholder group</i>	<i>Role</i>
Manufacturer (OEM)	Warranty service – component supply – assembly offshore
Operating company (maintenance and service provider)	Day to day operation of the wind park, electricity generation, service and maintenance
Government/legal agencies	Setting rules, monitoring, financing
Logistic company	Provide the transport mode to the offshore site
Suppliers of components and subsystem	Distribution and providing the material and spare parts
Suppliers of raw material, composites, and material processing	Providing raw material for making the spare part components, material used during maintenance and service
Wind turbine installation companies	Setup and assembly inland and on the sea
Storage	Storage of components or spare parts, storage and transfer of electricity
Planning, consulting and project development	Consulting, coordination in areas of inspection, maintenance or operation
Utility and grind operation	Power generation, transfer, and distribution
Insurance company	Safeguard the setup of the wind park. Especially installation of cables, montage of the components and logistics to the sea for the personnel and the wind turbine components
NGOs	Voting for start/stop of an offshore wind park construction
Certification body and classification society	Inspection and certification-fit for purpose and safe to use design evaluation, site condition evaluation structure analysis, risk analysis collision analysis, property assessment, maintenance audit
Education and research	The companies who do research and provide training regarding wind energy
Organisations	Companies who do business with the wind sector, or offer services related to wind turbines (wind industry)
Investor	Bond or putting money to start or operate the wind farm
Competitors	Organisations, which offer other products for producing electric energy
Electricity users	The users of the electricity produced by the wind turbines

*Table I-1: Les acteurs impliqués dans la phase MOL d'une éolienne (Nabati, Thoben, and Daudi 2017)*

Afin de faire face aux difficultés mises en évidence ci-dessus, de nouvelles approches ont été proposées. Le développement des concepts de produit « intelligent » ou « actif », a notamment permis de revisiter le domaine du PLM en introduisant une nouvelle approche : le Closed-loop PLM (Cassina et al. 2006; Cassina, Cannata, and Taisch 2009; Kiritsis, Bufardi, and Xirouchakis 2003; Kiritsis 2011). Une définition, donnée dans (Kiritsis 2011), est la suivante : « *Un système PLM en boucle fermée permettra à tous les acteurs qui interviennent dans le cycle de vie d'un produit (responsables, concepteurs, opérateurs de service et de maintenance, recycleurs, etc.) de suivre, gérer et contrôler les informations produit à toutes les phases de son cycle de vie (conception, fabrication, MOL et EOL), à tout moment et en tout lieu dans le monde* ».

Le principe de base réside en l'élaboration de flux informationnels en aval ou en amont d'une phase du cycle de vie, à partir des données collectées par le produit « intelligent ». Comme

explicité sur la Figure I-6 , en aval de la phase « utilisation », le flux informationnel généré est utilisé pour améliorer les performances (ex : permettre en phase EOL, un meilleur recyclage en sachant comment les composantes du produit ont été sollicitées). En amont, le flux informationnel contenant les retours d'expérience sur l'usage du produit permet d'améliorer les nouvelles générations de produits en les rendant plus conformes aux attentes des clients.

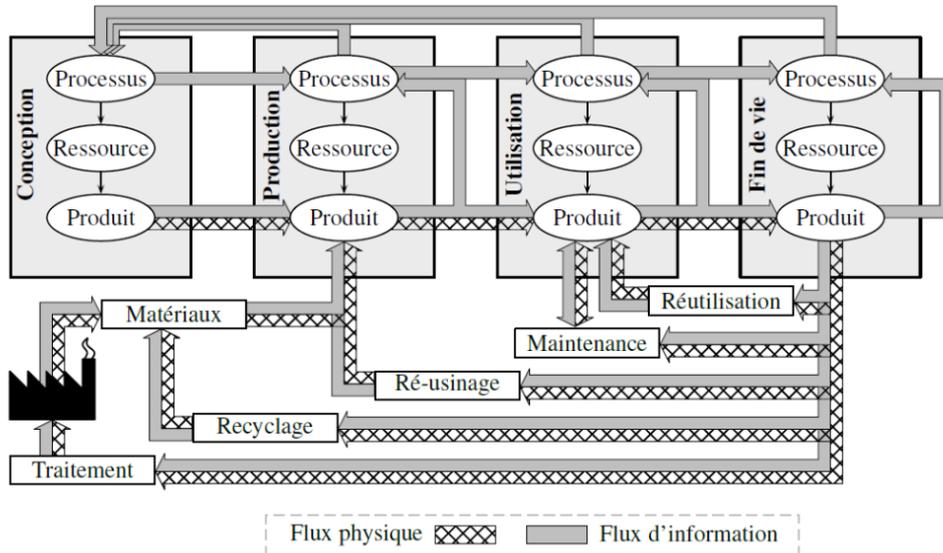


Figure I-6 : Les différents flux dans une approche Closed-loop PLM

Dans ce contexte de flux informationnels entre phases du cycle de vie, la section suivante détaille la phase MOL qui se trouve être la plus longue du cycle de vie pour la plupart des systèmes cyber-physiques.

### II-3/ Focus sur la phase MOL

Après une description des différentes boucles cybernétiques existant lors de la phase MOL, l'activité de maintenance, faisant l'objet de nos préoccupations, est plus particulièrement présentée.

#### II-3-1/ Les différentes catégories de boucles cybernétiques

Dans le cadre de la phase MOL, trois grandes catégories de boucles cybernétiques, reliant le SCP aux systèmes de soutiens et aux stakeholders, peuvent être distinguées. Comme illustré à la Figure I-7, ces boucles sont organisées selon trois horizons temporels :

- À court terme, la première catégorie de boucles cybernétiques, nommée « Surveillance » vise principalement deux objectifs :
  - Assurer le suivi et la traçabilité du SCP (par exemple : surveillance temporelle de certaines caractéristiques techniques (e.g. courant au niveau d'un actionneur)).
  - Détecter toute anomalie (par exemple : une déviation par rapport à un comportement nominal de référence du système ou une évolution indésirable de son environnement (e.g. température extérieure excessive)).

Cette boucle de surveillance se traduit par l'envoi d'informations (e.g. alarmes, évolution d'une mesure) aux différents stakeholders concernés qui peuvent alors décider d'intervenir pour remédier au problème.

- À moyen terme, et tout au long de la phase MOL, les boucles de la catégorie « Amélioration » exploitent différentes instance(s) d'utilisation du SCP (ou d'une flotte de systèmes similaires) au travers d'un historique avec deux objectifs :
  - (1) Assurer l'homéostasie du système en évitant toute dégradation.
  - (2) Accroître les performances du système selon les concepts de l'Amélioration continue (ex. réduire son empreinte environnementale, améliorer la qualité du service rendu).

Ces boucles d'amélioration sont prises en charge par les stakeholders et se concrétisent par un ensemble d'interventions (ex : remplacement d'un composant, enrichissement d'un guide « utilisateur » pour un meilleur usage du système).

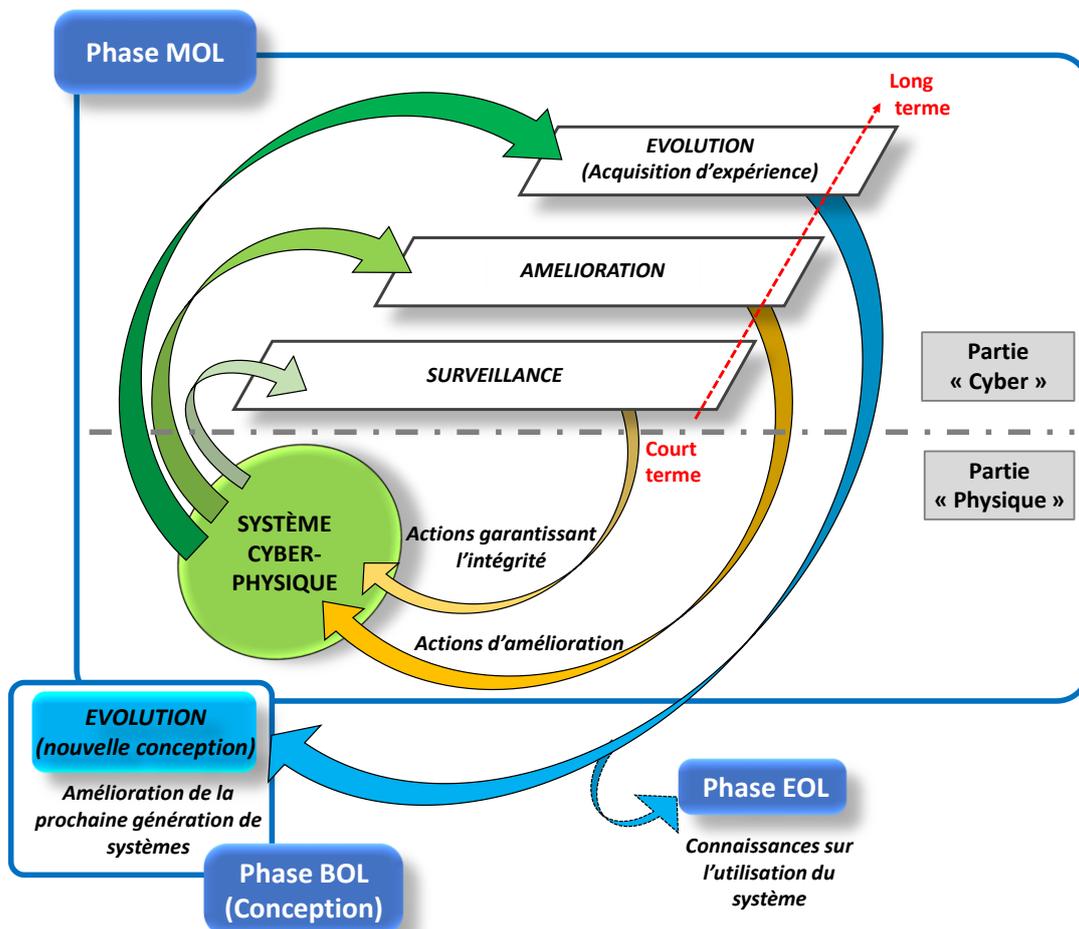


Figure I-7: Les trois types de boucles cybernétiques

- À long terme, d'autres boucles, dénommées « Evolution », supportent la mise en œuvre d'une approche Closed-loop PLM. Ces boucles n'ont pas un impact direct sur la phase MOL mais génèrent deux flux informationnels précieux pour les autres phases du cycle de vie. Comme décrit à la Figure I-7, un premier bloc « Acquisition d'expérience »

enregistre les données jugées intéressantes par les stakeholders concernés lors des différentes instances d'usage du système. Un second bloc élabore en temps utile deux flux informationnels, le premier à destination de la phase BOL afin de pouvoir améliorer les prochaines générations de systèmes, le second vers la phase EOL pour faciliter le démantèlement et le recyclage en fin de vie.

### **II-3-2/ L'activité de maintenance**

Selon la norme CEN - EN 13306, la maintenance est définie comme une combinaison d'activités techniques, administratives et de gestion (ou management) destinées à maintenir ou à rétablir un système dans un état dans lequel il peut accomplir sa fonction durant son cycle de vie. Dans le cadre de la typologie des boucles cybernétiques présentées dans la section précédente, elle s'inscrit clairement dans la catégorie « Amélioration ». Elle est cruciale dans la phase MOL d'un système, en permettant son bon fonctionnement, en prolongeant sa durée de vie et en minimisant les temps d'arrêt coûteux.

Dans le domaine du transport, les activités liées à la maintenance revêtent un caractère critique pour la gestion d'une flotte et supposent souvent la prise en compte de systèmes mobiles dispersés sur une vaste zone géographique. Elles sont opérées par le constructeur durant la phase de garantie, et par l'exploitant durant le reste du cycle vie (par exemple, un train peut avoir une durée de vie moyenne de 30 ans). De nombreuses études ont conclu que la maintenance des systèmes complexes représente 60 à 75 % de leurs coûts globaux de cycle de vie (Dhillon 1999). D'autres études indiquent que de bonnes pratiques de maintenance non seulement augmentent la fiabilité des systèmes entretenus mais réduisent également énormément leurs coûts d'exploitation (Jardine and Tsang 2013; Bouvard et al. 2011). Pour les exploitants du domaine du transport, ce lien entre la maintenance et la réduction des coûts opérationnels est de la plus haute importance dans un marché de plus en plus concurrentiel. De plus, dans le cadre de la gestion d'une flotte, la maintenance joue un rôle capital pour la disponibilité des véhicules et par la même dans la qualité de service apporté aux clients.

L'entretien d'une flotte de systèmes mobiles n'est pas nouveau (Cassady et al. 1998) mais a récemment connu un regain d'attention en particulier dans des secteurs tels que l'aéronautique, le ferroviaire et le militaire (C. Li et al. 2022; Rahimi et al. 2022; Dalzochio et al. 2023). Dans (J. W. Mbuli 2019), l'auteur définit la maintenance d'une flotte de systèmes cyber-physiques comme « le processus d'identification des tâches de maintenance requises, de planification et d'allocation des ressources aux tâches de maintenance identifiées (réparation, remplacement, maintenance préventive), l'exécution de ces tâches et l'évaluation des tâches exécutées associées à une flotte de CPS ».

Des travaux récents, au sein du LAMIH, se sont intéressés à la maintenance des flottes de systèmes cyber-physiques. Les travaux (J. W. Mbuli 2019; Adoum 2019) exposent en détail les problématiques associées à la gestion de cette maintenance. La Figure I-8, extraite de la thèse (J. W. Mbuli 2019), donne une vue d'ensemble des principaux éléments intervenant au niveau de la gestion de la maintenance d'une flotte de SCP :

- Les objectifs déclinés selon différents aspects :
  - Aspects économiques : Disponibilité (pour les exploitants de la flotte), fiabilité et réactivité (Occurrences d'événements imprévus, exploitation dans un environnement dynamique) ;
  - Aspects sociétaux : Sécurité ;

- Aspects environnementaux : Empreinte énergétique et carbone ;
- Les contraintes associées au système de soutien telles que le coût des opérations de maintenance, la disponibilité des opérateurs de maintenance ou des pièces de rechange ;
- Les normes relatives à cette gestion de la maintenance ;
- Les différentes stratégies de maintenance applicables.

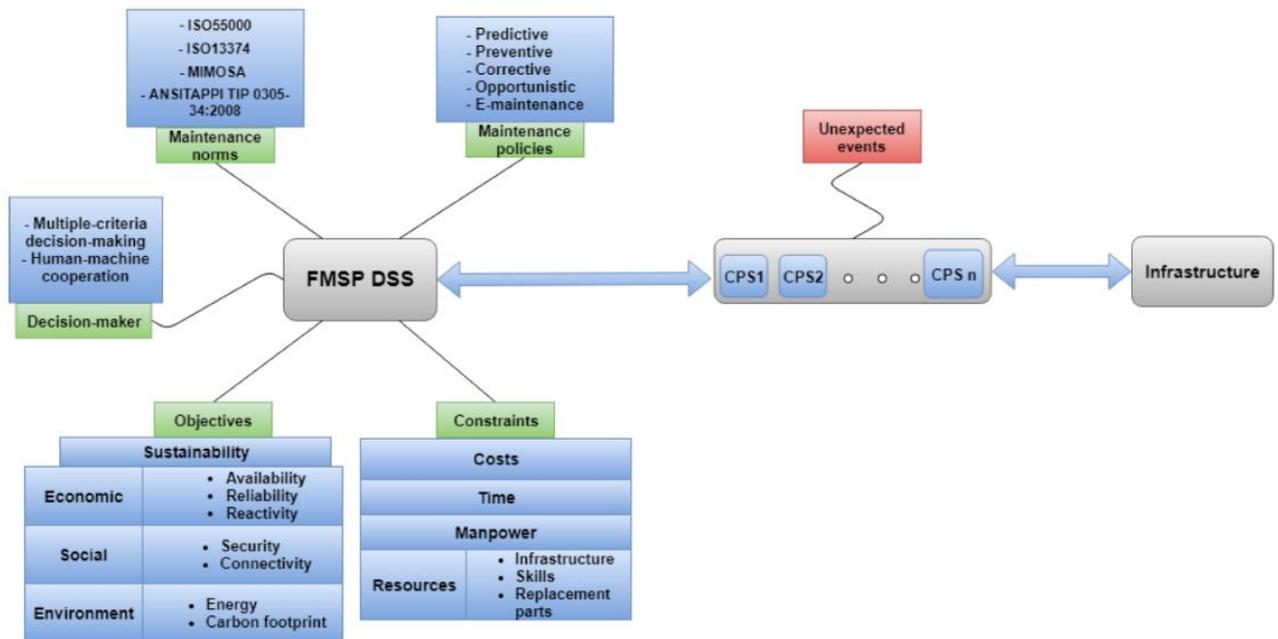


Figure I-8: Contraintes associées à la maintenance d'une flotte de SCP dans le domaine du transport (J. W. Mbuli 2019)

### III/ Analyse des boucles cybernétiques : l'IOT, le Big Data, le Data Analytics et le Machine Learning

Comme souligné plus avant, une boucle cybernétique se compose d'une partie « ascendante » et d'une partie « descendante ». La partie « ascendante » correspond au flux informationnel remonté depuis le SCP vers un stakeholder appartenant à un système de soutien. Ce besoin de collecte de données au niveau du système est largement couvert par les technologies déployées par l'IOT (Internet of Things). Selon le volume de ce flux informationnel, un nouveau domaine doit aussi être considéré ; celui du « Big data » qui permet de faire face à des volumes importants de données.

Le stakeholder est ensuite amené à prendre des décisions au vu du flux informationnel remonté, comme explicité à la Figure I-9. Confronté à des volumes importants de données à traiter et à des situations potentiellement complexes à analyser, le stakeholder peut être accompagné dans cette prise de décisions par une assistance. Cette dernière doit être apte à analyser un flux informationnel issu de plusieurs sources (instances d'utilisation du SCP, expériences passées, retours clients...). Dans ce contexte, des approches de type « Data Analytics » et « Machine Learning » peuvent s'avérer particulièrement utiles.

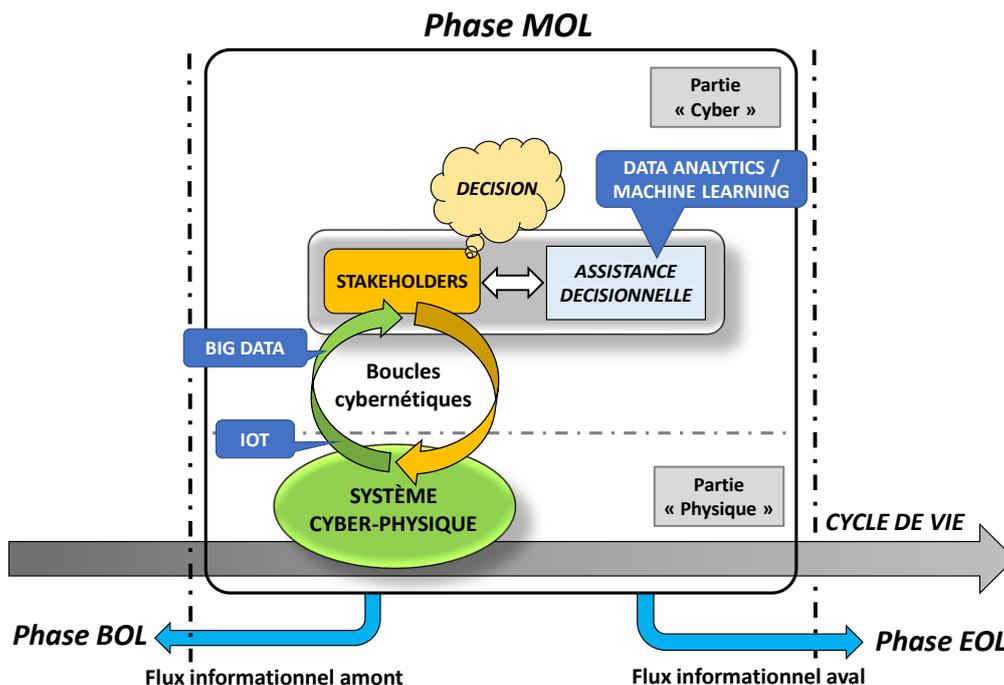


Figure I-9: Positionnement des différentes approches vis-à-vis d'une boucle cybernétique

La Figure I-9 positionne les approches IOT, Big Data, Data Analytics ou Machine Learning au niveau des boucles cybernétiques permettant aux différents stakeholders de prendre des décisions au regard d'un SCP. Les apports possibles de ces différentes approches sont passés en revue dans les sections suivantes.

### III-1/ L'IOT

Le concept d'« Internet of Things » concerne nombre de domaines d'activités : l'industrie, le médical, le Bâtiment, etc. (S. Chen et al. 2014). L'IoT peut être défini comme une infrastructure d'entités physiques, de systèmes et de ressources d'information interconnectées, ainsi que de services intelligents, capables de traiter et de réagir aux informations du monde physique et virtuel et d'influencer les activités dans le monde physique (ISO/IEC 2018). L'utilisation généralisée d'Internet et de ses protocoles (en particulier IPv4/IPv6) en font le principal moyen de communication pour l'IoT.

La Figure I-10 décrit une proposition d'architecture générique en couches (Bandyopadhyay and Sen 2011). L'architecture en couches présentée se décompose en deux parties distinctes qui ont en commun la couche de communication Internet (basée sur le protocole IP). Les deux couches inférieures (i.e. « Edge Technology » et « Access Gateway ») contribuent à la capture des données, tandis que les deux couches supérieures (i.e. « Middleware » et « Application ») permettent l'exploitation des données :

- « Middleware » permet le stockage des données, leurs prétraitements, le filtrage, l'agrégation, la transformation sémantique... ainsi que la gestion et le contrôle des objets connectés (ex. activation/désactivation d'un flux issu d'un objet connecté).
- « Application », située au niveau le plus haut, est responsable de l'interfaçage et de l'interaction avec les applications métiers, business, des divers utilisateurs de l'IoT. Ces applications, selon les cas, concernent par exemple les domaines de la production, de la logistique, de l'environnement, de la santé, de l'industrie alimentaire...

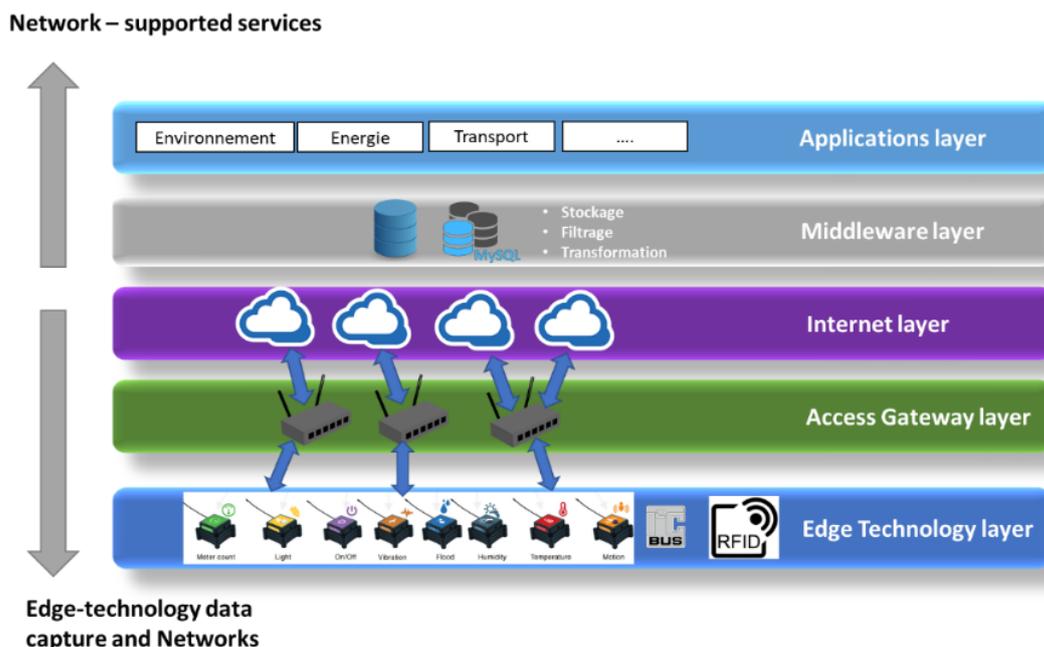


Figure I-10: Les différentes couches de l'architecture IoT (Bandyopadhyay and Sen 2011)

### III-2/ Le Big Data

Depuis une dizaine d'années, est apparu le phénomène de Big Data, souvent vu comme synonyme de « données massives ». Avec l'utilisation croissante de l'IoT, des systèmes mobiles sans fil, des applications Web, des réseaux sociaux et d'autres technologies de l'information et de la communication de plus en plus de données sont mises à disposition des entreprises dans le but de les analyser et d'en extraire des informations et connaissances utiles à une prise de décision. Les entreprises utilisent des techniques de traitement de données spécifiques, telles que le traitement distribué, le stockage sur le cloud et les systèmes de fichiers Hadoop (Ishwarappa and Anuradha 2015), pour gérer et analyser ces ensembles de données massives. Les applications du Big Data sont multiples, allant de l'industrie à la finance, en passant par la santé et le marketing (Y. Shi 2022).

Comme dépeint à la Figure I-11, le concept de Big Data est souvent caractérisé par trois attributs (3 V) : Volume, Vitesse et Variété (Berisha, Mëziu, and Shabani 2022; Montgomery 2014) (Montgomery 2014) :

- Le premier attribut « Volume » fait référence à l'ampleur des données. Le Big data fait souvent référence au traitement de téraoctets, voire parfois de pétaoctets de données (Russom and Org 2011) . Par exemple, on a estimé que Wal-Mart produisait 2,5 pétaoctets de données par heure de fonctionnement (K. and K. 2020). L'estimation du volume est difficilement réalisable. (Lau et al. 2016) considère que lorsque la taille des données augmente à tel point que les technologies classiques ont du mal à faire face en matière de stockage, de récupération et l'analyse des données, ce volume est considéré comme « grand ».
- (Lau et al. 2016) définit la « Variété » comme les hétérogénéités inhérentes aux structures, formats et sources de données. Par exemple, le contenu généré par l'entreprise UGC (ex : vidéos, images et audios) vu sur les sites Web et les médias sociaux, est constitué de données non structurées. Cette quantité de contenus non structurés peut

constituer une énorme difficulté pour les méthodes traditionnelles de stockage et d'analyse (Manyika et al. 2011).

- L'attribut « Vélocité » concerne la vitesse à laquelle les données sont produites et la vitesse à laquelle les données doivent être récupérées et analysées (Russom and Org 2011; Lau et al. 2016). Parmi les trois V, la vélocité est l'attribut qui a le lien le plus direct avec l'IoT. La large utilisation des smartphones et des objets « communicants » a entraîné une forte augmentation de la fréquence de collecte des données générées.

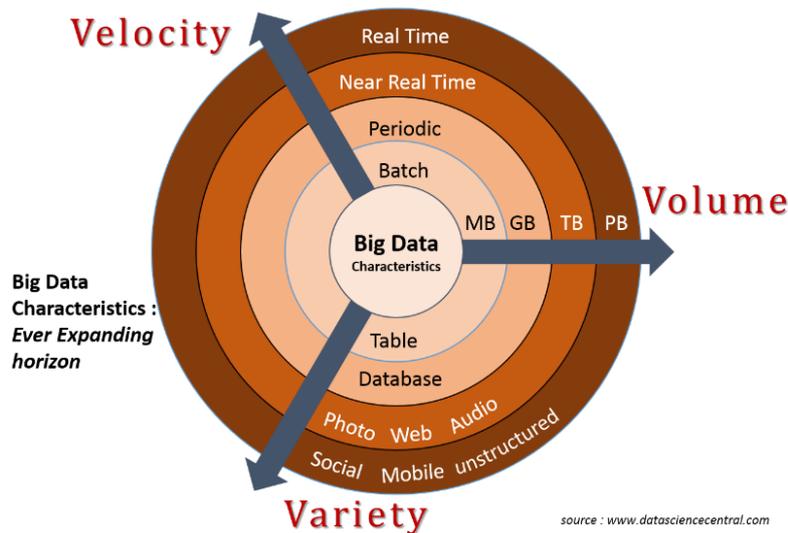


Figure I-11: Illustration des 3 V (Volume / Variété / Vélocité)

Dans la suite logique de l'analyse des boucles cybernétiques, les deux sections suivantes sont dédiées à une présentation des approches pouvant aider les stakeholders dans leurs analyses et prises de décision concernant le SCP ciblé.

### III-3/ Le Data Analytics

Le « Data analytics », également connu sous le nom d'analyse de données, est l'ensemble des méthodes et techniques visant à extraire des informations significatives et des connaissances à partir de données (Runkler 2020). Cela peut inclure la découverte de tendances et de modèles, l'identification de relations entre variables, la prédiction de tendances futures. Les données peuvent provenir de différentes sources, telles que des enquêtes, des transactions, des fichiers, des capteurs, des médias sociaux, etc.

Le Data Analytics peut répondre aux besoins des stakeholders selon différentes facettes associées à des horizons temporels différents (Figure I-12). Les facettes les plus couramment distinguées sont les suivantes :

- (1) Analyse « Descriptive » : L'analyse descriptive examine les données pour comprendre et décrire une situation qui s'est produite dans le passé et éclairer une situation présente. L'analyse descriptive est le type d'analyse le plus largement utilisé à l'heure actuelle dans les entreprises. En catégorisant, caractérisant, agrégeant et classant les données, l'analyse descriptive convertit les données en informations utiles pour analyser les situations. Cette analyse implique la consolidation des sources de données et la mise à disposition de toutes les données pertinentes sous une forme qui permet un

« reporting » (ex : rapports, requêtes, alertes, tendances). Ce « reporting » passe par l'usage d'outils de visualisation et de présentation appropriés.

- (2) Analyse « Diagnostic » : Cette analyse va plus loin que l'analyse descriptive en cherchant à comprendre le « pourquoi » derrière une situation passée ou un événement qui est survenu. Ce type d'analyse comprend la comparaison de tendances ou la découverte de corrélations entre variables et la détermination de relations causales lorsque cela est possible. Les données historiques sur le système peuvent alors être exploitées et comparées à d'autres données pour apporter un élément de réponse. L'analyse « diagnostic » est particulièrement utile pour déterminer les causes racines d'un problème.
- (3) Analyse « Prédictive » : L'analyse prédictive est utilisée pour faire des prédictions sur les tendances ou les événements futurs et répond à la question « Que pourrait-il se passer dans le futur ? ». L'analyse prédictive s'appuie sur des données historiques, des tendances passées et des hypothèses pour se projeter dans une situation future. Elle rassemble un certain nombre de méthodes d'exploration de données, de méthodes de prévision, de modèles prédictifs et de techniques analytiques pour analyser les données actuelles, évaluer les risques et les opportunités, saisir les relations existantes et faire des prédictions sur l'avenir.
- (4) Analyse « Prescriptive » : Couplée à l'analyse prédictive, ce type d'analyse identifie les actions spécifiques à entreprendre pour atteindre de futurs objectifs. Lorsqu'un stakeholder ne peut pas envisager d'utiliser efficacement l'analyse descriptive ou prédictive en raison de l'existence d'un trop grand nombre d'alternatives possibles, l'analyse prescriptive entre en jeu. La question clé à laquelle l'analyse prescriptive tente de répondre est la suivante : quel « devrait » être le résultat (optimal) ? De plus, une fois le résultat (ou objectif) prédit, l'analyse prescriptive propose les plans d'action permettant de l'atteindre.

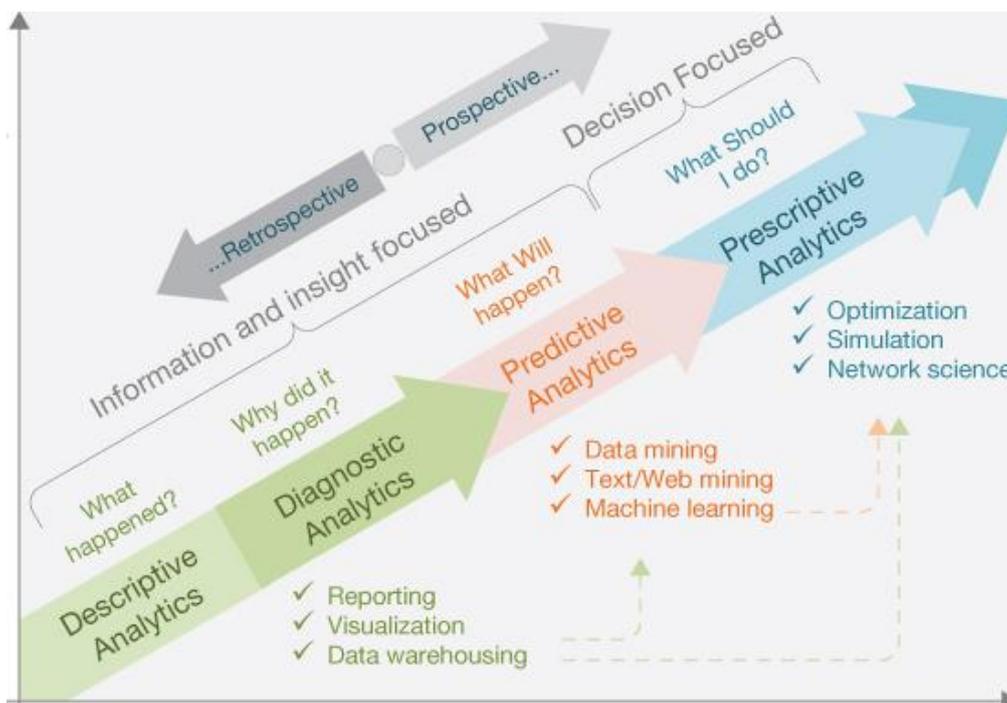


Figure I-12 : Les différentes facettes du Data Analytics (Delen and Ram 2018)

### III-4/ Le Machine Learning et le Deep Learning

La définition de L'intelligence artificielle (IA) selon Marvin Minsky (1927-2016), l'un des fondateurs de l'IA est « *La construction de programmes informatiques capables d'accomplir des tâches qui sont, pour l'instant, accomplies de façon plus satisfaisantes par des êtres humains.* ». L'IA n'est pas donc une science en soi, mais plutôt un domaine qui s'est développé en différentes branches (e.g. Sciences de données, le Machine Learning,...) au cours des six dernières décennies (Figure I-13). Nous retenons dans ce mémoire la définition de l'IA en tant qu'un domaine de l'informatique qui vise à créer des systèmes (i.e. des algorithmes, des machines,...) capables de simuler ou de reproduire des capacités intellectuelles humaines. L'IA comprend plusieurs approches et techniques, dont deux peuvent exploiter la partie « ascendante » (i.e. le flux informationnel) de la boucle cybernétique. Il s'agit du Machine Learning (apprentissage automatique) et du Deep Learning (apprentissage profond).

Le Machine Learning (ML) est une approche de l'intelligence artificielle qui consiste à développer des modèles capables d'apprendre à partir des données (Murdoch et al. 2019). La boucle cybernétique implique la collecte de données provenant des SCP et d'autres sources. Avec le développement de l'IoT et le flux constant de données générées, il peut y avoir un volume important de données à traiter. Amplifiant la difficulté de prendre une décision par le stakeholder. Le Machine Learning peut fournir une assistance dans ce processus de prise de décisions en proposant des recommandations ou en fournissant des informations supplémentaires basées sur l'analyse des données. Ainsi, les modèles du ML peuvent identifier des tendances, des corrélations ou des motifs cachés dans les données.

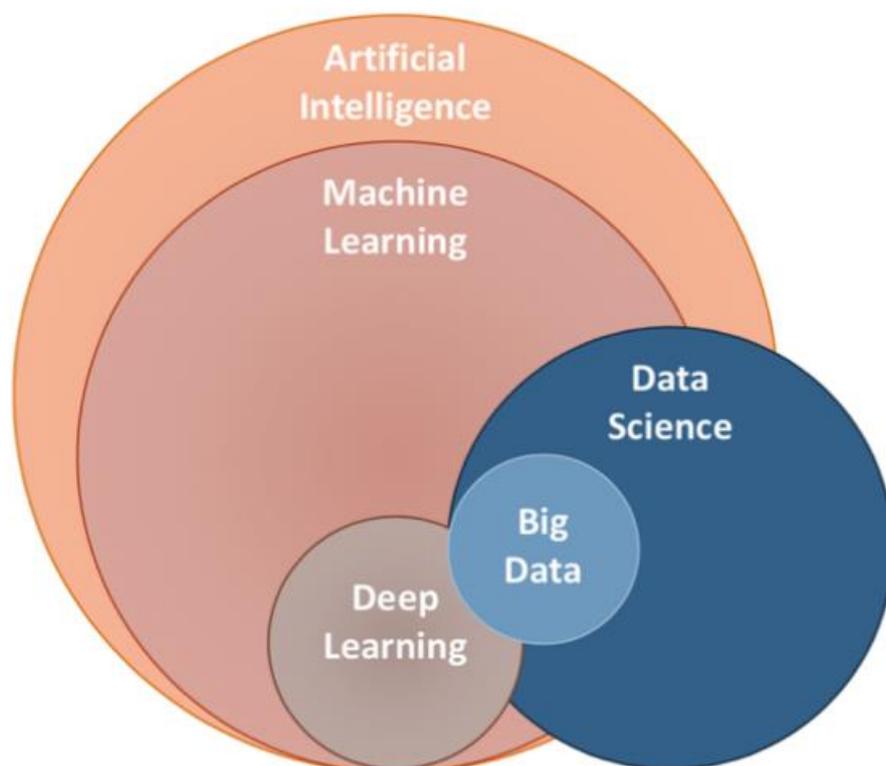


Figure I-13: Positionnement du Machine Learning et du Deep Learning

Le Deep Learning est une sous-discipline du Machine Learning qui se concentre sur l'utilisation de réseaux de neurones artificiels profonds pour résoudre des problèmes complexes (Chassagnon et al. 2020). Contrairement aux méthodes de ML traditionnelles qui nécessitent souvent un prétraitement manuel des caractéristiques, le Deep Learning peut apprendre automatiquement les caractéristiques pertinentes directement à partir des données. Cela simplifie le processus de prétraitement des données surtout pour le cas des stakeholders non spécialistes de l'analyse de données. Cependant, le Deep Learning nécessite généralement de grandes quantités de données et plus de temps de traitement pour entraîner l'algorithme, engendrant des coûts supplémentaires.

Les différents algorithmes et leurs applications analytiques, en particulier pour la maintenance, sont détaillés dans le chapitre suivant.

#### **IV/ Problématiques scientifiques et contexte applicatif**

Au regard des différents domaines constituant le contexte de nos travaux présentés dans les précédentes sections, cette partie précise successivement le contexte applicatif et les problématiques traitées dans le cadre de ce mémoire.

##### **IV-1/ Contexte industriel**

Le contexte applicatif de la thèse se situe dans le domaine du transport et concerne deux principales collaborations industrielles.

La première collaboration, en début de thèse, a concerné la société marocaine STMF. Cette société est le leader reconnu au Maroc du transport de matières dangereuses (produits chimiques, carburants). Elle dispose d'une flotte d'environ 360 camions desservant les différentes régions du Maroc.

Comme toute entreprise dans le domaine du transport routier, elle est confrontée aux problématiques de disponibilité et de sécurité de sa flotte. A cet effet, elle déploie des efforts pour optimiser les opérations de maintenance et notamment assurer une bonne gestion des pneumatiques. Ces derniers sont des éléments critiques et se doivent de rester dans un état compatible avec le respect des contraintes sécuritaires régissant le transport. La perte de contrôle d'un véhicule suite à l'éclatement d'un pneumatique peut en effet avoir des conséquences désastreuses. Les pneumatiques constituent également un centre de frais important pour l'entreprise (environ 30 % des frais d'exploitation de la flotte). Dans ce contexte ; les sociétés de transport réalisent une opération de permutation des pneumatiques au niveau des différents trains de roulement des camions de façon à répartir les usures. Cette opération nécessite la prise en compte de nombreux paramètres (ex : type de pneumatique, kilométrages parcourus, types de routes utilisées...). Un outil d'assistance décisionnelle a donc été réalisé pour faciliter la prise de décision du responsable maintenance de la société.

La crise COVID et les contraintes de déplacement vers le Maroc ont cependant contribué à distendre cette coopération et à envisager d'autres champs applicatifs.

La seconde collaboration, en fin de thèse, a été établie dans la cadre d'un contrat entre le LAMIH et la société Alstom. La problématique porte sur la croissance de fiabilité du matériel roulant.

Les constructeurs ferroviaires de matériels roulants sont confrontés à la problématique de très rapidement atteindre un niveau de fiabilité important des équipements pour répondre aux besoins en exploitation de leurs clients. Ces derniers désirent en effet bénéficier d'une disponibilité élevée de leur flotte de trains dès le début de la mise en service. Les principaux challenges pendant la phase de croissance de fiabilité d'un matériel roulant sont l'agrégation des données, leurs analyses et l'identification des causes racines à l'origine des pannes rencontrées en exploitation. Par définition, ces activités se font a posteriori où les pannes ont déjà été imputées au constructeur (on parle de correctif dans ce cas), entraînant une exposition importante (ex. en termes de réputation, financière). Ce fait est d'autant plus vrai en début de phase de croissance de fiabilité pour un nouveau matériel roulant. La caractérisation des causes racines est donc un élément clé pour limiter cette exposition car elle est le point de départ pour la définition et la mise en place des actions correctives sur flotte.

Dans ce contexte de croissance de fiabilité, les travaux ont porté sur l'analyse de l'historique des pannes d'une flotte de trains de façon à élaborer une méthodologie et développer des outils d'analyse permettant de détecter des signaux avant-coureurs d'une défaillance. Ces travaux se situent clairement dans une approche « Closed loop PLM » permettant d'améliorer le processus de conception d'une nouvelle génération de matériel ferroviaire.

Les travaux réalisés dans le cadre de ces deux collaborations seront détaillés dans le chapitre V.

#### **IV-2/ Contribution scientifique de la thèse**

La problématique scientifique de la thèse se situe au niveau des boucles cybernétiques reliant un système « cible » (SCP cible) et les différents stakeholders concernés durant sa phase d'usage. Même si de par le contexte applicatif, les préoccupations relatives à la maintenance sont plus particulièrement étudiées, les concepts avancés dans ce mémoire peuvent être appliqués à l'ensemble des phases du cycle de vie.

Comme mentionné en introduction, notre contribution se situe dans la continuité de travaux entrepris dans le cadre de l'étude des chaînes informationnelles et décisionnelles associées aux boucles cybernétiques (Basselot 2019). La contribution scientifique de la présente thèse porte principalement sur la proposition d'une assistance décisionnelle aux stakeholders participant aux différentes boucles cybernétiques.

Comme illustré à la Figure I-14, la conception et la mise en œuvre d'une telle assistance décisionnelle nécessite de répondre à trois principaux questionnements :

- (1) **Caractériser les boucles cybernétiques au travers d'un modèle générique** : Au regard d'une préoccupation spécifique relative au système en phase d'usage (ex : maintenance, amélioration continue de l'exploitation), cette problématique consiste à :
  - a. identifier les différents stakeholders concernés,
  - b. caractériser les flux informationnels au sein des boucles cybernétiques à élaborer.
- (2) **Spécifier l'assistance décisionnelle à apporter aux stakeholders** : En association avec la problématique précédente, il s'agit ici de spécifier les besoins en assistance des stakeholders et de répondre à la question suivante : A partir des flux informationnels

disponibles au niveau des boucles cybernétiques, quels éléments informationnels pertinents présenter aux stakeholders pour faciliter la prise de décision ?

Ce questionnement devra prendre en compte le fait que cette assistance doit intégrer à la fois une composante Machine (aspects matériels et logiciels de l'assistance) et une composante Humaine (ex : expert du domaine applicatif ou du système cyber-physique).

- (3) **Proposer un ensemble d'approches et d'outils de Machine Learning permettant de développer cette assistance décisionnelle** : Ce questionnement est relatif au choix d'une approche pertinente permettant le développement d'une assistance réellement opérationnelle à partir des spécifications obtenues. Il devra être tenu compte du fait que les stakeholders n'ont généralement pas d'expertise en Machine Learning et n'ont d'ailleurs pas vocation à en avoir. Il s'ensuit que des interfaces adaptées devront donc être proposées aux stakeholders pour qu'ils puissent prendre leurs décisions.

Tout au long du cheminement visant à répondre à ces questionnements, certaines exigences devront être respectées :

- Veiller à adopter des concepts et approches suffisamment génériques pour être utilisés pour des systèmes cibles simples ou composites (formés d'une hiérarchie de sous-systèmes).
- Retenir des approches applicables quel que soit le niveau de sous-système considéré (dans le cas d'un produit composite).
- Être indépendant des technologies de mise en œuvre.

Enfin, cette analyse des boucles cybernétiques et des assistances décisionnelles associées, devra être accompagnée d'un guide méthodologique permettant de préciser les différentes étapes de la démarche.

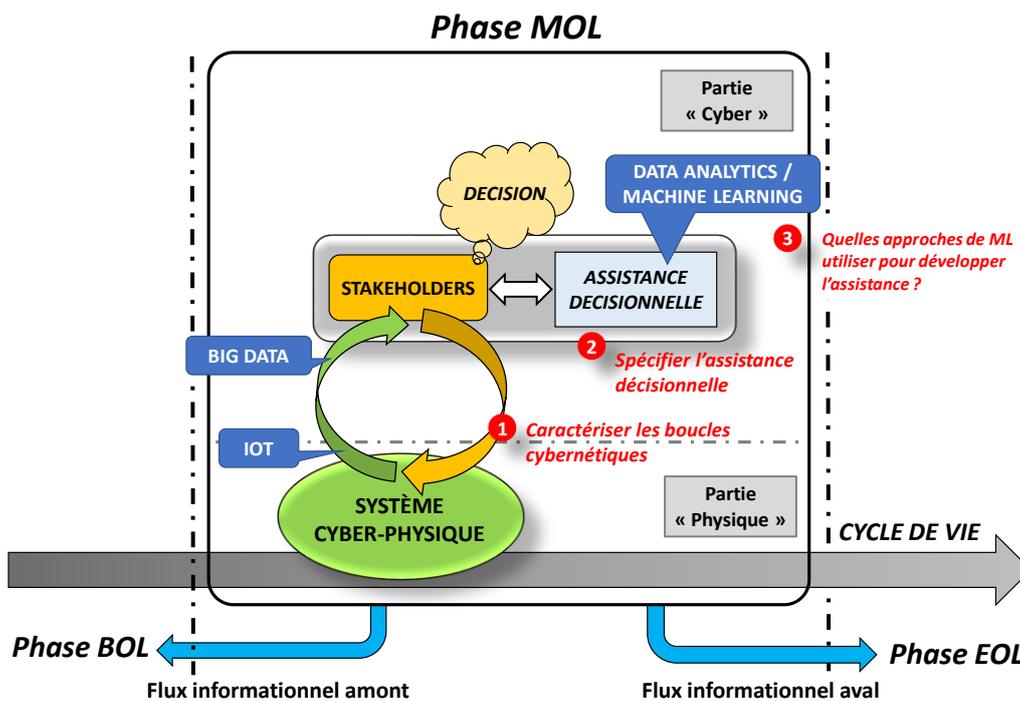


Figure I-14: Illustration des problématiques scientifiques

## **V/ Conclusion du chapitre**

Ce premier chapitre a permis d'introduire le contexte de nos travaux et de présenter les problématiques qui seront considérées.

Dans un premier temps, les systèmes cyber-physiques et leur principe de fonctionnement sont présentés. Ensuite, leur analogie avec les systèmes de transport est démontrée étant donné que les systèmes de transport modernes peuvent être qualifiés de systèmes cyber-physiques complexes.

Une seconde partie a présenté les différentes phases du cycle de vie d'un SCP. Les problématiques associées à la gestion du cycle de vie de ces systèmes cyber-physiques ont ensuite été mises en évidence. L'accent a notamment été mis sur la multiplicité des stakeholders amenés à intervenir sur le SCP tout au long de son cycle de vie.

Dans une troisième partie, positionne les approches IOT, Big Data, Data Analytics ou Machine Learning au niveau des boucles cybernétiques permettant aux différents stakeholders de prendre des décisions au regard d'un SCP.

Enfin les problématiques industrielle et scientifique ont été présentées. La problématique scientifique s'intéressant à la conception et à la mise en œuvre d'une assistance décisionnelle pour les stakeholders a été présentée et décomposée en un ensemble de questionnements à considérer dans le cadre d'une approche générique.

Les travaux proposés dans cette thèse s'inscrivent pleinement dans le contexte de développement des outils Analytics et Big data et plus particulièrement de leur application en maintenance. Un état de l'art sur les différentes approches utilisées et leurs applications fait l'objet du prochain chapitre.

## Chapitre II

### Etat de l'art

#### Introduction

Ce chapitre est dédié à un approfondissement des approches Analytics introduites très succinctement dans le chapitre précédent.

Dans une première partie, les outils analytics classiques sont brièvement présentés.

La seconde partie est dédiée à une présentation des approches de Machine Learning. Les techniques d'apprentissage supervisé, non supervisé et par renforcement sont successivement détaillées.

Les techniques du Deep Learning et plus particulièrement les réseaux de neurones convolutifs et récurrents font l'objet de la troisième partie.

Enfin dans une quatrième partie, après introduction d'un cadre d'analyse, est menée une revue de la littérature portant sur les applications des outils Analytics au domaine de la maintenance.

#### I/ Les outils analytics classiques

De nos jours, les entreprises et les industries génèrent une quantité massive de données chaque jour. Ces données, souvent de type "Big Data", sont hétérogènes et peuvent provenir de diverses sources telles que les réseaux sociaux, les capteurs, les transactions en ligne ou encore les applications mobiles. La gestion et l'analyse de ces données sont devenues de plus en plus complexes, nécessitant l'intervention de la machine et des techniques de Data Analytics pour en extraire des informations exploitables. Cependant, la collecte, le stockage et l'analyse de Big Data sont des défis majeurs pour de nombreuses entreprises, qui doivent être équipées des outils et des compétences nécessaires pour en tirer parti. Dans cette optique, les techniques de Data Analytics sont devenues indispensables pour exploiter les Big Data de manière efficace et productive, comme détaillé dans le premier chapitre, en fonction de la nature des données et des besoins des stakeholders. Plusieurs techniques classiques sont utilisées pour le data analytics (Judd, McClelland, and Ryan 2011). Ci-après les techniques les plus utilisées :

*L'analyse descriptive* consiste à résumer et à décrire les caractéristiques des données (Kemp et al. 2017). Elle utilise des méthodes telles que la moyenne, la médiane, l'écart-type, les quantiles, les histogrammes, les diagrammes en boîte, etc (Lawless and Heymann 2010) pour donner une idée générale de la distribution des données.

Dans le cadre de l'analyse descriptive, *l'Analyse de corrélation* est utilisée pour mesurer la relation entre deux variables (Zhuang, Yang, and Cordes 2020). Elle utilise généralement le coefficient de corrélation de Pearson ou le coefficient de corrélation de rang de Spearman pour mesurer la force et la direction de la relation entre les variables (Bishara and Hittner 2012).

Pour comparer les moyennes de plusieurs groupes, *l'Analyse de variance (ANOVA)* détermine si les moyennes sont significativement différentes les unes des autres. Les méthodes ANOVA courantes comprennent l'ANOVA à un facteur et l'ANOVA à deux facteurs (Martin Salvador, Budka, and Gabrys 2016). Les tests d'hypothèses sont utilisés pour tester une hypothèse

statistique sur les données et déterminer si les données observées sont significativement différentes de ce qui serait attendu sous une hypothèse nulle. Les tests d'hypothèses courants comprennent le test t, le test de chi-carré, le test de Kolmogorov-Smirnov, le test de Shapiro-Wilk (Yap and Sim 2011).

*L'analyse de la composante principale (PCA)* permet de réduire la dimensionnalité des données en créant de nouvelles variables qui représentent la variabilité des données (Abdi and Williams 2010; Karamizadeh et al. 2013). Elle est souvent utilisée pour visualiser les données dans un espace à deux dimensions.

Finalement, *l'association de règles* vise à découvrir des relations entre les variables d'un ensemble de données, en identifiant des règles qui expriment des liens fréquents entre les différents éléments. Une règle d'association comporte deux parties : un antécédent (si) et un conséquent (alors). Un antécédent est un élément trouvé dans les données. Un conséquent est un élément trouvé en combinaison avec l'antécédent. Les règles d'association sont donc créées en recherchant des motifs « si-alors » fréquents dans les données et en utilisant les critères de support et de confiance pour identifier les relations les plus importantes. Le support est une indication de la fréquence à laquelle les éléments apparaissent dans les données. La confiance indique le nombre de fois où les énoncés « si-alors » sont vrais. Une troisième métrique, appelée lift, peut être utilisée pour comparer la confiance avec la confiance attendue, ou combien de fois un énoncé « si-alors » est censé être vrai. Les règles d'association sont calculées à partir d'ensembles d'éléments, qui sont composés de deux éléments ou plus. Si les règles sont construites en analysant tous les ensembles d'éléments possibles, il peut y avoir tellement de règles que leur signification est limitée. Ainsi, les règles d'association sont généralement créées à partir des règles bien représentées dans les données. Les algorithmes populaires qui utilisent des règles d'association comprennent AIS, SETM, Apriori et des variations de ce dernier (Kumbhare Santosh V Chobe 2014). Avec l'algorithme AIS, les ensembles d'éléments sont générés et comptés au fur et à mesure de l'analyse des données. Dans les données transactionnelles, l'algorithme AIS détermine les grands ensembles d'éléments contenus dans une transaction, et de nouveaux ensembles d'éléments candidats sont créés en étendant les grands ensembles d'éléments avec d'autres éléments dans les données transactionnelles (Xie, Wu, and Qian 2009; Grabot 2020). L'algorithme SETM génère également des ensembles d'éléments candidats au fur et à mesure qu'il analyse une base de données, mais il prend en compte les ensembles d'éléments à la fin de son analyse. De nouveaux ensembles d'éléments candidats sont générés de la même manière qu'avec l'algorithme AIS, mais l'identifiant de transaction de la transaction génératrice est enregistré avec l'ensemble d'éléments candidats dans une structure de données séquentielle.

L'analyse statistique vise généralement à explorer et à comprendre les données, en identifiant les relations et les tendances dans les données. Elle est souvent utilisée pour obtenir des informations descriptives et inférer des conclusions sur une population à partir d'un échantillon.

## **II/ Le Machine Learning**

Dans la suite de ce mémoire, le terme « modèle » fera référence à une représentation simplifiée et abstraite d'un système réel ou d'un phénomène. Un « modèle » est donc une structure mathématique et statistique qui capture les relations et les patterns présents dans les données, permettant ainsi de comprendre, d'expliquer, de prédire ou de prendre des décisions. Un

« modèle » est généralement construit à partir des données disponibles, en utilisant des algorithmes Machine Learning ou Deep Learning. Le processus de construction d'un modèle consiste à choisir une approche appropriée, à sélectionner les variables pertinentes, à définir les paramètres du modèle et à l'entraîner à partir des données d'entraînement.

Le Machine Learning, ou apprentissage automatique en français, est une branche de l'intelligence artificielle qui permet aux ordinateurs d'apprendre à partir de données. Contrairement à la programmation classique, où un développeur spécifie explicitement toutes les instructions nécessaires pour réaliser une tâche, le Machine Learning permet à un ordinateur de découvrir des règles à partir des données d'entrée, sans qu'il soit nécessaire de les spécifier explicitement (Bell 2022).

Cela se fait en entraînant un algorithme à partir de données d'apprentissage, en ajustant ses paramètres pour minimiser une fonction de coût qui mesure la différence entre les prédictions de l'algorithme et les valeurs réelles. Une fois l'algorithme entraîné, il peut être utilisé pour effectuer des prédictions sur de nouvelles données.

Le Machine Learning est utilisé dans de nombreux domaines tels que la recommandation de produits, la prédiction des tendances financières, la détection de fraudes. Il est devenu une compétence clé pour de nombreux professionnels de l'informatique et des sciences de données (De Mauro et al. 2018), car il permet de découvrir des informations précieuses à partir de grandes quantités de données, conduisant ainsi à des améliorations significatives dans la prise de décision.

Comme illustré à la Figure II-1, il existe plusieurs approches de Machine Learning (Qiu et al. 2016), chacune avec ses propres techniques et algorithmes. Les principaux types de Machine Learning sont l'apprentissage supervisé, l'apprentissage non-supervisé et l'apprentissage par renforcement.

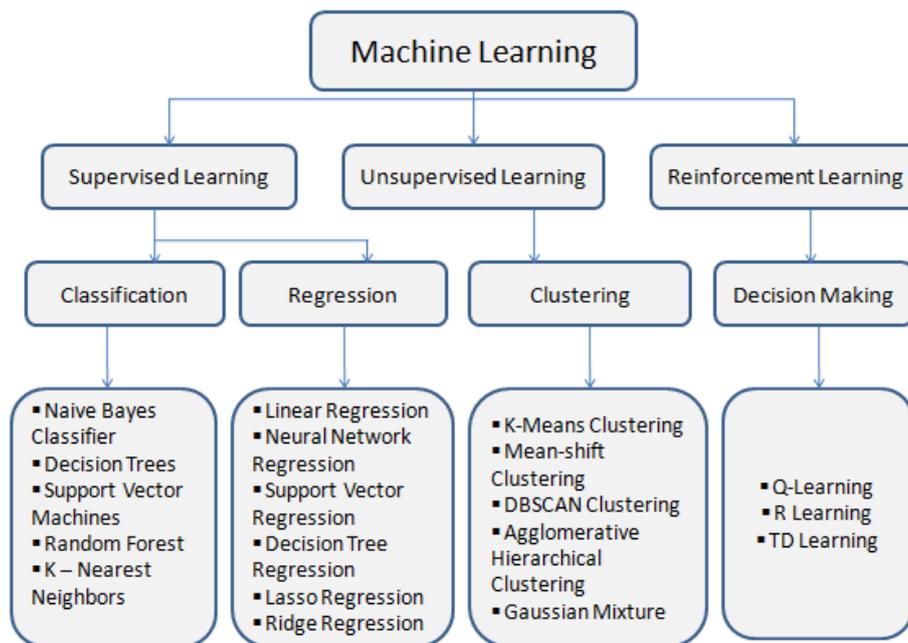


Figure II-1: les différents types du Machine Learning

## II-1/ L'apprentissage supervisé

Dans ce type d'apprentissage, un modèle est entraîné à prédire une sortie (ou une étiquette) à partir d'une entrée en se basant sur un ensemble de données d'entraînement pré-étiquetées.

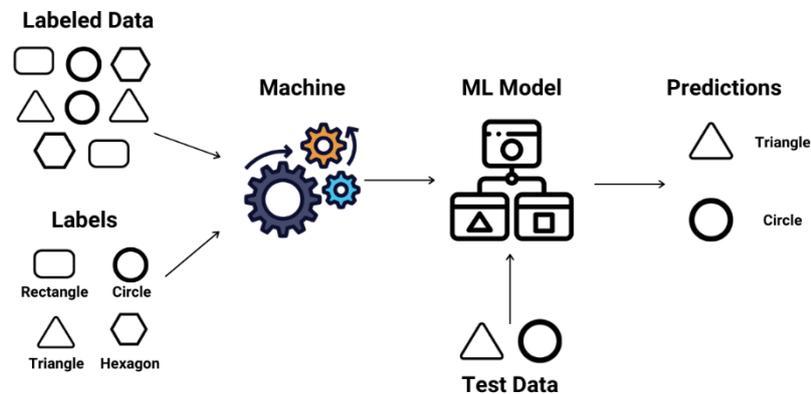


Figure II-2: Le principe de fonctionnement de l'apprentissage supervisé

La Figure II-2 illustre le fonctionnement de l'apprentissage supervisé. Le mot supervisé renvoie à ce que les données d'apprentissage soient étiquetées, c'est-à-dire qu'on connaît la valeur qu'on souhaite prédire. Le processus d'apprentissage apprend à prédire cette valeur dans les données d'apprentissage et essaie de la prédire dans les données de test.

Il existe plusieurs algorithmes d'apprentissage supervisé (Burkart and Huber 2021), chacun avec leurs avantages et inconvénients. Ci-après une description de certains des algorithmes les plus couramment utilisés :

**Les arbres de décision :** L'objectif est de prendre une décision à partir d'un ensemble de conditions en effectuant une série de choix binaires. (Breiman et al. 2017; Quinlan 1986). Un arbre de décision est construit en sélectionnant une variable (ou attribut) qui divise le mieux l'ensemble de données en sous-ensembles homogènes (ou partitions). Cette opération est effectuée récursivement pour chaque partition jusqu'à ce que les données soient suffisamment homogènes ou qu'un critère d'arrêt soit atteint. Ils peuvent être utilisés pour des tâches de classification ou de régression. Dans le cas de la classification, chaque nœud de l'arbre représente une question sur une variable (par exemple, "La température est-elle supérieure à 30°C ?"). Les branches de l'arbre correspondent à chaque réponse possible (oui ou non). Les feuilles de l'arbre représentent les classes de sortie (par exemple, "Surchauffé" ou "Normal") (Atziori, Iera, and Morabito 2010; Vanfretti and Arava 2020). Dans le cas de la régression, l'objectif est de prédire une valeur continue plutôt que de classer une observation dans une catégorie. Les nœuds internes de l'arbre sont des tests de conditions sur les valeurs des attributs, tandis que les feuilles sont des valeurs numériques de sortie (De Caigny, Coussement, and De Bock 2018). L'un des avantages des arbres de décision est qu'ils sont relativement faciles à interpréter et à visualiser, ce qui les rend populaires pour les tâches de diagnostic. En outre, ils sont capables de gérer efficacement des données avec des variables catégorielles et numériques (S. Liu et al. 2018).

**Les réseaux de neurones :** sont une technique Machine Learning qui s'inspire du fonctionnement du cerveau humain pour apprendre à partir de données complexes (Rosenblatt 1958). Ces réseaux sont composés de neurones artificiels interconnectés, qui peuvent être organisés en différentes couches.

Chaque neurone prend en entrée un ensemble de valeurs et effectue un calcul pour produire une sortie. Les entrées sont pondérées par des poids qui sont ajustés pendant la phase d'apprentissage pour minimiser l'erreur de prédiction. Les sorties de chaque neurone sont ensuite transmises à d'autres neurones de la couche suivante pour calculer une sortie globale du réseau. Les réseaux de neurones peuvent être utilisés pour des tâches de classification, de régression et de clustering. Dans le cas de la classification, les neurones de la dernière couche du réseau représentent les différentes classes de sortie. Les entrées du réseau sont les caractéristiques d'une observation, et la sortie du réseau représente la probabilité d'appartenance à chaque classe. La classe avec la plus haute probabilité est sélectionnée comme prédiction finale. Dans le cas de la régression, les neurones de la dernière couche représentent une valeur de sortie continue plutôt qu'une classe. Les entrées du réseau sont les caractéristiques d'une observation, et la sortie du réseau est une prédiction continue de la variable cible. Dans le cas du clustering, les neurones de la dernière couche représentent les différents clusters, et l'objectif est de trouver une représentation compacte des données qui maximise la similarité intra-cluster et minimise la similarité inter-cluster.

**Les machines à vecteurs de support :** La Support Vector Machines (SVM) en anglais, est une technique d'apprentissage supervisé utilisée dans le domaine du Machine Learning pour résoudre des problèmes de classification et de régression (Cortes and Vapnik 1995). L'objectif de la SVM est de trouver un hyperplan qui sépare les données en deux classes, de telle sorte que la marge, qui est la distance entre les points les plus proches de chaque classe et l'hyperplan, soit maximale. Ces points sont appelés vecteurs de support (Gholami and Fakhari 2017). Dans le cas d'une classification binaire, l'hyperplan est défini comme une droite ou un plan dans un espace de dimensions équivalentes au nombre de caractéristiques du jeu de données. Si les classes ne sont pas linéairement séparables, un noyau peut être utilisé pour projeter les données dans un espace de dimension supérieure où elles seront linéairement séparables. Une fois l'hyperplan défini, les SVM peuvent être utilisées pour classer de nouvelles observations en fonction de leur position relative à l'hyperplan. Les observations situées d'un côté de l'hyperplan sont classées comme appartenant à une classe, tandis que les observations situées de l'autre côté de l'hyperplan sont classées comme appartenant à l'autre classe. Les SVM peuvent également être utilisées pour résoudre des problèmes de régression. Dans ce cas, l'objectif est de trouver un hyperplan qui minimise l'erreur de prédiction entre les valeurs réelles et les valeurs prédites. L'hyperplan est choisi de telle sorte que la somme des distances entre les points de données et l'hyperplan soit minimale (Zendehboudi, Baseer, and Saidur 2018). Les SVM sont largement utilisées dans des applications telles que la classification de textes, la reconnaissance d'images et la détection de fraude, car elles sont très performantes pour traiter des données complexes et des problèmes de grande dimensionnalité (Maulik and Chakraborty 2017; Cervantes et al. 2020).

**La régression linéaire :** Elle permet de modéliser la relation entre une variable dite « dépendante » et une ou plusieurs variables dites « indépendantes ». Elle est utilisée pour prédire une valeur numérique continue en fonction des valeurs d'une ou plusieurs variables explicatives. La régression linéaire est basée sur la fonction mathématique d'une droite, appelée droite de régression, qui représente la relation entre les variables (Ross and Willson 2017). La droite est déterminée par un ensemble de coefficients numériques, appelés coefficients de régression, qui sont calculés à partir des données d'apprentissage. Le but de la régression linéaire est de trouver les coefficients de régression qui minimisent l'écart entre les valeurs prédites et les valeurs réelles des données (Schmidt and Finan 2018). Il existe deux types de régression linéaire :

simple et multiple selon le nombre de variable(s) explicative(s) utilisé(s) (Hu et al. 2019). Le modèle de régression linéaire multiple est souvent utilisé lorsque plusieurs variables ont une influence sur la variable dépendante.

**Les forêts aléatoires :** Elles sont utilisées pour la classification et la régression et sont particulièrement utiles pour des ensembles de données contenant de nombreuses variables (Ho 1995). Le principe de base des forêts aléatoires est de combiner plusieurs arbres de décision en un seul modèle (Paul et al. 2018). Chaque arbre de décision est construit en utilisant un sous-ensemble aléatoire des données d'apprentissage et des variables explicatives. Les variables explicatives sont sélectionnées de manière aléatoire pour chaque nœud de décision, ce qui réduit la corrélation entre les arbres et améliore la précision des prédictions.

## II-2/ L'apprentissage non supervisé

Dans ce type d'apprentissage, le processus doit trouver des modèles et des structures dans les données d'entrée sans être guidé par des étiquettes ou des sorties prédéfinies (Memoona et al. 2015).

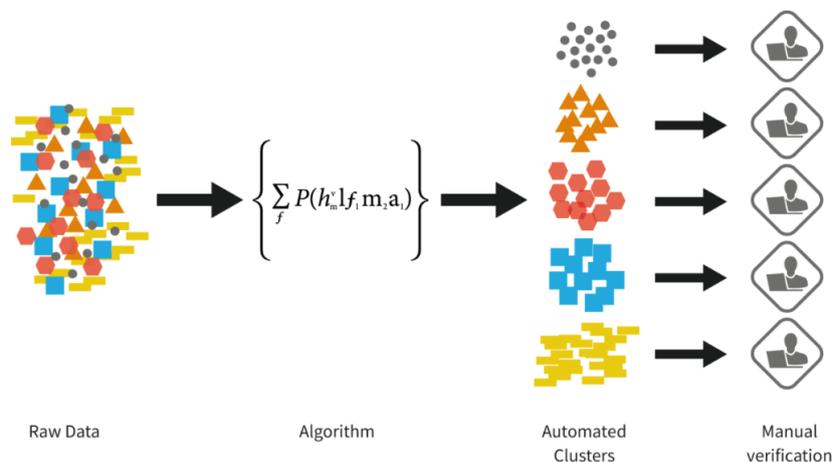


Figure II-3: Le principe de fonctionnement de l'apprentissage non supervisé

Comme la Figure II-3 le montre et contrairement à l'apprentissage supervisé, le non-supervisé apprend à partir de données non étiquetées (Ezugwu et al. 2022; Mohammadi et al. 2018; Alloghani et al. 2020). Le résultat final de ce type d'apprentissage nécessite généralement une intervention manuelle pour labéliser chaque groupe (cluster) détecté. Les algorithmes les plus utilisés pour ce type d'apprentissage sont les suivants :

**Le k-means :** Le k-means est un algorithme de clustering utilisé pour diviser un ensemble de données en un certain nombre de groupes (clusters) (J. Wu 2012). Les algorithmes de clustering exploitent la structure sous-jacente de la distribution des données et définissent des règles pour regrouper les données présentant des caractéristiques similaires (Jain, Murty, and Flynn 1999). Ce processus aboutit à la partition d'un ensemble de données en fonction des critères de regroupement sans aucune connaissance préalable de l'ensemble des données (données non labélisées). Dans un scénario de regroupement idéal, chaque groupe se compose d'instances de données similaires qui sont très différentes des instances des autres groupes. Une telle mesure de dissimilarité dépend des données sous-jacentes et de l'objectif de l'algorithme. Le regroupement est au cœur de nombreuses applications basées sur les données et est considéré comme une tâche intéressante et importante dans le domaine du Machine Learning. Il est

également étudié dans les statistiques, la reconnaissance des formes, la géométrie informatique, la bio-informatique, l'optimisation, le traitement des images et dans de nombreux autres domaines (Ahmed 2018; Tondini et al. 2019).

**La classification hiérarchique** : est une technique de Machine Learning qui consiste à regrouper des données similaires en clusters hiérarchiques, qui peuvent ensuite être subdivisés en sous-clusters plus petits (Silla and Freitas 2011). Cette technique est souvent utilisée pour explorer et visualiser la structure des données non étiquetées (Figure II-4). Il existe deux types de classifications hiérarchiques : la classification hiérarchique ascendante (CHA) et la classification hiérarchique descendante (CHD). La CHA commence par considérer chaque donnée comme un cluster individuel et fusionne ensuite les clusters similaires en un seul cluster. La CHD, quant à elle, commence avec un seul cluster contenant toutes les données et les divise en sous-clusters plus petits à chaque étape (Silla and Freitas 2011; Tieppo et al. 2022).

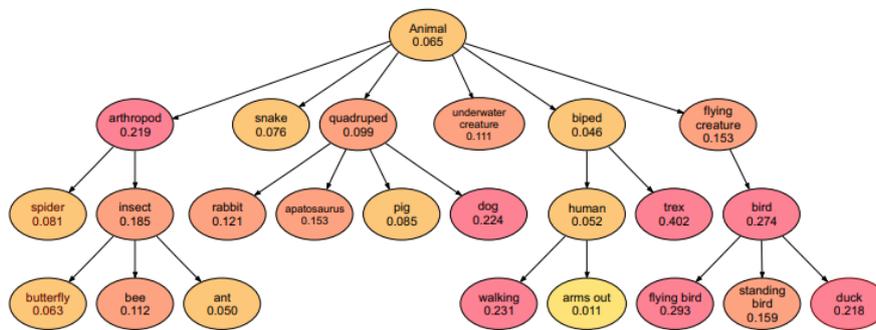


Figure II-4: Exemple de classification hiérarchique (Barutcuoglu and DeCoro 2006)

Le processus de classification hiérarchique commence par le calcul de la similarité entre les données. La mesure de similarité la plus couramment utilisée est la distance euclidienne, qui mesure la distance entre les points dans l'espace des caractéristiques. Une autre mesure courante est la corrélation, qui mesure la relation linéaire entre deux variables. Une fois que les mesures de similarité ont été calculées, les données sont regroupées en clusters hiérarchiques en utilisant un algorithme de regroupement, comme la méthode de Ward, la méthode de la liaison moyenne ou la méthode de la liaison simple. Ces méthodes utilisent différentes règles pour fusionner les clusters en fonction de leur similarité (Gordon 1987).

La classification hiérarchique peut être représentée sous forme de dendrogramme (Alshamaa, Chehade, and Honeine 2018), un diagramme en forme d'arbre qui montre la hiérarchie des clusters. Les clusters sont représentés par des nœuds, et les branches représentent la distance entre les clusters. Cependant, cette classification peut être sensible aux données aberrantes et peut nécessiter une validation externe pour déterminer le nombre optimal de clusters (Silla and Freitas 2011).

**L'analyse en composantes principales (PCA)** : AFD est une technique de Machine Learning très réputée qui permet de réduire la dimensionnalité des données en projetant les données originales dans un nouvel espace de dimensions inférieures, tout en conservant un maximum d'informations utiles. Cette technique est souvent utilisée pour explorer et visualiser les données multidimensionnelles et pour améliorer la performance des modèles de Machine Learning en réduisant la complexité de l'ensemble de données (Abdi and Williams 2010; Karamizadeh et al. 2013). Le processus de PCA commence par le calcul de la matrice de

covariance (D'Agostini 1994), qui mesure la relation entre les différentes variables de l'ensemble de données. Cette matrice, décrivant la variance et la corrélation entre les variables, est utilisée pour déterminer les directions principales (composantes) dans lesquelles les données présentent le plus de variation. Ensuite, l'algorithme PCA calcule les vecteurs propres (ou axes principaux) associés aux valeurs propres de la matrice de covariance. Les vecteurs propres sont des directions dans l'espace de données qui représentent les axes avec la plus grande variation. Les composantes principales sont formées en combinant les variables originales et en utilisant les vecteurs propres associés aux valeurs propres les plus élevées (Mohammed, Hasan, and Mohsin Abdulazeez 2021). Les données peuvent ensuite être projetées dans le nouvel espace de dimensions inférieures en utilisant les vecteurs propres comme axes. Cette projection de données dans l'espace de dimensions inférieures permet de réduire la complexité des données tout en conservant les informations les plus importantes. Les nouvelles variables (composantes principales) qui sont créées après la projection sont des combinaisons linéaires des variables originales et sont ordonnées en fonction de l'importance de leur contribution à la variance totale des données. La PCA peut être utilisée pour de nombreux cas d'usage, tels que l'analyse de données, la reconnaissance de formes, la classification, la compression de données, etc. Elle peut également être utilisée comme étape de prétraitement pour d'autres algorithmes de Machine Learning en réduisant la dimensionnalité de l'ensemble de données (Gewers et al. 2021). La PCA est particulièrement utile pour les ensembles de données contenant de nombreuses variables, où il est difficile de détecter des relations entre les variables, ou pour les ensembles de données contenant des variables corrélées.

**Les réseaux de neurones non-supervisés :** Ils forment une classe d'algorithmes de Machine Learning qui permettent de découvrir des structures cachées dans les données non étiquetées. Contrairement aux réseaux de neurones supervisés, qui nécessitent des données étiquetées pour apprendre, les réseaux de neurones non-supervisés sont capables d'extraire des motifs à partir de données non étiquetées.

Les réseaux de neurones non-supervisés sont souvent utilisés pour explorer et visualiser les données en identifiant des motifs ou des groupes de données similaires (Zaadnoordijk, Besold, and Cusack 2022). Ils peuvent également être utilisés pour effectuer des tâches de prétraitement des données, comme la réduction de la dimensionnalité des données (W. Wang et al. 2014). L'un des types de réseaux de neurones non-supervisés les plus courants est le réseau de neurones auto-encodeur. Ce type de réseau est composé de deux parties (Sewak, Sahay, and Rathore 2020): un encodeur qui transforme les données d'entrée en une représentation latente de dimensions inférieures, et un décodeur qui retransforme la représentation latente en une reconstruction de l'entrée originale. L'objectif de l'apprentissage est de minimiser la différence entre l'entrée originale et sa reconstruction, ce qui oblige le réseau à apprendre une représentation latente utile qui capture les motifs importants dans les données d'entrée.

Un autre type de réseau de neurones non-supervisé est le réseau de neurones de Kohonen ou carte auto-organisatrice (Murtagh and Hernández-Pajares 1995). Ce réseau permet de regrouper les données en fonction de leur similarité en utilisant une topologie en deux dimensions (Qu et al. 2021). Chaque neurone dans la carte représente une région de l'espace de données, et les neurones proches ont tendance à avoir des réponses similaires. L'apprentissage consiste à ajuster les poids des neurones pour qu'ils correspondent aux distributions de données dans l'espace de données.

### II-3/ L'apprentissage par renforcement

Dans ce type d'apprentissage, le modèle apprend à prendre des décisions en interagissant avec un environnement dynamique (Yi, Fu, and Liang 2023).

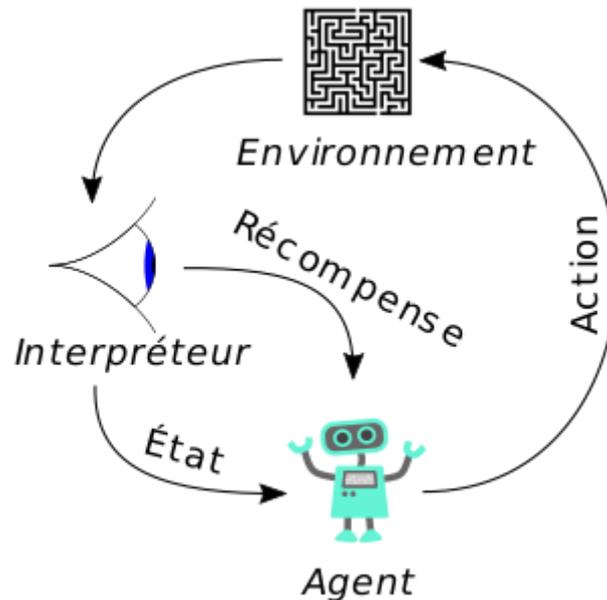


Figure II-5: Le principe de fonctionnement de l'apprentissage par renforcement

Le modèle est entraîné à maximiser une récompense en choisissant des actions qui ont un impact positif sur l'environnement, tout en minimisant les actions qui ont un impact négatif (Figure II-5). Les exemples d'applications de l'apprentissage par renforcement incluent les jeux vidéo, les voitures autonomes et les robots. Les algorithmes cités par la suite sont utilisés généralement pour l'apprentissage par renforcement (Botvinick et al. 2019; Yi, Fu, and Liang 2023).

**Q-Learning :** Parmi les algorithmes les plus connus pour le RL, le Q-Learning, qui utilise une table de valeurs Q pour estimer la valeur de chaque action pour chaque état de l'environnement. L'algorithme utilise la valeur Q pour choisir la meilleure action à prendre dans chaque état, en se basant sur une politique d'exploration-exploitation. Le Q-Learning est largement utilisé dans les jeux, la robotique et le contrôle de processus (Kumar et al. 2020). Le SARSA est un autre algorithme d'apprentissage par renforcement qui est similaire à Q-Learning, mais qui utilise une approche plus conservatrice pour choisir les actions à prendre (Samsuden, Diah, and Rahman 2019). Au lieu de choisir toujours l'action ayant la valeur Q la plus élevée, SARSA choisit l'action en fonction de la politique d'exploration-exploitation, ce qui peut conduire à un comportement plus stable. SARSA est souvent utilisé dans les applications de contrôle en ligne. Deep Q-Networks (DQN) sont des réseaux de neurones profonds qui sont utilisés pour estimer la valeur Q dans des environnements complexes et continus. Les DQN utilisent un algorithme d'optimisation basé sur la descente de gradient pour ajuster les poids des réseaux de neurones en fonction des récompenses obtenues (Bester, James, and Konidaris 2019). Les DQN ont été utilisés dans le cadre de jeux vidéo, de la navigation de robots et de la reconnaissance d'objets.

**Policy Gradients :** Les Policy Gradients sont des algorithmes qui apprennent directement une politique en utilisant la descente de gradient. Ils sont principalement utilisés dans le cadre de contrôle en ligne où l'agent doit agir en temps réel pour maximiser les récompenses. Les Policy

Gradients ont été utilisés dans divers domaines (jeux vidéo, navigation de robots, manipulation de robots) (Daskalakis, Foster, and Golowich 2020).

**Actor-Critic :** Les algorithmes Actor-Critic sont une combinaison de Policy Gradients et de Q-Learning. L' « acteur » est chargé de choisir les actions à prendre, tandis que le « critique » est chargé d'évaluer la valeur des actions dans chaque état (Cheng et al. 2022). Les Actor-Critic sont largement utilisés pour résoudre des problèmes de contrôle en ligne et ont été utilisés dans les domaines des jeux vidéo et de la robotique.

En fonction du problème à résoudre, il est possible d'utiliser une combinaison de ces différents types d'apprentissage. Par exemple, *l'apprentissage semi-supervisé* combine l'apprentissage supervisé et non supervisé pour améliorer les performances d'un modèle lorsque les données d'entraînement sont limitées ou coûteuses à obtenir (Figure II-6).

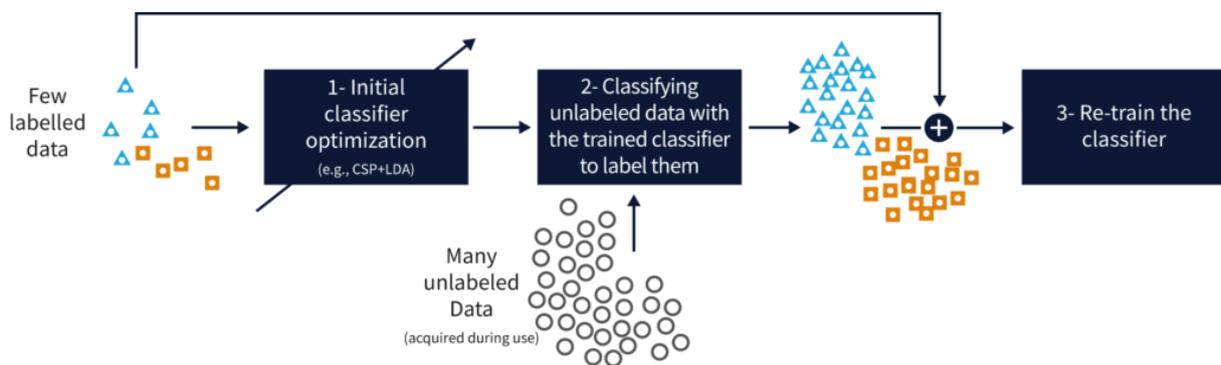


Figure II-6: Le principe de fonctionnement de l'apprentissage semi-supervisé

L'idée de base de l'apprentissage semi-supervisé est d'utiliser des exemples étiquetés pour guider le modèle dans l'apprentissage des structures de données, tout en utilisant des exemples non étiquetés pour améliorer la généralisation du modèle (van Engelen and Hoos 2020). Le processus d'apprentissage semi-supervisé concerne en particulier l'étape de l'apprentissage. Dans cette étape les données étiquetées sont utilisées pour entraîner un modèle de Machine Learning, comme dans l'apprentissage supervisé. Ce modèle est ensuite utilisé pour étiqueter les données non étiquetées en fonction de la sortie qu'il produit pour chaque exemple. Ensuite, les données étiquetées et nouvellement étiquetées sont utilisées pour re-entraîner le modèle. Ce processus peut être répété plusieurs fois pour améliorer la qualité des étiquettes produites pour les données non étiquetées.

### III/ Le Deep Learning

Le Deep Learning est une branche de l'Intelligence Artificielle (IA) qui utilise des réseaux de neurones artificiels pour apprendre à partir de données complexes. Contrairement aux algorithmes traditionnels de Machine Learning qui se basent sur la conception de modèles statistiques et de règles explicites, les réseaux de neurones du Deep Learning apprennent à partir de données brutes, sans nécessiter de prétraitement (Shrestha and Mahmood 2019). Les réseaux de neurones du Deep Learning sont organisés en couches successives, chacune effectuant des opérations sur les données d'entrée pour produire des sorties qui seront utilisées par la couche suivante. Les réseaux de neurones les plus simples ont une seule couche cachée, tandis que les réseaux plus complexes peuvent avoir des dizaines, voire des centaines de couches (H. Wu, Liu, and Liu 2019; Shrestha and Mahmood 2019).

Pendant la phase d'apprentissage, le réseau de neurones est entraîné à partir d'un ensemble de données d'entraînement en ajustant les poids et les biais de chaque neurone pour minimiser une fonction de coût prédéfinie. Cette fonction de coût mesure l'écart entre les sorties prédites du réseau et les sorties réelles des données d'entraînement. Le processus d'ajustement des poids et des biais est réalisé à l'aide d'algorithmes d'optimisation tels que la descente de gradient (Berman et al. 2019).

Une fois le réseau de neurones entraîné, il peut être utilisé pour effectuer des prédictions sur de nouvelles données en fournissant les données en entrée et en obtenant les sorties correspondantes à partir de la dernière couche du réseau (Berman et al. 2019). Les réseaux de neurones du Deep Learning sont capables de trouver des modèles complexes et non linéaires dans les données, ce qui les rend très efficaces pour des tâches telles que la reconnaissance d'images, la reconnaissance vocale, la traduction automatique et d'autres tâches de traitement du langage naturel (Mohammadi et al. 2018).

Les algorithmes les plus utilisés dans la littérature sont présentés ci-après :

**Les réseaux de neurones convolutifs (CNN) :** Ces algorithmes de Deep Learning sont particulièrement utilisés pour la reconnaissance d'images. Les CNN sont composés de plusieurs couches, chacune remplissant une fonction spécifique. La première couche est généralement une couche de convolution qui applique un filtre à l'image d'entrée pour extraire des caractéristiques (Z. Li et al. 2022). La deuxième couche est souvent une couche de pooling qui réduit la taille de l'image en prenant la valeur maximale (max-pooling) ou moyenne (average-pooling) de chaque région. Les couches suivantes sont des couches entièrement connectées qui utilisent des neurones artificiels pour classer les images en fonction des caractéristiques extraites des couches précédentes (Khan et al. 2020; Z. Li et al. 2022). L'apprentissage des CNN se fait par rétropropagation, qui consiste à ajuster les poids des filtres pour minimiser l'erreur entre la sortie prédite et la sortie réelle. Les filtres appris par les CNN sont spécifiques aux données d'entraînement et peuvent être utilisés pour la classification ou la détection d'objets dans de nouvelles images.

**Les réseaux de neurones récurrents (RNN) :** Ces algorithmes de Deep Learning sont utilisés pour traiter les données séquentielles (Y. Chen et al. 2020), telles que les séries temporelles (Weerakody et al. 2021). La Figure II-7 illustre le fonctionnement de base d'un RNN. Par exemple, les RNN peuvent être utilisés pour prédire les pannes d'équipements en utilisant des données de capteurs collectées au fil du temps et pour calculer la durée de vie utile avant la panne (Remaining Useful life RUL). Ils peuvent prendre en compte les données historiques de capteurs pour prédire la prochaine panne et aider les décideurs à planifier la maintenance préventive. Les RNN sont également utilisés pour optimiser la maintenance corrective. En utilisant les données de capteurs et des données d'utilisation opérationnelle afin d'identifier les causes racines des pannes d'équipements, ils peuvent aider les stakeholders à réduire les temps d'arrêt et à améliorer la fiabilité des équipements. Cependant, les RNN souffrent de deux problèmes principaux qui sont la disparition du gradient et le problème de la dépendance à long terme (Smagulova and James 2019). Pour résoudre ces problèmes, les réseaux de neurones LSTM (Long Short-Term Memory) ont été développés (Smagulova and James 2019; Yu et al. 2019). De structure plus complexe, les LSTM sont constitués de cellules qui peuvent stocker des informations pour une longue période de temps, et de portes qui régulent l'information entrante et sortante (Kantasa-ard et al. 2019; Sherstinsky 2020). Les LSTM sont capables de

conserver l'information dans la cellule pendant une longue période de temps, grâce à leurs portes, tandis que les RNN ont tendance à perdre l'information au fil du temps (Kantasa-ard et al. 2020; Sherstinsky 2020).

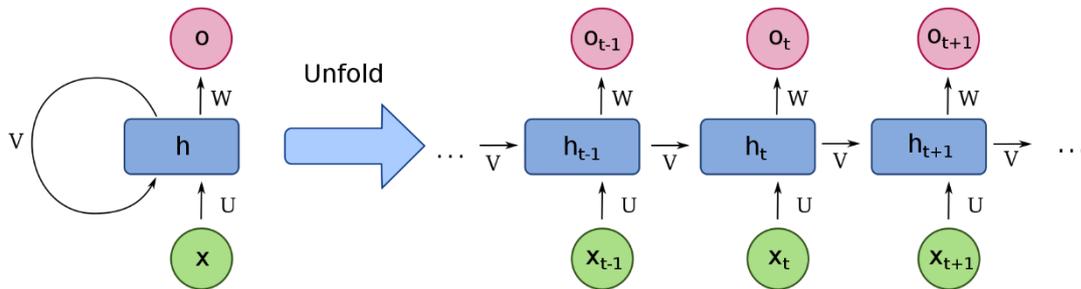


Figure II-7: Schéma d'un réseau de neurones récurrents à une unité de l'entrée à la sortie du réseau

**Les autoencodeurs** : Ces algorithmes sont utilisés pour réduire la dimensionnalité des données en conservant les caractéristiques les plus pertinentes. Les autoencodeurs peuvent être utilisés par exemple pour identifier les caractéristiques les plus pertinentes des données d'un capteur et réduire par la suite le bruit dans les données captées (Essien and Giannetti 2020). Un autoencodeur peut être entraîné à apprendre une représentation compressée des données de l'utilisation normale d'une machine. Lorsque de nouvelles données sont présentées à l'autoencodeur, il peut détecter les anomalies en comparant la reconstruction des données normales avec la reconstruction des données lors de l'exploitation de la machine en question.

**Les réseaux de neurones adverses génératifs (GAN)** : Ils sont utilisés pour générer de nouvelles données en apprenant à partir des données existantes (Figure II-8). Les GAN peuvent être utilisés pour générer des données de capteurs synthétiques pour simuler des scénarios de pannes et pour améliorer les modèles de prédiction de pannes.

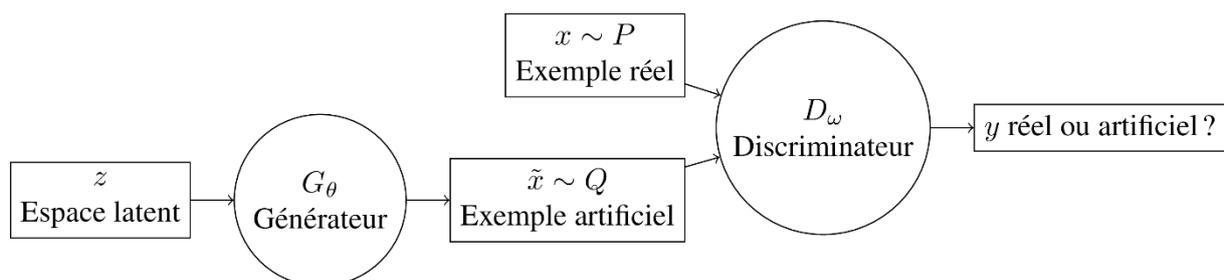


Figure II-8: Schéma général d'un GAN

Dans le domaine de la maintenance, l'application des approches précédentes peut apporter des améliorations significatives dans la gestion des équipements et des infrastructures. Ces approches permettent de prédire les pannes, d'optimiser les coûts de maintenance, de réduire les temps d'arrêt et d'améliorer la durée de vie des équipements. Ces techniques permettent l'analyse des données de surveillance et de diagnostic des équipements afin de détecter les anomalies et les signaux faibles.

Dans la partie suivante, l'application de ces approches dans le domaine de la maintenance est explorée au travers d'une analyse de la littérature.

## IV/ Les outils IA pour la maintenance

### IV-1/ Les différentes facettes analytics

Dans un contexte industriel, la maintenance est une activité essentielle pour assurer la performance et la fiabilité des équipements et des installations. Comme vu dans le chapitre I, elle peut être définie comme l'ensemble des actions visant à maintenir ou rétablir un bien en état ou en mesure d'assurer une fonction requise.

On peut notamment distinguer plusieurs types de maintenance, tels que la maintenance préventive, corrective, conditionnelle, ou encore la maintenance prédictive. Chacun de ces types de maintenance a ses avantages et ses inconvénients, et peut être adapté en fonction des besoins spécifiques de chaque entreprise. Les types de maintenance peuvent varier en fonction des objectifs recherchés, des coûts, des risques, de l'importance des équipements ou encore de la stratégie adoptée par l'entreprise.

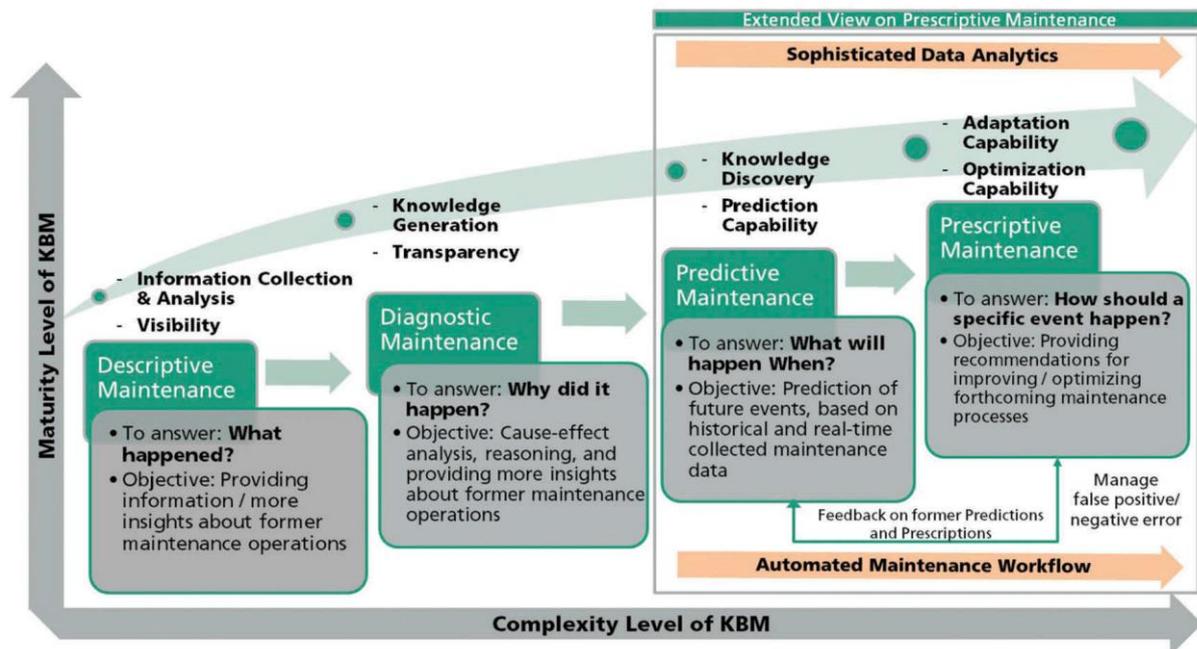


Figure II-9: Niveaux de maturité et de complexité de la gestion basée sur la connaissance

Il est donc primordial de bien comprendre les enjeux de chaque type de maintenance et le niveau de la maturité de la connaissance afin de fournir aux différents stakeholder l'assistance décisionnelle adéquate. Dans le contexte de la maintenance en particulier, les niveaux de complexité de la connaissance correspondent aux différents types de données et d'analyses qui peuvent être utilisés pour gérer les équipements et les actifs. Dans le contexte de la maintenance, la Figure II-9, extraite de (Muan Sang 2021), permet de distinguer différents niveaux selon ces axes de complexité et de maturité.

**Le niveau Descriptif :** Le niveau descriptif consiste à décrire l'état actuel des équipements et des actifs. Cette connaissance est basée sur les données historiques telles que des relevés issus de capteurs, les heures d'utilisation et les données d'entretien préventif. Les analyses

descriptives peuvent être utilisées pour comprendre les tendances et les anomalies dans les données historiques, ce qui peut aider à identifier des problèmes potentiels avant qu'ils ne se produisent.

**Le niveau Diagnostic :** Le niveau diagnostic consiste à comprendre les causes profondes des pannes ou des défaillances des équipements. Les analyses diagnostiques utilisent souvent des techniques d'analyse de cause à effet pour déterminer pourquoi un équipement est tombé en panne. Les données telles que les données de maintenance corrective et les rapports de pannes peuvent être utilisées pour identifier les facteurs sous-jacents qui ont conduit à une défaillance.

**Le niveau Prédicatif :** Le niveau prédictif consiste à prédire les défaillances ou les pannes futures à l'aide de modèles statistiques et de techniques d'apprentissage automatique. Les données telles que les relevés de température, les vibrations et les données de maintenance prédictive peuvent être utilisées pour créer des modèles prédictifs qui aident à identifier les équipements qui risquent de tomber en panne avant qu'ils ne le fassent réellement.

**Le niveau Prescriptif :** Le niveau prescriptif consiste à recommander des actions spécifiques à prendre pour résoudre les problèmes détectés. Les analyses prescriptives peuvent recommander des actions telles que la maintenance préventive ou la réparation immédiate. Les données d'analyse peuvent être utilisées pour recommander la meilleure action à prendre pour minimiser le temps d'arrêt de l'équipement et maximiser la disponibilité opérationnelle.

#### **IV-2/ Proposition d'un cadre tridimensionnel pour la modélisation et la classification des travaux**

Dans cette section nous proposons un cadre tridimensionnel d'analyse et de classification des travaux de la revue de littérature. Comme explicité à la Figure II-10, les trois dimensions considérées sont les facettes analytiques, le niveau de traitement et la disponibilité des données.

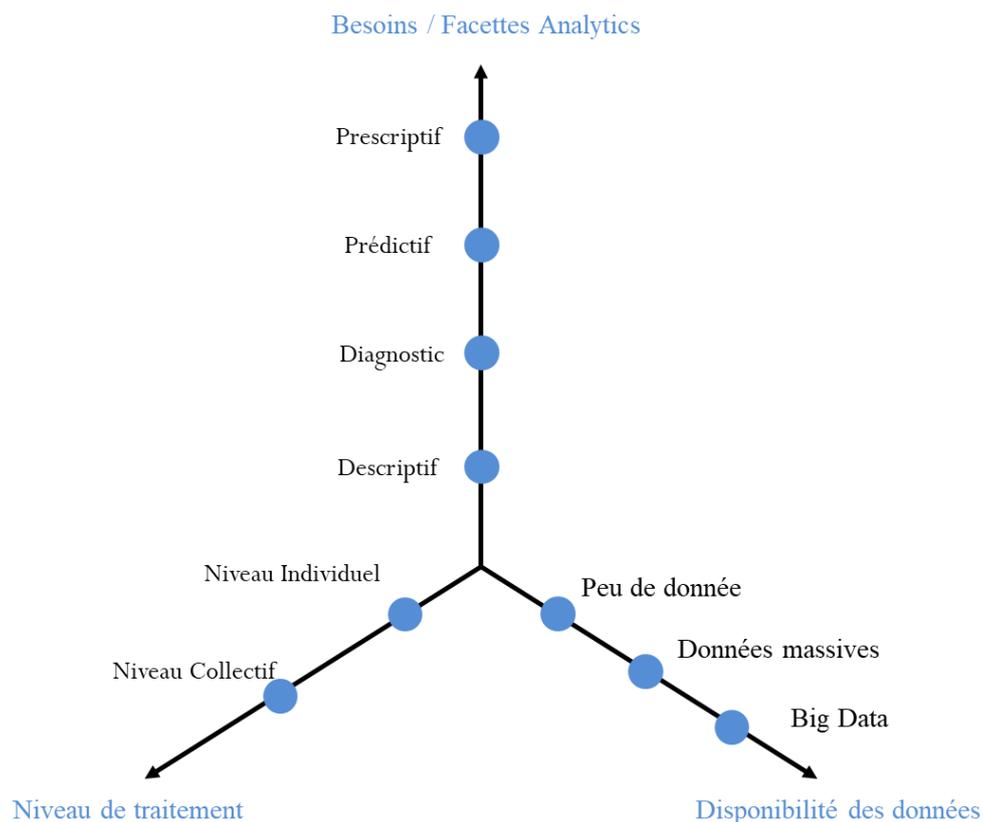


Figure II-10: Cadre tridimensionnel pour l'analyse des travaux scientifiques

Le premier axe reprend les différentes facettes Analytics explicitées dans la section précédente.

Le deuxième axe caractérise le niveau de traitement : individuel ou collectif. Le traitement individuel se concentre sur les données individuelles issues des systèmes eux-mêmes et de leur environnement, tandis que le traitement collectif s'intéresse aux données agrégées concernant un collectif de systèmes (ex : flotte de véhicules ferroviaires).

Le troisième axe concerne la disponibilité des données. Les données peuvent être peu nombreuses, massives ou de type Big Data. La catégorie « Peu de données » se réfère aux ensembles de données de petite taille qui peuvent être analysés avec des méthodes statistiques classiques. La catégorie « données massives », en revanche, caractérise des ensembles de données très volumineux nécessitant des méthodes d'analyse et de calcul plus poussées. La catégorie « Big Data » se réfère à des ensembles de données extrêmement volumineux et généralement hétérogènes qui nécessitent des outils d'analyse avancés et des technologies de traitement spécifiques au domaine du Big Data. Comme introduit dans le chapitre I, les Big Data peuvent être considérés comme des volumes de données que les systèmes traditionnels ne peuvent pas stocker et traiter (Gandomi and Haider 2015). L'idée traditionnelle pense à tort que les Big Data devraient avoir la taille d'un téraoctet, d'un zettaoctet ou même d'un exaoctet alors que cela dépend de la situation dans laquelle les données ont été utilisées (Yoo 2015; Plantin et al. 2017).

Le Tableau II-1 suivant tente de comparer les différentes catégories de données.

Type de donnée	Taille	Géré par	Stockage	Exemples
<b>Peu nombreuse</b>	< 10GB	Excel, R	Dans la mémoire d'une machine standard	Historique de la maintenance (millier de ligne)
<b>Massive</b>	De 10GB à 1TB	Fichiers indexé, Base de données relationnelle	Disque dur, flash disque	Millions de transaction avec des liens relationnels
<b>Big Data</b>	>1TB	Hadoop, Base de données distribuées	Stocké sur des machines parallèles	Billions d'évènement issu des données brutes d'une flotte de machines

*Tableau II-1: Comparaison entre les différentes catégories de données*

Ce trièdre sera utilisé dans la prochaine section pour classer quelques-uns des travaux relatifs au domaine de la maintenance.

### **IV-3/ Les applications des outils analytics pour la maintenance**

Avec l'introduction de l'Internet des objets (IoT), de l'apprentissage automatique, de la technologie cloud et de l'analyse massive des données, les maintenances prédictive, prescriptive et proactive sont devenues plus accessibles. Afin de fournir des informations utiles aux gestionnaires et stakeholders, les données doivent être traitées avec des outils avancés adéquats pour générer des informations pertinentes et significatives. De ce fait, les données massives et leur traitement par l'apprentissage automatique, entre autres, doivent être capable de déceler, détecter et de traiter ces problèmes invisibles tels que la dégradation de la machine, l'usure des composants, etc.

Dans la suite de cette section, sont passés en revue trois principaux champs applicatifs des approches Analytics : la maintenance prédictive, la détection de défauts liée au diagnostic et l'optimisation de la maintenance.

#### **IV-3-1/ Maintenance prédictive**

Les outils Machine Learning et Deep Learning peuvent être utilisés pour prédire les pannes et les défaillances des équipements avant qu'elles ne se produisent. Les modèles de Machine Learning, par exemple peuvent être élaborés à partir de données historiques pour prédire les temps d'arrêt, les pannes et les réparations nécessaires. La Figure II-11 explore les différentes taxonomies de la maintenance prédictive. Dans ce qui suit, certains travaux portant sur la maintenance prédictive sont décrits.

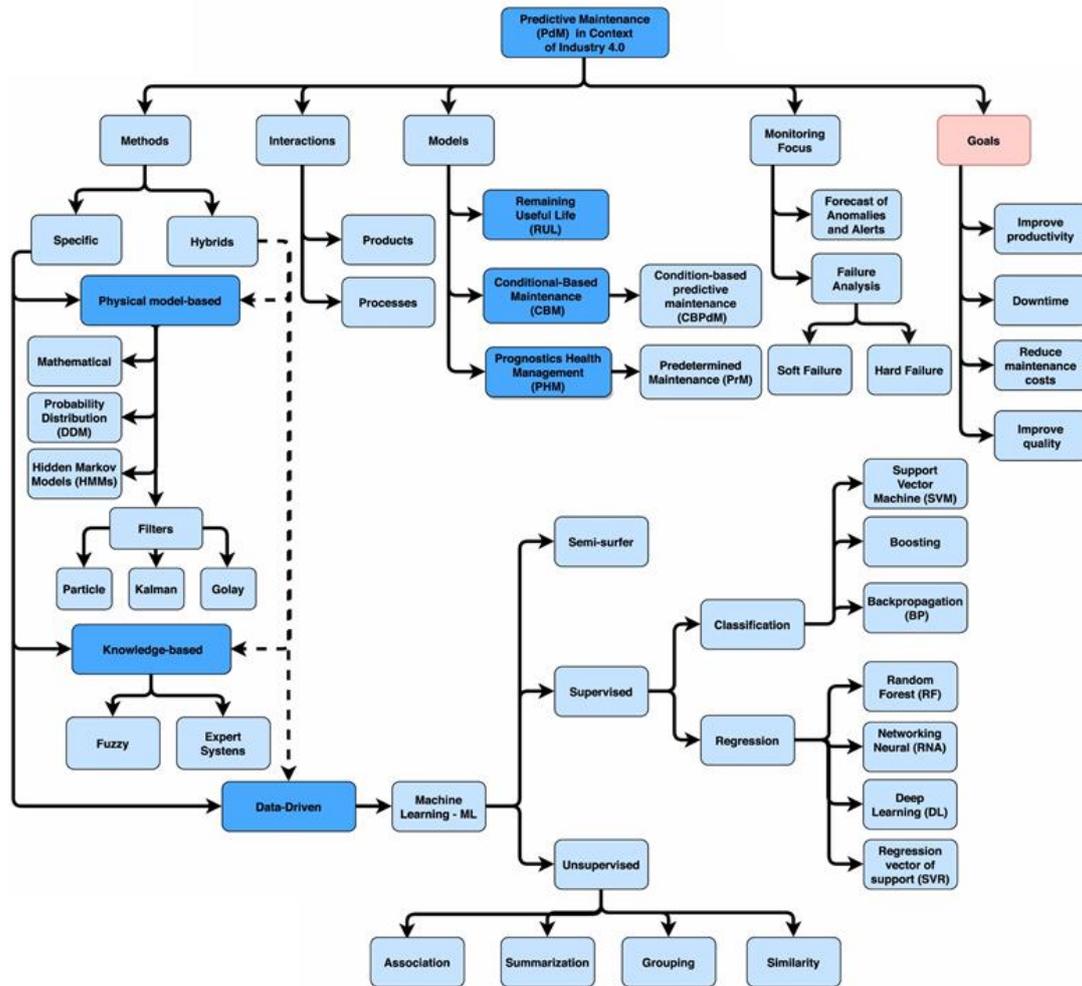


Figure II-11: Taxonomie de la maintenance prédictive

Le travail de (Haddad, Sandborn, and Pecht 2014) concerne la maintenance des parcs éoliens. Les auteurs ont proposé une aide à la décision de maintenance prédictive des éoliennes sur la base des prédictions de la durée de vie utile (RUL) en utilisant l’algorithme least squares Monte Carlo (LSMC). L’approche utilisée détermine la date maximale pour planifier la maintenance. Les gestionnaires de la maintenance du parc éolien peuvent donc déterminer des stratégies de maintenance opportuniste sur la base de ces résultats.

La Figure II-12 positionne ce travail selon le trièdre d’analyse préalablement présenté.

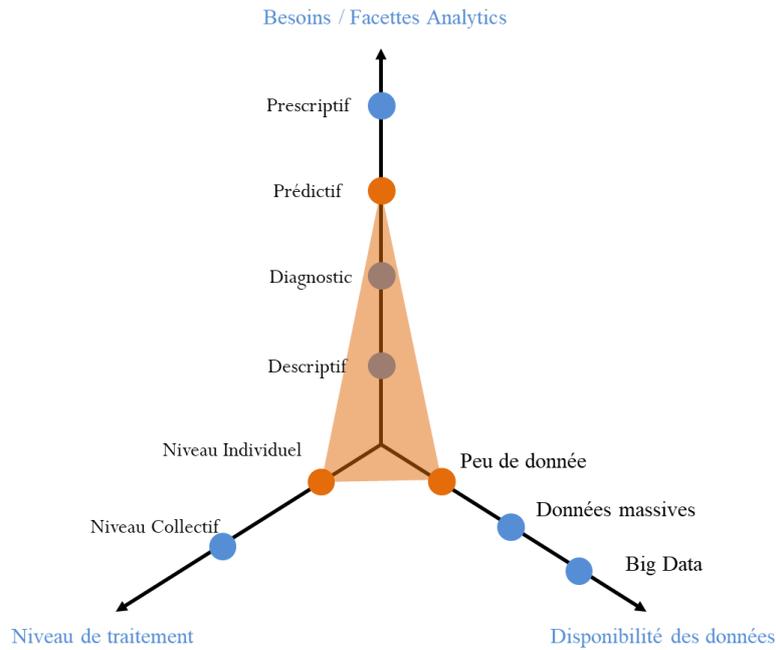


Figure II-12: Instanciation du cadre d'analyse pour le travail (Haddad, Sandborn, and Pecht 2014)

Dans (Bampoula et al. 2021), des autoencodeurs LSTM ont été mis au point pour estimer la durée de vie utile (RUL) d'équipements de systèmes cyber-physiques de production, permettant ainsi la mise en œuvre d'actions de maintenance prédictive. La stratégie de maintenance prédictive présentée a été confirmée comme plus rentable que la maintenance classique en cas de panne. La Figure II-13 illustre leur proposition.

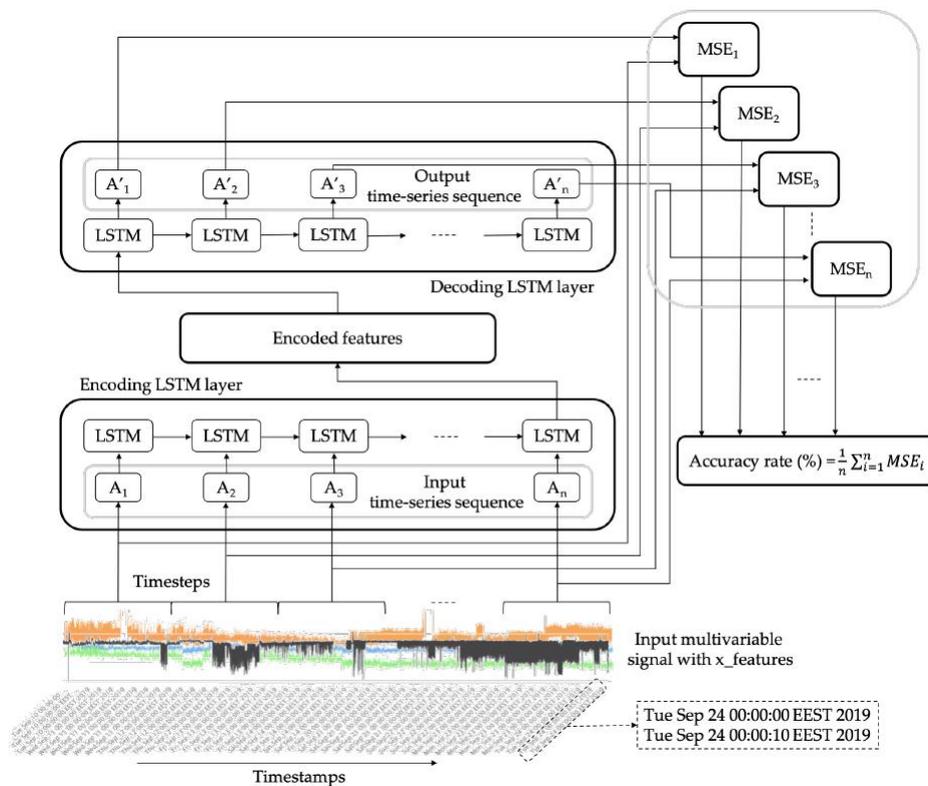


Figure II-13: L'architecture proposée par (Bampoula et al. 2021)

Le travail (Yang et al. 2022) est un exemple d'hybridation des outils du Machine Learning traditionnel et du Deep Learning. Les auteurs ont développé un système de maintenance préventive pour identifier les caractéristiques des données issues des capteurs d'un robot à l'aide de l'algorithme K-means et détecter par la suite l'état anormal du robot grâce à un modèle de réseau neuronal. Les résultats ont montré une précision de plus de 97%, avec une capacité de classification précise des données normales et des données anormales. Ce système permet de réduire les coûts d'inspection inutiles de l'équipement lors du processus de fabrication de semi-conducteurs. La Figure II-14 positionne leur travail selon les trois axes d'analyse.

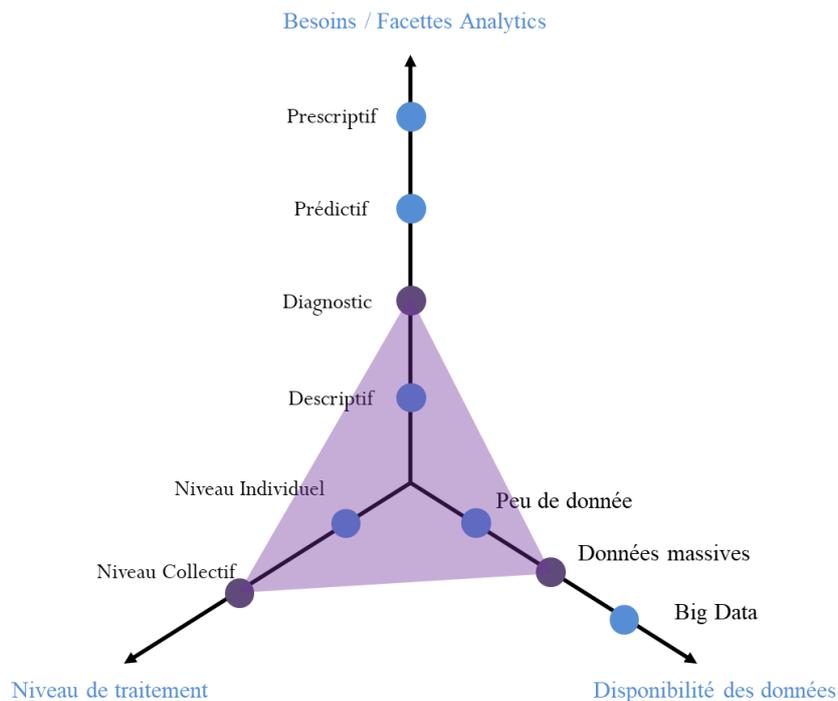


Figure II-14: Instanciation du cadre d'analyse pour le travail (Yang et al. 2022)

Les auteurs (Nguyen and Medjaher 2019) ont présenté un cadre de maintenance prédictive dynamique en utilisant l'algorithme LSTM. Ce dernier est utilisé pour calculer les probabilités de défaillance d'un système à des moments spécifiques et contribue ainsi à offrir une meilleure décision en matière de maintenance.

En comparant les arbres de décision, les forêts aléatoires et les arbre de renforcement du gradient (GBT), le travail (Zaharah Allah et al. 2019) a développé un modèle de maintenance prédictive pour prédire (i) si une maintenance sera effectuée ou retardée, (ii) le type d'activité de maintenance à effectuer et (iii) l'état d'avancement de la maintenance. Les résultats ont montré que le modèle GBT était le plus performant avec une précision de 86%. Pour la suite, les auteurs suggèrent de développer des modèles de régression pour estimer le meilleur moment pour effectuer la maintenance.

#### **IV-3-2/ Détection d'anomalies**

Le Machine Learning peut être utilisé pour détecter les anomalies et les erreurs dans les données issues de capteurs ou d'autres sources. Les algorithmes de détection d'anomalies peuvent apprendre à partir de données historiques pour identifier les comportements anormaux dans les machines et les équipements.

Le travail (D. Li et al. 2019) présente une nouvelle approche de détection d'anomalies multivariées sur des données de séries temporelles générées par des systèmes cyber-physiques en utilisant un réseau de neurones adverses génératifs (GAN). L'approche proposée utilise des LSTM-RNNs en utilisant un nouveau score nommé Discrimination and Reconstruction Anomaly Score (DR-Score). Les résultats ont montré que cette approche exhibe une performance supérieure aux méthodes de détection non supervisées existantes.

Dans (Diez-Olivan et al. 2017), les auteurs proposent une approche de pronostic basée sur les données pour prédire et identifier les anomalies et les défauts opérationnels dans des équipements complexes tels que les moteurs « marins » et les machines industrielles. Les résultats expérimentaux démontrent le potentiel de cette approche pour anticiper les défaillances potentielles en se basant sur l'état de santé de l'équipement mesuré par des capteurs. Les auteurs ont développé une stratégie de détection des anomalies en combinant l'approche K-means, la modélisation floue et le LOF-based score. Cette approche peut être intégrée dans un système de maintenance conditionnelle pour améliorer la fiabilité, la sécurité et les performances d'un équipement.

Le travail (Javed et al. 2021) propose une approche basée sur le mécanisme multi-étapes avec un réseau de neurones LSTM pour détecter des lectures anormales des capteurs dans les véhicules autonomes. Les résultats montrent que cette méthode, appelée MSALSTM-CNN, améliore efficacement le taux de détection des anomalies avec une faible quantité d'instances anormales dans le jeu de données. La Figure II-15 illustre l'architecture proposée.

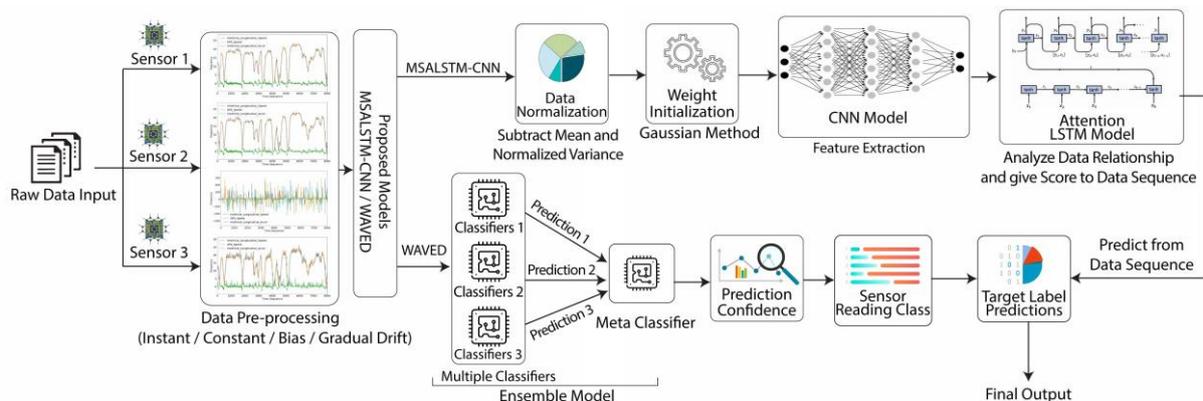


Figure II-15: L'architecture proposée par (Javed et al. 2021)

Dans des applications alliant surveillance et cybersécurité, le travail (Islam et al. 2022) propose une approche de détection précoce d'attaques sur le protocole CAN bus utilisé dans les réseaux ferroviaires autonomes. Utilisant un modèle du Extended Neural Networks (ENN), le modèle proposé surpasse les méthodes de comparaison, y compris les réseaux de neurones convolutionnels (CNN), les réseaux de neurones récurrents (LSTM) et les réseaux de neurones profonds (DNN), avec une précision de détection de 99,7% sur les données de test. Cependant, le modèle nécessite une infrastructure lourde et des ressources de calcul élevées.

#### IV-3-3/ Optimisation de la maintenance

Les techniques d'optimisation sont utilisées pour planifier les opérations de maintenance de manière efficace, en tenant compte des besoins des stakeholders, des contraintes de temps et de la disponibilité des ressources. Des techniques de la recherche opérationnelle et de l'optimisation peuvent être hybridées avec les outils analytics afin de déterminer une

planification optimale de la maintenance préventive ou corrective en minimisant les temps d'arrêt et les coûts. Ci-après sont cités des travaux dans différents domaines d'application.

L'approche proposée dans (Morariu et al. 2020) utilise une architecture de type Big Data (Figure II-16) pour la planification de la production et l'allocation de ressources dans des systèmes de production manufacturière. Cette approche utilise aussi des techniques du Deep Learning, en particulier l'algorithme LSTM pour apprendre des modèles de séries temporelles concernant les performances des ressources. Les résultats montrent que cette approche offre une vue globale sur l'horizon de production et permet une prise de décisions en temps réel. La Figure II-17 positionne ce travail selon notre cadre d'analyse.

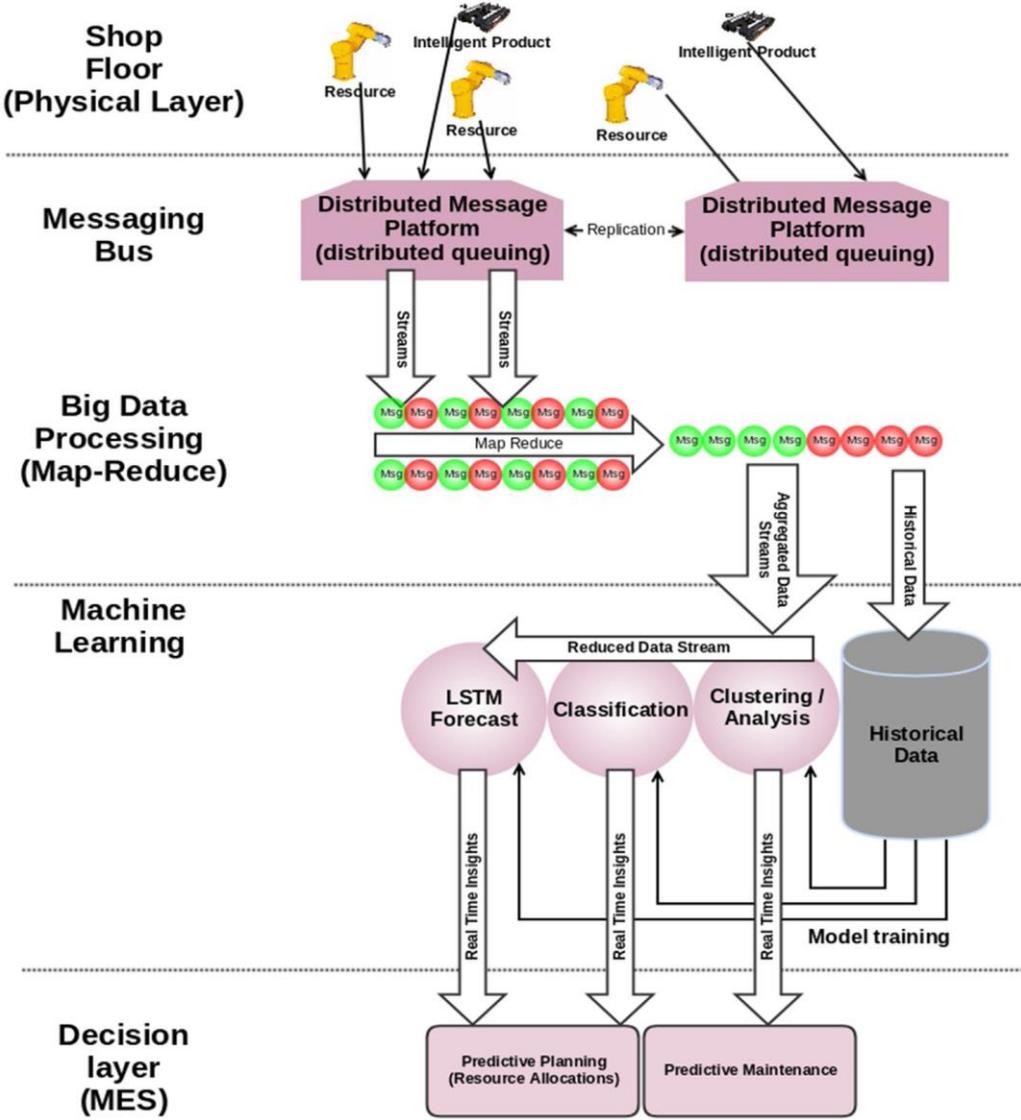


Figure II-16: L'approche proposée par (Morariu et al. 2020)

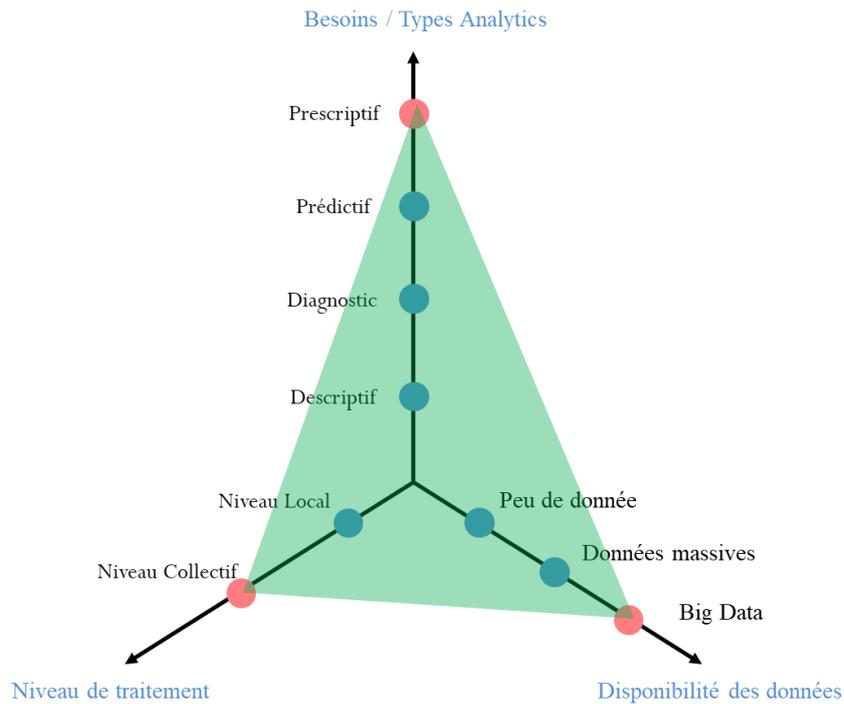


Figure II-17: Instanciation du cadre d'analyse pour le travail (Morariu et al. 2020)

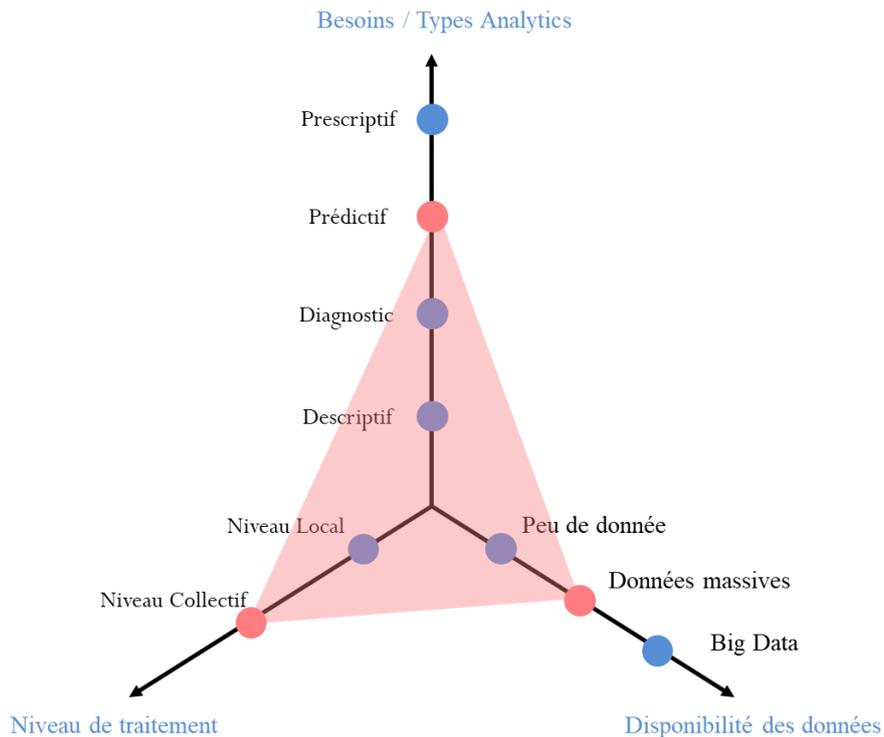


Figure II-18: Instanciation du cadre d'analyse pour le travail (Ridwan and Purnomo 2022)

Le travail (Ren et al. 2022) propose une nouvelle approche basée sur le Deep Neural Network (DNN) pour améliorer la performance de la maintenance en combinant différentes approches du Big Data analytics pour la collecte et l'analyse de données. L'approche a été validée avec des données issues des cycles de production de machines CNC afin d'optimiser la production et la politique de la maintenance.

Le travail (Ridwan and Purnomo 2022) a utilisé l'algorithme de Gated Recurrent Unit (GRU) pour prédire le Temps moyen entre deux défaillances (Mean Time Between Failure (MTBF)) d'un équipement permettant de diminuer le coût total de maintenance en optimisant les maintenances préventives et correctives. Cette approche permet également une gestion proactive des pannes pour maintenir les lignes de production. En outre, le modèle d'optimisation proposé peut être utilisé pour déterminer les plannings de maintenance en tenant compte du temps disponible. La Figure II-18 positionne le travail selon les trois axes d'analyse.

Dans le domaine du ferroviaire, le travail (Lopes Gerum, Altay, and Baykal-Gürsoy 2019) a proposé une hybridation entre le k-means, les arbres aléatoires (RF) le RNN et le Particle Swarm Optimisation (PSO) pour la détection des anomalies et la planification optimale des opérations de maintenance (Figure II-19). L'approche proposée est basée sur l'observation du système et sur des règles à base de seuils pour la planification des actions de maintenance. Les résultats indiquent un gain important même avec des contraintes fortes sur la disponibilité des ressources.

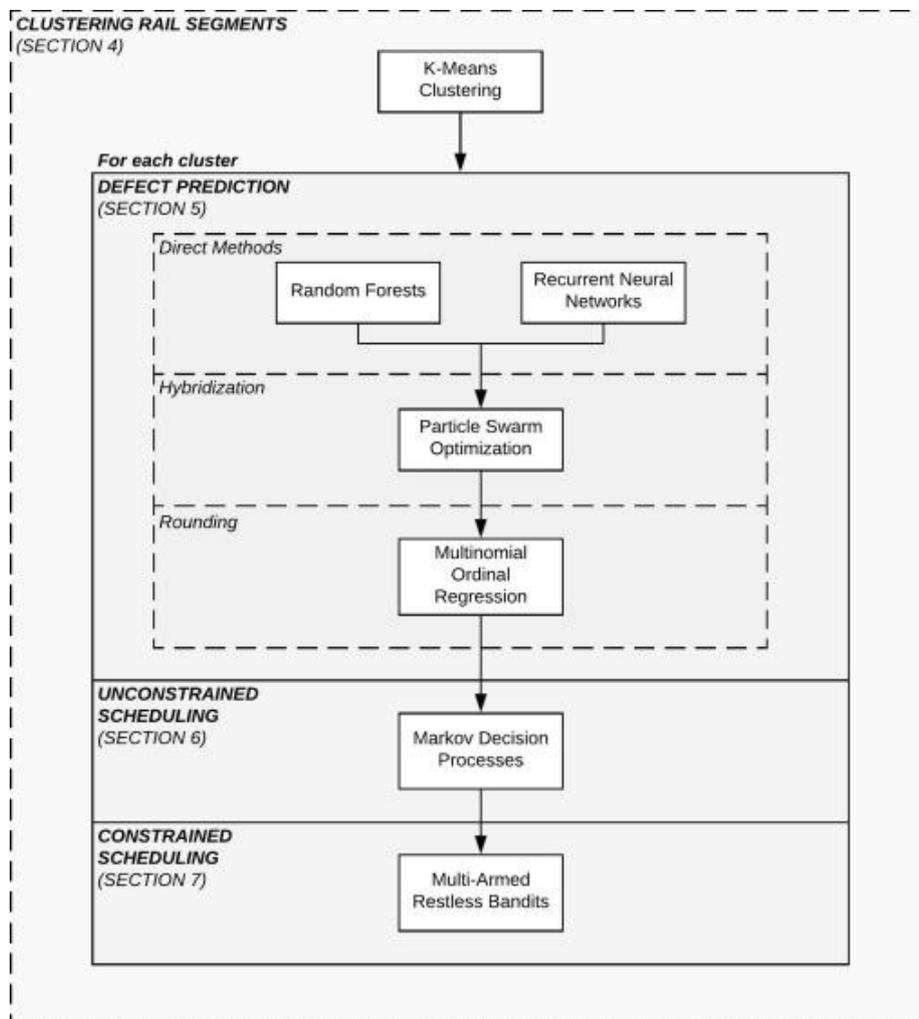


Figure II-19: L'architecture proposée par (Lopes Gerum, Altay, and Baykal-Gürsoy 2019)

La table II-2 ci-après offre une synthèse des travaux cités précédemment.

Table II-2 : Synthèse de la revue de littérature

Références	Modèle / méthode / architecture	Cas	Disponibilité données	Facette analytics	Niveau de traitement
(Haddad, Sandborn, and Pecht 2014)	Aide à la décision de maintenance prédictive des éoliennes sur la base des prédictions RUL en utilisant l'algorithme least squares Monte Carlo (LSMC).	La maintenance des parcs éoliens.	Peu de donnée	Prédictif	Individuel
(Bampoula et al. 2021)	Estimer la durée de vie utile (RUL) avec des autoencodeurs LSTM des équipements cyber-physiques dans le cadre d'une stratégie de maintenance prédictive.	Des équipements cyber-physiques.	Donnée massive	Diagnostic	Collectif
(Yang et al. 2022)	Hybridation des algorithmes K-means et les réseaux neuronaux.	Détection des anomalies des robots de transfert de plaquettes.	Donnée massive	Diagnostic	Collectif
(Nguyen and Medjaher 2019)	Cadre de maintenance prédictive dynamique en utilisant l'algorithme LSTM.	Détection d'anomalie.	Peu de donnée	Prédictif	Individuel
(Zaharah Allah et al. 2019)	Comparaison des arbres de décision, des forêts aléatoires et des Arbres de renforcement du gradient (GBT) et développement d'un modèle de maintenance prédictive	Détection des anomalies et planification de la maintenance.	Peu de donnée	Diagnostic	Individuel
(Islam et al. 2022)	Propose une approche basée sur un modèle d'ensemble de neurones extrêmes (ENN) et comparée avec les réseaux de neurones convolutionnels (CNN), les réseaux de neurones récurrents (LSTM) et les réseaux de neurones profonds (DNN).	Détection précoce d'attaques sur le protocole CAN bus utilisé dans les réseaux ferroviaires.	Donnée massive	Prédictif	Collectif

Références	Modèle / méthode / architecture	Cas	Disponibilité données	Facette analytics	Niveau de traitement
(D. Li et al. 2019)	Propose une nouvelle approche de détection d'anomalies multivariées sur des données de séries temporelles en utilisant un réseau de neurones adverses génératifs (GAN) et LSTM-RNNs.	Détection d'anomalies des systèmes cyber-physiques	Données massives	Prédictif	Collectif
(Diez-Olivan et al. 2017)	Proposition d'une stratégie de détection des anomalies en combinant entre le K-means, la modélisation fuzzy et le LOF-based score.	Prognostics et identification des anomalies et des défauts des moteurs marins et les machines industrielles	Données massives	Prescriptif	Collectif
(Javed et al. 2021)	Propose une approche basée sur le mécanisme multi-étape avec un réseau de neurones à mémoire à court terme (LSTM).	Détection des lectures anormales des capteurs dans les véhicules autonomes.	Données massives	Diagnostic	Collectif
(Morariu et al. 2020)	Proposition d'une architecture de Big Data en utilisant l'algorithme LSTM pour apprendre des modèles de séries temporelles.	Planification de la production et l'allocation de ressources dans des systèmes de fabrication à grande échelle.	Big Data	Prescriptif	Collectif

Références	Modèle / méthode / architecture	Cas	Disponibilité données	Facette analytics	Niveau de traitement
<i>(Ren et al. 2022)</i>	Propose une nouvelle approche basée sur le Deep Neural Network (DNN) et des approches du Big Data analytics.	Amélioration des performances de la maintenance des machines CNC.	Big Data	Prescriptif	Collectif
<i>(Ridwan and Purnomo 2022) a</i>	Approche basée sur l'algorithme de Gated Recurrent Unit (GRU) permettant une gestion proactive des pannes pour maintenir les lignes de production.	Prédiction du temps moyen entre deux défaillances (MTBF).	Données massives	Prédictif	Collectif
<i>(Lopes Gerum, Altay, and Baykal-Gürsoy 2019)</i>	Proposition d'une hybridation entre le k-means, les arbres aléatoires (RF) le RNN, le Particle Swarm Optimisation (PSO).	Détection des anomalies et la planification de la maintenance dans le domaine du ferroviaire.	Peu de donnée	Descriptif	Collectif

## **V/ Conclusion du chapitre**

Ce chapitre a permis de présenter les différentes approches utilisées dans le domaine de l'Analytics et de l'IA avec un focus sur les applications de maintenance.

Les outils IA et spécifiquement les outils Machine Learning et Deep Learning sont devenus de plus en plus populaire dans le domaine de la maintenance. Ils sont utilisés pour analyser des données massives, prévoir les pannes, optimiser les plannings de maintenance, et extraire des indicateurs pertinents. Cependant, bien que l'IA puisse offrir de nombreux avantages, elle présente également des limites pour la prise de décision dans le contexte de la maintenance. Tout d'abord, les algorithmes utilisés peuvent avoir des difficultés à comprendre le contexte spécifique de chaque cas. Par exemple, un algorithme d'IA peut être capable de prédire la probabilité de panne d'un équipement, mais il ne pourra pas prendre en compte les spécificités du contexte de maintenance, comme les contraintes budgétaires, les priorités opérationnelles ou encore les compétences des techniciens. Pour faire face à ces difficultés, comme exposé dans la revue de littérature réalisée, les auteurs hybrident plusieurs techniques ce qui augmente la complexité du calcul et aussi réduit la généralité des approches proposées.

En outre, les outils d'IA pour la maintenance peuvent être très dépendants de la qualité et de la quantité des données utilisées. Si les données sont incomplètes, inexactes ou obsolètes, les prévisions d'IA peuvent être biaisées ou incohérentes. Cela signifie que les résultats obtenus par ces algorithmes peuvent être difficiles à comprendre pour les non-spécialistes et que les décisions prises sur la base de ces résultats peuvent être remises en question. En plus, pour pallier aux problèmes liés au prétraitement des données, dans la littérature plusieurs approches ont été proposées pour améliorer la qualité des données d'apprentissage ce qui engendre plus de prétraitement spécifique selon le cas d'étude. Cependant, la plupart de ces approches deviennent très spécifiques à un cas particulier et perdent en généralité. Par exemple, certaines études ont proposé des méthodes de prédiction de la durée de vie restante d'un équipement en utilisant des données de capteurs. Cependant, ces méthodes sont souvent spécifiques à un type d'équipement et ne sont pas applicables à d'autres cas.

Finalement, la majorité des travaux explorés n'implique les décideurs que durant la phase de l'élaboration du cahier des charges. Cependant, les stratégies de maintenance à élaborer nécessitent une collaboration étroite entre les décideurs et les développeurs de l'assistance, ce qui peut être difficile à mettre en place dans la pratique sans cadre générique.

Le chapitre suivant répond à ces limites en proposant une modélisation de la chaîne informationnelle et décisionnelle partant de l'équipement (système « cible ») jusqu'aux différents stakeholders concernés.

## **Chapitre III**

# **Modélisation des processus décisionnels associés aux boucles cybernétiques**

### **Introduction**

Les propositions présentées dans ce chapitre se situent dans le prolongement des travaux de l'équipe depuis les années 2010 (Sallez et al. 2010; Sallez 2012; Basselot, Berger, and Sallez 2019b; Berger et al. 2020).

Les premières études (Sallez et al. 2010) ont proposé un modèle qui décrit les interactions supportées par les produits « actifs » dans un contexte de Closed-loop PLM. Ces études portaient principalement sur le produit lui-même et ne tenaient pas compte des complexités du contexte et des situations d'utilisation (utilisateur, environnement, etc.).

Plus tard, les travaux (Basselot 2019) ont pris en compte, en plus du produit, l'ensemble de son contexte en mettant l'accent sur les stakeholders impliqués dans les processus de prise de décisions associés au produit. Cependant, ces études s'intéressaient principalement à la modélisation des chaînes informationnelles reliant le produit aux stakeholders sans prendre en compte l'assistance pouvant être apportée pour la prise de décision.

Dans le cadre de ce mémoire, l'accent est mis sur l'assistance décisionnelle pouvant être apportée aux stakeholders. Le produit considéré est un SCP tel que décrit au chapitre I.

Dans une première section, seront présentées les différentes entités interagissant dans le cadre des différentes boucles cybernétiques associées à l'utilisation d'un système cyber-physique.

Afin de positionner le rôle de l'Humain dans ces boucles cybernétiques, les modèles permettant de caractériser un Système Humain-Cyber-Physique (SHCP) sont ensuite introduits.

Un modèle générique des processus décisionnels et de l'assistance associée est proposé dans une troisième section.

Enfin, un guide méthodologique permettant de supporter l'approche de modélisation proposée est détaillée dans une dernière section.

### **I/ Description d'un Système Humain-Cyber-Physique**

Avant de proposer un modèle générique de boucles cybernétiques associées à un système cyber-physique, il est nécessaire de préciser quelques exigences :

- Exigence n°1 (Exig. #1) : Le modèle doit permettre de décrire une grande variété de systèmes cyber-physiques (e.g. trains, équipements manufacturiers...), chaque système étant généralement lui-même composé de plusieurs sous-systèmes cyber-physiques ;
- Exigence n°2 (Exig. #2) : Le modèle doit être suffisamment générique pour répondre aux différents besoins des acteurs impliqués dans le cycle de vie du système ;
- Exigence n°3 (Exig. #3) : Le modèle doit être technologiquement agnostique.

Le type de système cyber-physique abordé dans ce chapitre peut être considéré comme un Système Humain-Cyber-Physique (Berger et al. 2020). Comme décrit à la Figure III-1, de manière générique un SHCP est composé d'humains et de machines (au sens entités artificielles) exécutant des tâches dans le cadre d'un domaine d'intérêt (par exemple, atelier manufacturier, réseau de transport ferroviaire...). Dans la suite du document, la composante matérielle de la partie « physique » d'un SHCP (ex : machine-outil, véhicule de transport...) est appelé système « cible ».

La Figure III-1 met en évidence plusieurs boucles cybernétiques, associées à des fonctions primaires et secondaires, détaillées ci-après.

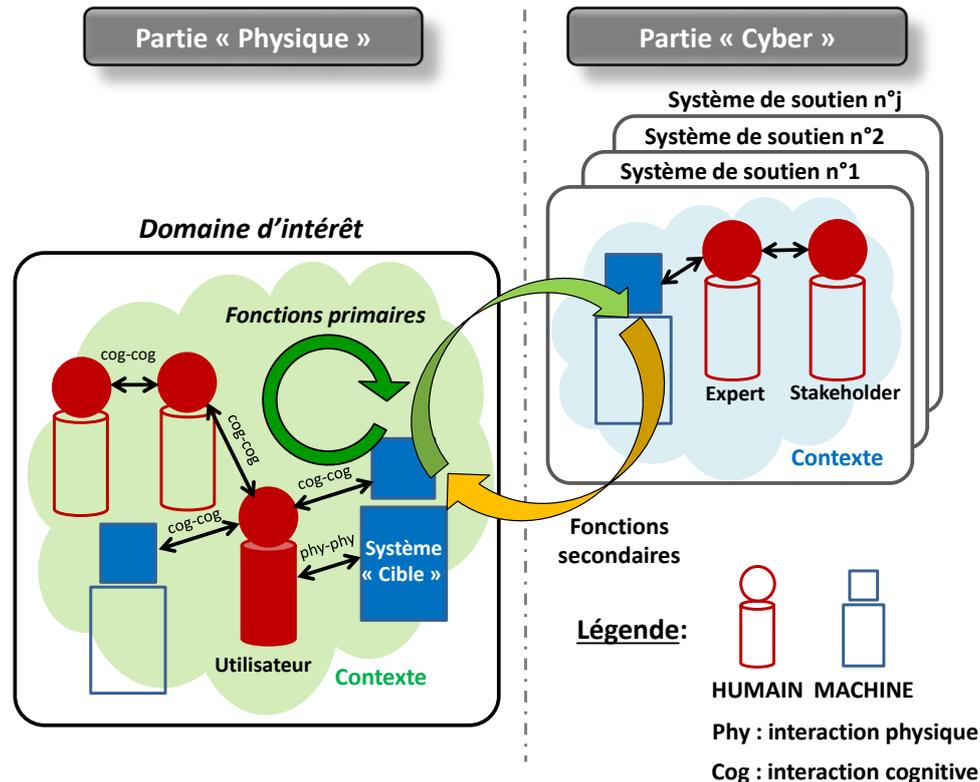


Figure III-1: Illustration d'un Système Humain-Cyber-Physique

### I-1/ Fonctions primaires

Les fonctions primaires  $Fp_i$  permettent au système « cible » de rendre des services à un ou plusieurs utilisateurs lors de sa phase d'usage. Par exemple, la fonction primaire la plus importante associée à un véhicule de transport routier sera la fonction  $Fp_1$  « transporter des marchandises de A à B ». Au regard de la décomposition d'un SHCP en partie « Physique » et partie « Cyber », les fonctions primaires se positionnent clairement dans la partie « Physique » du SHCP.

Comme décrit à la Figure III-1, le système « cible » servant de support à l'exécution des fonctions primaires, est immergé dans un contexte comprenant :

- Le ou les utilisateurs/acteurs humains interagissant avec le système « cible » dans le cadre d'une fonction primaire. Différentes catégories peuvent être distinguées : les utilisateurs qui bénéficient du service (e.g. les passagers d'un train bénéficiant d'un service de transport) et les acteurs qui pilotent directement le système « cible » (ex. conducteur d'un

train, opérateur sur une machine-outil). Différentes informations peuvent être associées à ces utilisateurs/acteurs : nom, identifiant dans l'entreprise, capacité à intervenir sur le système (ex. certifications, compétences particulières...).

- Les tâches associées à l'utilisation du système dans le cadre des fonctions primaires et donnant lieu à un comportement réel observable. A des fins de genericité, une tâche est considérée comme un processus permettant d'atteindre un objectif et, conjointement ou non, supportée (pour l'exécution) par des Humain(s) et/ou machine(s). A chaque tâche peuvent être associés une procédure d'utilisation prescrite et certains critères de performance (ex. qualité du résultat, durée de la tâche).
- L'environnement décrit les conditions dans lesquelles se déroule la tâche. Deux facettes principales sont considérées : physique (par exemple, température extérieure, hygrométrie) et non physique (par exemple, législation associée à l'utilisation du système « cible »).

### **I-2/ Fonctions secondaires**

D'autres fonctions, appelées fonctions secondaires  $F_{S_i}$  sont associées aux boucles cybernétiques (Surveillance / Amélioration / Evolution) introduites dans la section II-3-1 du chapitre I. Au regard de la décomposition d'un SHCP en partie « Physique » et partie « Cyber », les fonctions secondaires se situent dans la partie « Cyber » du SHCP. Lors de la phase MOL du cycle de vie, elles visent trois objectifs :

- Assurer la surveillance du système « cible » et sa traçabilité : Par exemple, dans le cadre de l'exemple précédent de transport routier, une fonction secondaire  $F_{S1}$  peut assurer la surveillance et veiller à l'intégrité du fret.
- Contribuer à l'amélioration des critères de performance associés aux fonctions primaires. Toujours pour le même exemple, une fonction secondaire  $F_{S2}$  peut améliorer la disponibilité de la flotte de véhicule via une maintenance prédictive.
- Générer différents flux d'informations vers les phases aval (EOL) ou amont (BOL) du cycle de vie du système, en accord avec l'approche « Closed-loop » PLM. Une fonction secondaire  $F_{S3}$  peut par exemple collecter les conditions d'usage du système pour faciliter son recyclage lors de la phase EOL.

Aux fonctions secondaires sont associées un ensemble d'acteurs (ex : experts du système « cible », stakeholders) comme décrit à la Figure III-1. Les boucles cybernétiques relient le système « cible » aux différents systèmes de soutien amenés à intervenir sur lui. Ces systèmes de soutien sont également immergés dans un contexte qui leur est spécifique (ex : réglementation du transport, contraintes financières ou juridiques).

Les caractéristiques génériques des fonctions primaires et secondaires, applicables aux différentes phases du cycle de vie du SHCP, permettent de répondre à la seconde exigence (Exig. #2) introduite précédemment.

### **I-3/ Exemple illustratif**

La Figure III-2 illustre une instantiation du modèle générique de SHCP dans le cas d'une application de transport qui servira de cas d'étude dans le chapitre V. Le véhicule constitue ici le système « cible » auquel peuvent être associées plusieurs fonctions primaires ( $F_{P1}$  : « transporter des marchandises de A à B »,  $F_{P2}$  : « charger / décharger la cargaison »). Les

tâches, relatives à ces fonctions primaires, sont caractérisées par des procédures prescrites (par exemple, comment la cargaison doit être transportée, chargée et déchargée) et certains critères de performance (par exemple, le temps de transport, la consommation d'énergie, la sécurité de la cargaison). L'utilisateur (i.e. le conducteur du véhicule) peut alors jouer plusieurs rôles au cours du processus de transport. Évidemment, le rôle principal concerne la conduite du véhicule alors qu'un rôle plus secondaire est relatif au chargement/déchargement de la cargaison.

Dans l'exemple de la Figure III-2, au niveau « véhicule », les systèmes supports internes exploitent le flux de données brutes collectées sur le processus de transport par les capteurs et l'instrumentation associés aux différents sous-systèmes (par exemple, les données envoyées par l'unité de contrôle électronique associée au moteur). Comme expliqué dans (Mortellec 2014) au travers d'une architecture décentralisée et coopérative, ces systèmes de support internes peuvent générer des informations raffinées et précises (par exemple, une liste de composants « suspects » en cas de défaillance).

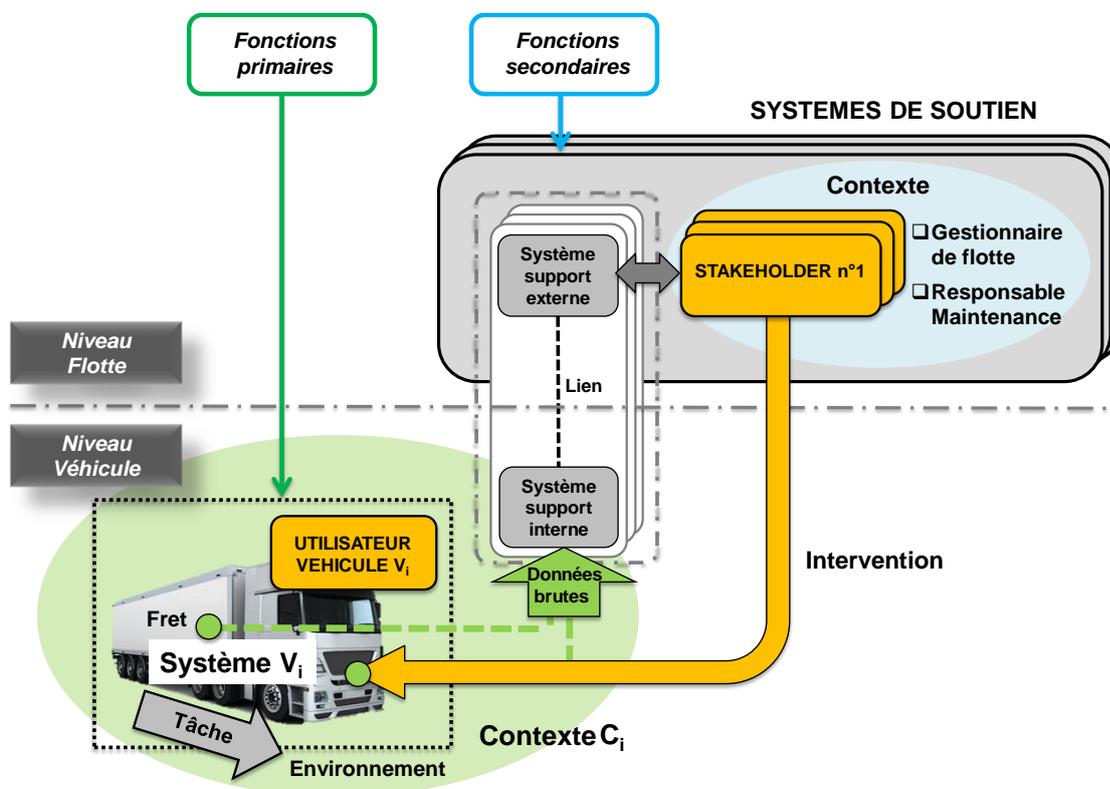


Figure III-2: Instanciation du modèle SHCP dans le cadre d'une application de transport routier

Au niveau « flotte », des systèmes de supports externes, composés de ressources expertes en diagnostic (humaines et/ou artificielles) génèrent des résultats d'expertise à destination des stakeholders impliqués. En tenant compte des résultats d'expertise générés, les stakeholders peuvent alors programmer des interventions sur le véhicule (ex : remplacement d'un composant en cours de détérioration).

Comme vu dans cette section, les interactions entre Humains et systèmes / machines sont au cœur des différentes boucles cybernétiques. Un modèle générique des relations Humain-machine dans le cadre de ces tâches est détaillé dans la section suivante.

## II/ Modélisation d'un Système Humain-Cyber-Physique

Afin de prendre en charge la complexité des différentes interactions ; un modèle générique pour l'Humain et la machine et un modèle générique des tâches au sein d'un SHCP sont successivement présentés dans les sections suivantes.

### II-1/ Modèles associés à l'Humain et à la machine

Comme illustré sur la partie droite de la Figure III-3, trois dimensions sont considérées pour caractériser l'Humain :

- Physique : cette dimension concerne toutes les interactions physiques agissant/percevant vers/depuis le domaine d'intérêt. Le comportement physique est sous le contrôle de processus conscients ou inconscients. Par exemple, dans une opération d'assemblage, la coordination des mouvements pour insérer précisément un câble dans un connecteur peut être déclenchée par le "cerveau conscient" (c'est-à-dire des processus contrôlés) mais l'exécution est prise en charge par le "cerveau inconscient" (c'est-à-dire des processus automatiques) (Schneider and Chein 2003).
- Cognitive : cette dimension concerne toutes les décisions conscientes prises en relation avec la résolution d'un problème (connu ou inconnu). Cette dimension est également liée à l'engagement intentionnel, au contrôle, au déclenchement, de la dimension physique pour percevoir et agir. Par exemple, l'exécution d'une tâche nécessite de respecter consciemment une procédure, des règles ou un protocole (par exemple, démarrer ou arrêter une machine, interagir avec les autres).
- Sociale : cette dimension concerne les relations avec les autres au sens large (i.e. Humains et / ou machines) dans le cadre d'interactions cognitives ou physiques. Par exemple, l'Humain peut interagir de manière collaborative avec un robot collaboratif vu comme un assistant physique, ou peut interagir avec une aide à la décision (ou autre Humain), vu comme un assistant cognitif.

Le contexte dans lequel l'Humain est immergé peut affecter ses performances sur les trois dimensions introduites. Par exemple, dans la dimension physique, un humain fatigué est plus lent. Dans la dimension cognitive, un humain avec une expertise limitée peut prendre de mauvaises décisions. Dans la dimension sociale, un humain soumis à un stress psychologique peut détourner son attention des autres, réduire ses interactions et commettre des erreurs.

Par analogie, ce modèle peut s'appliquer à une machine, comme illustré sur la partie gauche de la Figure III-3 en reprenant les mêmes dimensions :

- Physique : cette dimension concerne par exemple les parties mécaniques de la machine, les capteurs, les actionneurs et la commande de bas niveau utilisée pour animer une structure entière.
- Cognitive : cette seconde dimension concerne le contrôle de haut niveau de la machine gérant la dimension physique. Par exemple, l'exécution d'une procédure pour réaliser une opération d'usinage, de transport...
- Sociale : cette dernière dimension concerne les règles et protocoles utilisés pour interagir avec les autres (i.e. Humains, machines) et contribuant à l'exécution de la tâche.

Comme pour l'Humain, ces trois dimensions sont affectées par le contexte (e.g. température, vibration, énergie...) impactant la machine.

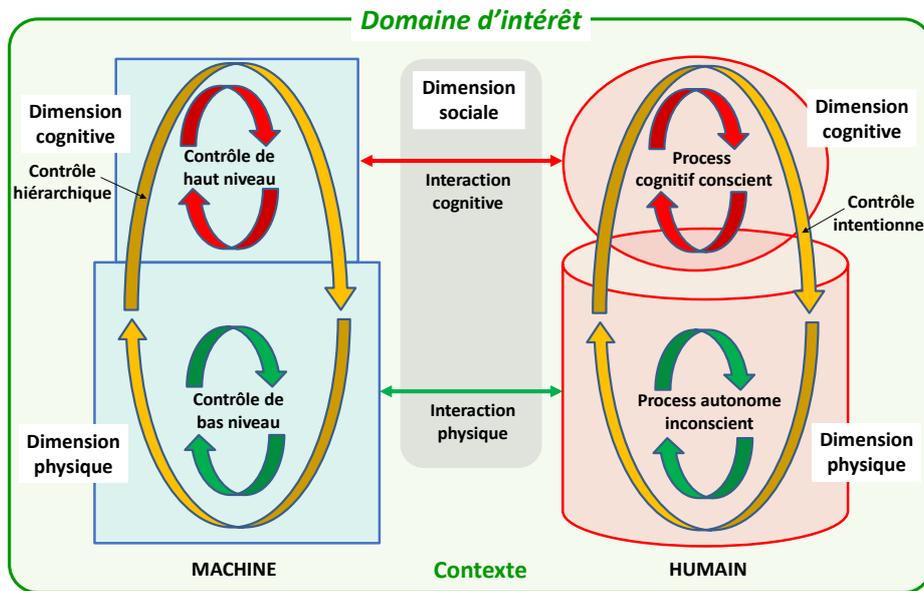


Figure III-3: Modèles génériques : Humain (à droite) et machine (à gauche)

Faisant suite au modèle proposé pour représenter les machines et les Humains, la problématique du choix entre l'Humain ou la machine pour exécuter une tâche est abordée dans la section suivante.

## II-2/ Modèles associés à la tâche

La tâche est vue ici au sens d'activité associée à une fonction primaire ou secondaire. Une tâche doit être partagée (pour l'exécution) entre Humain(s) et/ou machine(s) en tenant compte des forces, habiletés et des faiblesses de chacun d'entre eux. La caractérisation d'une tâche repose sur différents modèles couramment utilisés dans la littérature dans le domaine de la coopération Humain-Machine. Deux premiers modèles, les modèles SRK (Skill, Rule, Knowledge) (Rasmussen 1983) et DIK (Data, Information, Knowledge) (Targowski 2005), permettent de caractériser respectivement les niveaux cognitifs du processus décisionnel et la nature des éléments informationnels concernés. Ils aident à considérer la complexité de la tâche (en termes de capacités, de performances, d'erreur...) entre l'Humain et la machine. Complémentaire à SRK et DIK, un troisième modèle AADA (Acquisition, Analys, Décision et Action) (Parasuraman, Sheridan, and Wickens 2000) décompose la boucle générique perception-cognition-action en classes et décrit le partage des tâches entre l'Humain et la machine.

Ces modèles sont considérés comme des références dans la littérature et reposent sur une vision de l'Humain (et par extension de la machine) en termes de perception, de cognition et d'action. Ils sont génériques et utilisés dans de nombreux cas applicatifs. L'articulation de ces modèles dans notre architecture est décrite par la Figure III-4.

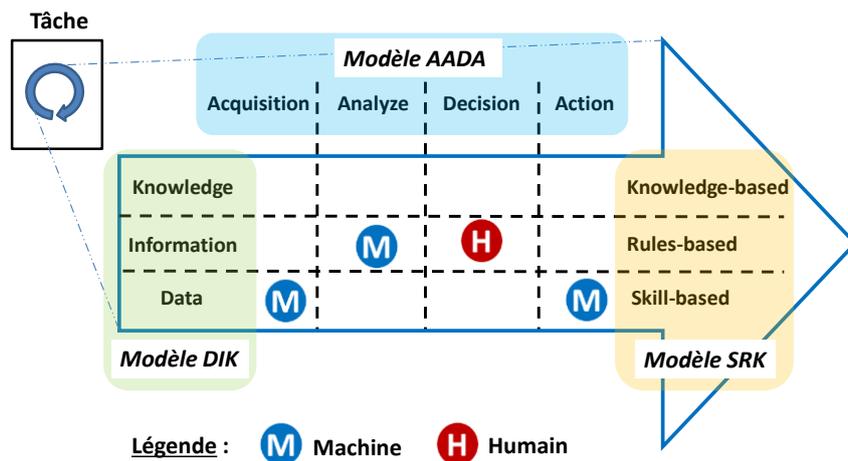


Figure III-4: Articulation des trois modèles DIK, SRK et AADA

Les sections suivantes détaillent successivement les trois modèles précédents.

### II-2-1/ Le modèle SRK

Une vue simplifiée du modèle SRK de Rasmussen est présentée Figure III-5. Elle fait apparaître trois niveaux comportementaux correspondants chacun à un niveau de complexité cognitive.

- A un niveau inférieur, correspondant au comportement « Skill-based », l'activité est instinctive et implique directement le système sensori-moteur (dans le cas d'un humain). Ce niveau traite un élément informatif de type « Signal » qui correspond à une manifestation d'un phénomène physique directement traité de façon instinctive. Le traitement associé est de type réflexe inné ou résultant d'une phase d'entraînement généralement longue.

Pour un système cognitif artificiel (i.e. une machine), cette activité correspond à un comportement purement réactif. Par exemple, si un signal dépasse un seuil fixé, cela déclenche automatiquement la génération d'une alarme. Dans la suite du mémoire, ce niveau sera donc appelé « Reactive-based ».

- Au niveau intermédiaire, correspondant au comportement « Rule-based », l'activité est procédurale, basée sur des règles apprises associées à des situations familières. Les éléments informatifs traités sur ce niveau sont de type « Signs » (i.e. Signes). Ils correspondent à une interprétation des signaux dans une situation. Par exemple, dans une tâche de conduite d'un véhicule, la couleur rouge sur un feu tricolore induira la nécessité de s'arrêter. Le lien entre le signe et l'action résulte d'un « appariement » appris. A ce niveau après reconnaissance d'un signe, une procédure est associée, déclenchée puis exécutée. Un algorithme, comme une recette, peut généralement décrire le comportement. Que ce soit pour l'Humain ou la Machine, un traitement procédural avec un ensemble d'étapes clairement définies est réalisé.

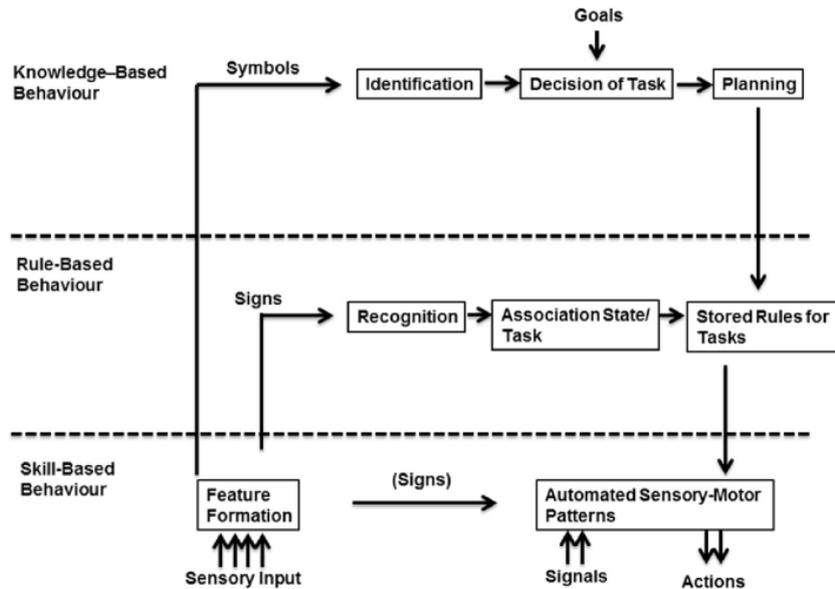


Figure III-5: Modèle de Rasmussen simplifié (Waterson, Le Coze, and Andersen 2017)

- A un niveau supérieur, correspondant au comportement « Knowledge-based », les éléments informationnels traités sont typiquement des « Symboles ». Ils ont un sens et correspondent à des éléments de connaissance. Ils offrent une interprétation conceptuelle détaillée des signaux, des signes et des relations entre eux aidant à comprendre une situation. Une fois la situation comprise, compte tenu d'un objectif à atteindre, un plan d'action peut par exemple être créé de toutes pièces puis mis en action.

## II-2-2/ Le modèle DIK

Le modèle DIK permet de compléter le précédent modèle SRK en décrivant la sémantique des éléments informationnels. Inspiré de la hiérarchie DIKW (Targowski 2005), le modèle DIK distingue les éléments suivants :

- D (pour Data) sont des faits bruts issus du système « cible » et de son contexte (par exemple, pression extérieure du contexte, température associée à une composante du système « cible »...).
- I (pour Information) sont obtenues en ajoutant des détails informationnels aux données (D) comme "quand", "où", "qui", "comment", "quoi" (par exemple, conducteur (qui), à un endroit précis de son itinéraire (où) à un moment précis (quand)). Cette activité d'ajout de détails est souvent connue sous le terme de marquage (i.e. « Tagging ») des données.
- K (pour Knowledge) peuvent être vu comme des groupes d'informations (I) liés par des relations sémantiques (ex. véhicule V<sub>10</sub> conduit par le conducteur C<sub>12</sub> dans un contexte opérationnel où la température extérieure de l'environnement est de 35° C). Cette « sémantification » des informations fait souvent appel à des ontologies (Hitzler and Parsia 2009). L'intérêt d'une ontologie, qui représente formellement des connaissances, est de permettre à une machine (i.e. ordinateur) d'explorer et d'exploiter, cette connaissance qui toutefois conserve du sens et reste compréhensible pour l'humain.

En établissant un parallèle avec le modèle SRK présenté précédemment, on note une cohérence et similitude très forte entre « signal » / « data », « sign » / « information », et

« symbol » / « knowledge » (Das 2008). En effet, le modèle DIK apporte un éclaircissement sur la nature des éléments informationnels, et le modèle de Rasmussen sur la nature des traitements qui leurs sont associés.

### **II-2-3/ Le modèle AADA**

Le modèle AADA vise à représenter et ainsi permettre d'étudier le partage de l'exécution des tâches entre un Humain et une machine. Il considère quatre grandes classes de fonctions : l'Acquisition d'informations, l'Analyse d'informations, la Décision et l'Action. Dans ce modèle AADA, le choix entre l'Humain et la machine (avec une politique statique ou dynamique) peut se faire, par exemple, sur la base des capacités, de l'efficacité, du risque, de la fiabilité, de la sécurité, du coût... Dans une perspective de conception, l'inconvénient est que L'humain doit faire tout ce qu'une machine est incapable de faire. L'humain est confronté à « l'ironie de l'automatisation » (Strauch 2018) et devient malgré lui le « solutionneur magique » (Damien Trentesaux and Millot 2016) afin de prendre en charge des situations très difficiles. Ceci, à long terme, n'est évidemment pas tolérable pour l'Humain dans le système.

Ces trois modèles (SRK, DIK et AADA) ne donnent pas de solution directe mais doivent être considérés comme un cadre directeur, qui partitionne l'espace du problème et en donne une vision globale. Cette dernière évite une vision trop limitée du problème et permet d'éviter ce qui a été identifié comme la « rationalité limitée » (Gigerenzer and Selten 2002) dans laquelle la première solution potentielle est adoptée avec peu de rationalité.

Dans ce qui suit, nous nous intéresseront principalement aux interactions cognitives entre l'Humain et la machine dans le cadre de processus décisionnels.

## **III/ Modélisation générique des processus décisionnels et de l'assistance associée**

Après avoir présenté dans la section précédente, un modèle générique Humain-machine, nous proposons un modèle des processus décisionnels associés aux tâches secondaires. En préambule à la modélisation, certaines hypothèses sont établies :

- 1- Le système « cible », est décomposable en un ensemble de sous-systèmes « cible » eux-mêmes (le cas échéant) décomposables. La Figure III-6 donne un exemple de décomposition d'un système  $S_1$ .
- 2- Chaque sous-système (du système « cible ») est immergé dans un contexte qui lui est propre.
- 3- Les fonctions secondaires, associées à chaque sous-système, sont sur le plan informationnel et décisionnel, autonomes et peuvent être coopératives.

Conformément aux sections précédentes, les notations suivantes sont également introduites :

- $S_i$  :  $i^{\text{ème}}$  système « cible » ;
- $C_i$  : contexte associé au système  $S_i$  ;
- $Fp_i$  : ensemble de toutes les fonctions primaires associées au système  $S_i$  ;
- $Fs_i$  : ensemble de toutes les fonctions secondaires associées au système  $S_i$  ;
- $fs_i^n$  : nième fonction secondaire associée au système  $S_i$ .

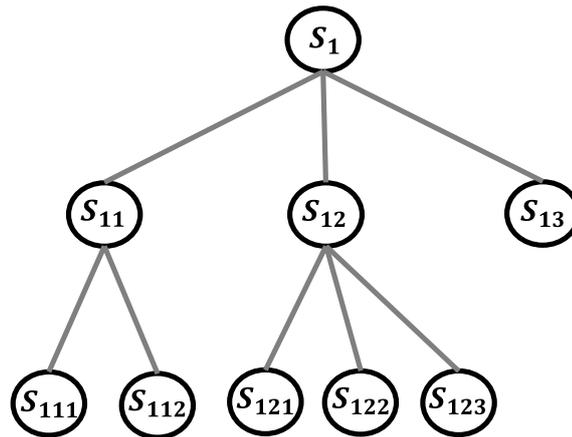


Figure III-6: Illustration de la décomposition d'un système  $S_1$  en sous-systèmes

### III-1/ Architecture holonique du système

Pour répondre à la première exigence (Exig. #1) présentée en début de chapitre, le choix d'une architecture holonique a été fait afin de permettre la représentation d'une décomposition et d'encapsuler les activités associées aux fonctions secondaires.

#### III-1-1/ Principes de base de la modélisation holonique

Le paradigme de modélisation holonique a été initialement introduit par (Koestler 1970). Ce paradigme a été largement utilisé et éprouvé dans les différents travaux de recherche du LAMIH que ce soit dans le cadre du pilotage que dans le cadre de la surveillance et du diagnostic de systèmes complexes (Le Mortellec et al. 2013). Dans le cadre de ces derniers travaux, un système holonique a permis de représenter récursivement la relation « partie réalisant la surveillance et le diagnostic » versus « partie surveillée ».

L'intérêt de ce paradigme repose notamment sur les caractéristiques suivantes (Christensen 1994) :

- Récursivité : un holon peut être composé d'autres holons,
- Autonomie : un holon a la capacité à mener un processus décisionnel en autonomie,
- Coopération : si nécessaire, un groupe de holons peuvent coopérer et exécuter des plans en commun.

Un ensemble d'holons peuvent être amenés à coopérer pour atteindre un objectif dans le cadre d'une holarchie régissant leur coopération. Pour un niveau donné d'une holarchie, un holon est constitué de deux parties : la première partie (la tête) agissant sur une seconde partie (le corps).

Comme indiqué dans la deuxième hypothèse, chaque système ou sous-système possède son propre contexte. A chaque sous-système et à son contexte est associé un ensemble de fonctions secondaires. La Figure III-7 illustre le cas d'un système  $S_i$  non décomposable et de l'ensemble des fonctions secondaires  $FS_i$  associées. Ces dernières se situent dans la partie « tête » du holon  $H_i$ . Le système  $S_i$  et son contexte  $C_i$  se situent dans la partie « corps » du holon  $H_i$ .

Comme illustré sur l'exemple de la Figure III-8, pour une fonction secondaire spécifique  $fs_i^n$  à chaque niveau de l'holarchie, un triplet  $(fs_i^n, S_i, C_i)$  est associé à chaque holon  $H_i$ . A chaque niveau  $i$ , un holon supporte de manière autonome un processus décisionnel relatif à la fonction secondaire considérée. De plus, le holon interagit avec d'autres holons au même niveau et (le

cas échéant) avec des holons situés dans les niveaux  $i+1$  et  $i-1$ , à travers un espace de collaboration dans lequel des informations sont échangées. Par exemple, dans le cadre d'une application de surveillance / diagnostic, un holon ayant détecté un problème sur le sous-système qu'il surveille peut interagir avec les autres holons situés au même niveau. Si ces derniers holons détectent le même problème sur leurs sous-systèmes respectifs, la cause du problème n'est très certainement pas due au sous-système mais est liée au contexte.

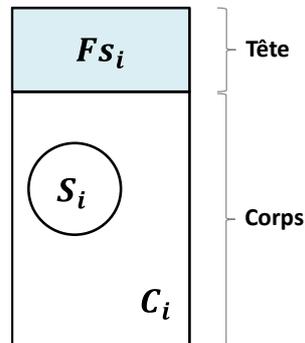


Figure III-7: Illustration d'un holon  $H_i$  pour un système  $S_i$  non décomposable

Un exemple de modélisation, repris dans un cas d'étude au chapitre V, est détaillé dans la prochaine section.

### III-1-2/ Exemple d'architecture pour la surveillance et le diagnostic dans le domaine ferroviaire :

La Figure III-8 décrit l'exemple de l'architecture holonique associée à un système de transport complexe telle qu'une rame de train « Voyageurs » pour une fonction secondaire de surveillance et diagnostic. Dans cet exemple, trois niveaux de décomposition sont considérés : le train, le véhicule et l'équipement terminal (exemple : porte d'accès voyageurs). Les données sont collectées à chaque niveau de la holarchie et sont utilisées pour le diagnostic :

Niveau « Porte » : À ce niveau inférieur de la holarchie (par exemple,  $S_{111}$  sur la Figure III-8), plusieurs sources de données sont collectées :

- Sur le système (i.e. la porte) : le courant absorbé par le moteur actionnant la porte.
- Sur le contexte : Pour chaque porte, trois sources de données sont distinguées :
  - o Les utilisateurs, c'est-à-dire les passagers du train qui appuient sur le bouton pour ouvrir la porte, restent partiellement inconnus (i.e. pas d'identification du passager qui a déclenché l'ouverture de la porte). Toutefois, certaines données sont collectées à l'aide de capteurs dédiés, comme le nombre de passagers en entrée et en sortie et le poids des passagers devant la porte. Ce dernier point est important car le poids des passagers déforme le plancher devant les portes et peut influencer sur la durée d'ouverture ou de fermeture et sur la consommation électrique.
  - o L'environnement est connu grâce à des données (par exemple, température externe, hygrométrie) mesurées au niveau du train.
  - o La tâche concerne le cycle d'actionnement d'une porte (par exemple,  $S_{111}$ ). Elle est caractérisée par les durées d'ouverture et de fermeture ainsi que par le courant électrique absorbé par le moteur de la porte pour chaque action.

Niveau « Véhicule » : À ce niveau intermédiaire, certaines données relatives au contexte (par exemple,  $C_{11}$ ) sont considérées, telles que par exemple le dévers de la voie ferrée. Cette caractéristique de l'infrastructure ferroviaire peut influencer sur les temps d'ouverture et de fermeture des accès voyageurs en induisant des frottements mécaniques au niveau porte.

Niveau « Train » : À ce niveau supérieur, la localisation du train via les coordonnées GPS, les données sur l'infrastructure (par exemple, l'identification de la gare où se situe le train) et les données sur l'environnement (température externe, hygrométrie) sont collectées. Ces dernières données relatives à l'environnement sont mutualisées et disponibles à tous les niveaux de la holarchie.

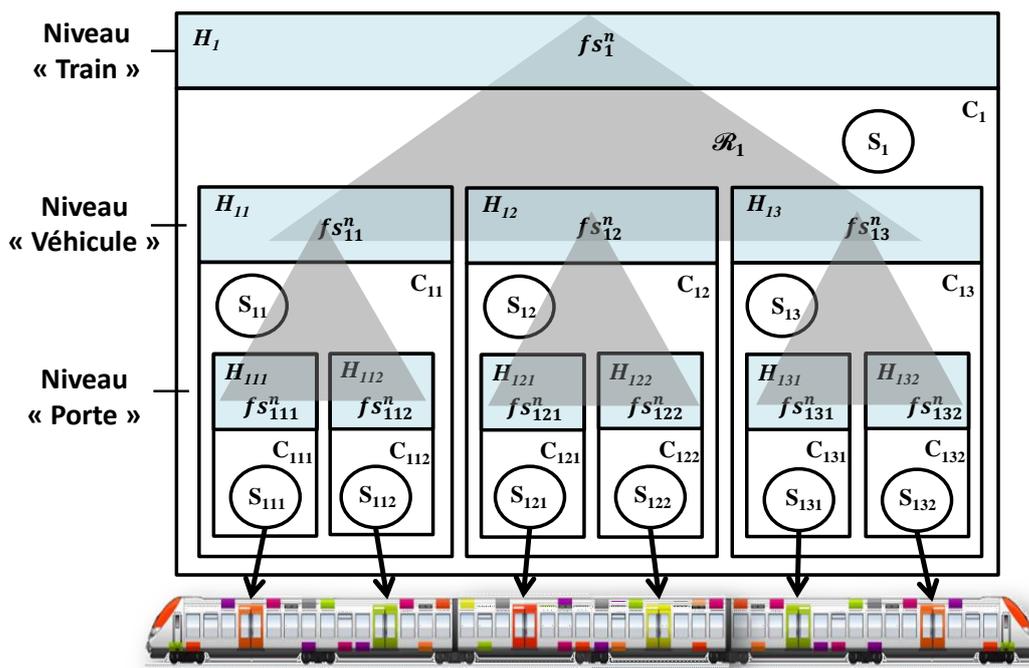


Figure III-8: Architecture holonique appliquée à un système ferroviaire

### III-2/ Modélisation de la boucle cybernétique associée à une fonction secondaire

Cette modélisation, dans le prolongement de précédents travaux (Basselot, Berger, and Salles 2019), met l'accent sur la coopération Humain-Machine au sein du processus décisionnel et plus particulièrement sur l'apport d'une assistance décisionnelle.

Classiquement chaque boucle cybernétique est constituée de deux parties :

- une partie « ascendante » constituée d'une chaîne informationnelle et décisionnelle reliant le système « cible » au stakeholder. Comme l'illustre la Figure III-9, pour chaque holon  $H_i$  de l'holarchie, une chaîne informationnelle et un processus décisionnel sont associés à la fonction secondaire  $fs_i^n \in FS_i$ . Ce processus décisionnel concerne des traitements (réalisés par la machine ou par l'Humain) se situant à différents niveaux de complexité cognitive et génère une sortie  $out_i^n$  à destination du stakeholder.
- une partie « descendante » relative à l'intervention déclenchée par le stakeholder sur le système « cible ».

Différentes sources d'informations sont exploitées par la partie « ascendante » :

- Une première source  $sta_i^n$  est relative à la structure informationnelle statique  $SIS_i$  associée au système  $S_i$ . Cette structure contient des éléments informationnels (données, informations et connaissances) statiques relatives au système. Elle rassemble tout un ensemble d'éléments servant de modèle de référence (par exemple, une description technique, des limites de fonctionnement, le niveau de compétence de l'utilisateur indispensable ainsi que la tâche prescrite pour utiliser le système...).
- Un sous-ensemble  $dyn_i^n$  de la structure informationnelle dynamique  $DIS_i$  associée au système  $S_i$ . Cette structure dynamique contient les données, informations et connaissances collectées sur le système ciblé et son contexte au cours des différentes instances d'utilisation. La collecte des éléments informationnels au sein de cette structure informationnelle permet de constituer un historique d'utilisation du système. Cet historique sera particulièrement précieux pour l'élaboration de l'assistance décisionnelle comme détaillé dans le prochain chapitre.
- Les flux informationnels résultant des échanges coopératifs entre les holons situés au même niveau ou aux niveaux immédiatement inférieur ou supérieur via les espaces collaboratifs  $\mathcal{R}_i$  et  $\mathcal{R}_j$ .

En cohérence avec les concepts présentés dans la section II dans le cadre d'un Système Humain-Cyber-Physique :

- Les structures informationnelles statiques et dynamiques sont basées sur le modèle DIK (Data / Information / Knowledge).
- Les différents niveaux cognitifs considérés au niveau du processus décisionnel sont ceux du modèle SRK (Skill-Reactive based / Rules based/ Knowledge based) proposé par Rasmussen.
- Au niveau du processus décisionnel, le partage de tâche entre l'Humain (i.e. l'expert du sous-système concerné) et la machine (i.e. l'assistance décisionnelle apportée) repose sur le modèle AADA.

Les sections suivantes détaillent la place de cette assistance décisionnelle au sein du processus décisionnel au travers de plusieurs exemples applicatifs.

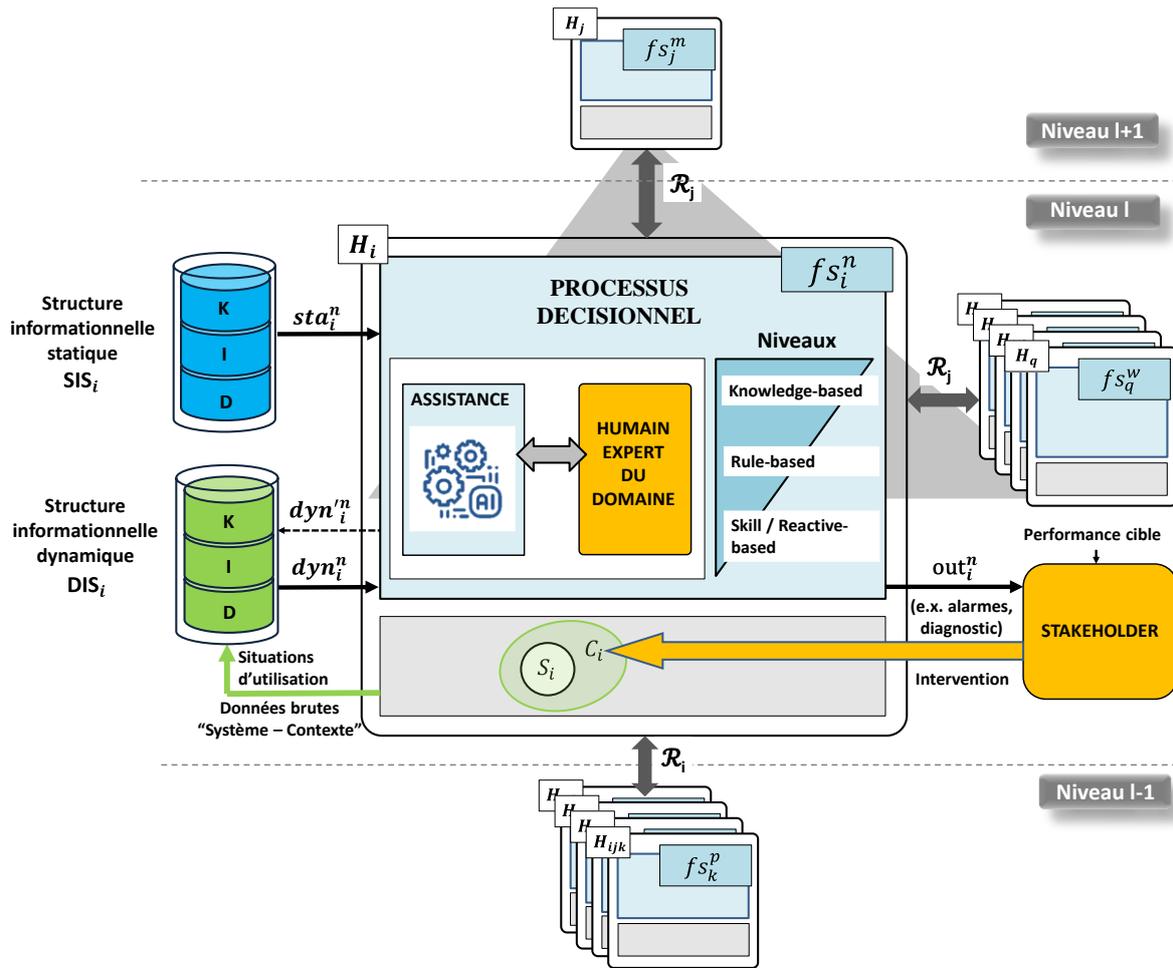


Figure III-9: Modèle de la boucle cybernétique associée à un holon  $H_i$

### III-3/ La place de l'assistance dans le processus décisionnel

Comme explicité dans les chapitres précédents, le rôle de l'assistance décisionnelle utilisant des approches « Data Analytics » et Machine Learning est d'apporter une aide à la décision selon différentes facettes : descriptive, diagnostic, prédictive ou prescriptive. Cette assistance vise à faciliter la tâche du stakeholder via un enrichissement des structures informationnelles.

Deux phases principales peuvent être distinguées au niveau de l'assistance comme le montre la Figure III-10 ci-après :

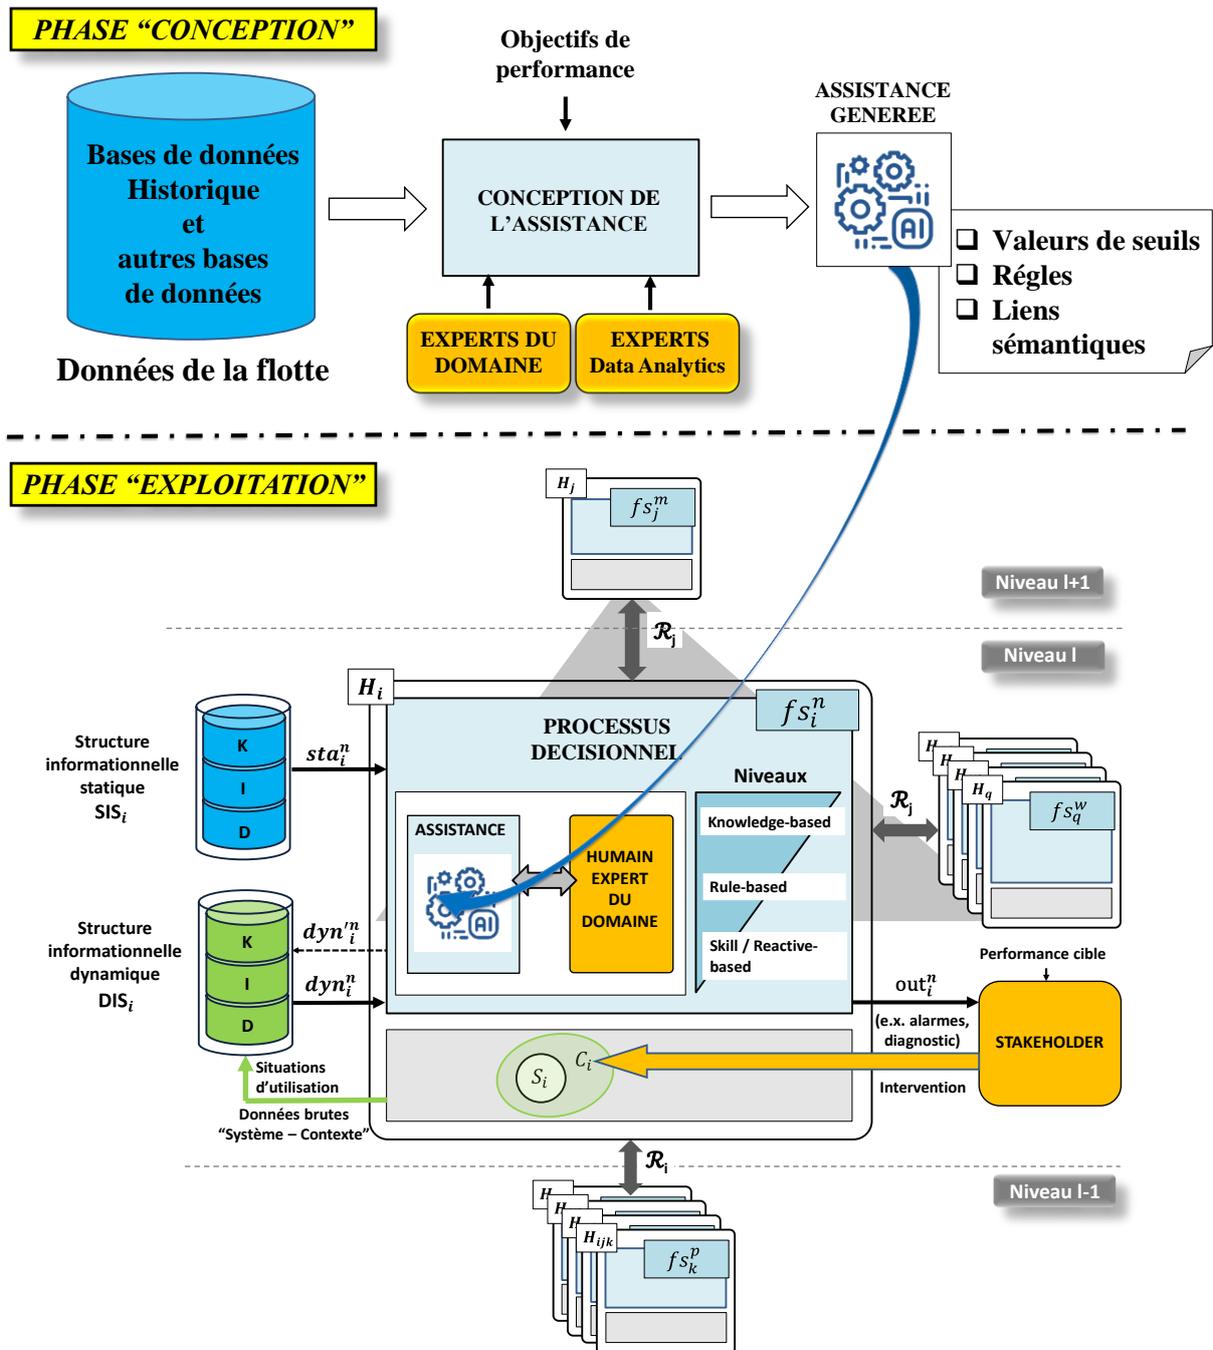


Figure III-10: Illustration des phases de conception et d'exploitation de l'assistance

1. Une phase de conception : En exploitant principalement les structures informationnelles statiques SIS et l'historique des données dynamiques DIS (issues du système « cible » ou d'une flotte de systèmes équivalents), une assistance décisionnelle est conçue de façon à générer les différents éléments (ex : seuils, règles et liens sémantiques) qui seront utilisés par la partie du processus décisionnel menant à une décision :
  - Au niveau « reactive-based » : le processus décisionnel est relativement basique et exhibe un comportement purement réactif. L'assistance peut alors se concrétiser par la simple détermination d'un seuil (ex : détermination d'une fréquence de remplacement des pneumatiques pour un véhicule routier) jusqu'à l'élaboration d'une assistance plus élaborée capable d'analyser une situation et de générer une alarme. Par exemple un réseau de neurones embarqué dans un véhicule autonome

peut être capable de détecter un problème de comportement au niveau des passagers (e.g. agression) et alerter le stakeholder exploitant le véhicule.

- Au niveau « rule-based » : le processus décisionnel repose sur l'exploitation de règles. L'assistance se concrétise alors par la génération d'un ensemble de règles de type « si-alors » placées dans un ordre spécifique.
- Au niveau « knowledge-based » : le processus décisionnel exploite les connaissances (par exemple, les relations entre le comportement du système et son contexte) pour améliorer la compréhension de situations complexes. Par exemple, une analyse détaillée du contexte pour plusieurs instances d'utilisation du système « cible » peut conduire à la mise en évidence de certaines corrélations entre éléments informationnels (ex : un poids excessif de fret et l'apparition d'une usure prématurée des pneumatiques). Dans ce cadre, l'assistance se traduira par la mise en évidence de liens sémantiques entre les différentes entités constituant l'écosystème du système « cible ». Ces liens sémantiques pourront alors être intégrés au sein d'une ontologie.

2. Une phase d'exploitation : Comme indiqué à la Figure III-10, l'assistance exploite les éléments informationnels à sa disposition (structure informationnelle statique SIS, structure informationnelle dynamique DIS et échanges entre holons au sein de l'espace collaboratif). Selon le niveau cognitif considéré, ces données sont comparées à des seuils, ou permettent de valuer un ensemble de règles ou de liens sémantiques de façon à prendre une décision. Cette dernière pourra être prise de manière entièrement automatique (i.e. sans intervention de l'expert) ou en relation avec l'expert. Dans ce cas, les éléments informatifs (ex : valuations des liens sémantiques entre entités) devront être présentés à l'expert de la manière la plus compréhensible possible.

Le partage des rôles pour les différentes phases (acquisition, analyse, décision et action) entre l'Humain (i.e. l'expert ou le stakeholder) et la Machine (i.e. l'assistance décisionnelle) sera décrit à l'aide du modèle AADA.

Des exemples sont donnés ci-après afin d'illustrer l'utilisation d'une assistance décisionnelle dans un contexte de maintenance de véhicules ferroviaires.

### **III-4/ Exemples illustratifs**

Cette section illustre l'application des concepts présentés précédemment à des travaux passés ou en cours au LAMIH en coopération avec un constructeur ferroviaire.

#### **III-4-1/ Exemple n°1 : Assistance de type « reactive-based »**

Ce premier exemple est relatif à des travaux en cours actuellement au sein du laboratoire. Ces travaux visent à développer une approche « intelligente » permettant de détecter des défauts ou des dégradations au niveau de certains équipements des véhicules (Voir Figure III-11).

Phase de conception : Une banque d'images, contenant des images d'équipements en bon état et d'équipements dégradés sont utilisés par un algorithme de Machine Learning pour générer l'assistance. Cette dernière prend la forme d'un module logiciel exhibant un comportement réactif, capable de détecter une situation anormale.

Phase d'exploitation : Comme explicité à la Figure III-12, en se référant au modèle AADA, les phases (i.e. Acquisition, Analyse, et Décision) sont prises en charge par une « machine » :

- L'acquisition se fait automatiquement au moyen des caméras vidéo embarquées dans les véhicules.
- L'analyse des images est effectuée en utilisant le module logiciel préalablement conçu et exploitant le flux vidéo issus des caméras. Ce module est capable d'identifier des dégradations apparentes sur les équipements observés.
- La décision, de type « reactive based », est prise par le module automatiquement dès qu'une dégradation est détectée, sans intervention humaine. Une alarme est alors envoyée au stakeholder (ex : le responsable maintenance de l'exploitant ferroviaire)
- L'Action est confiée au stakeholder qui planifie une intervention de maintenance pour réparer l'équipement dégradé.

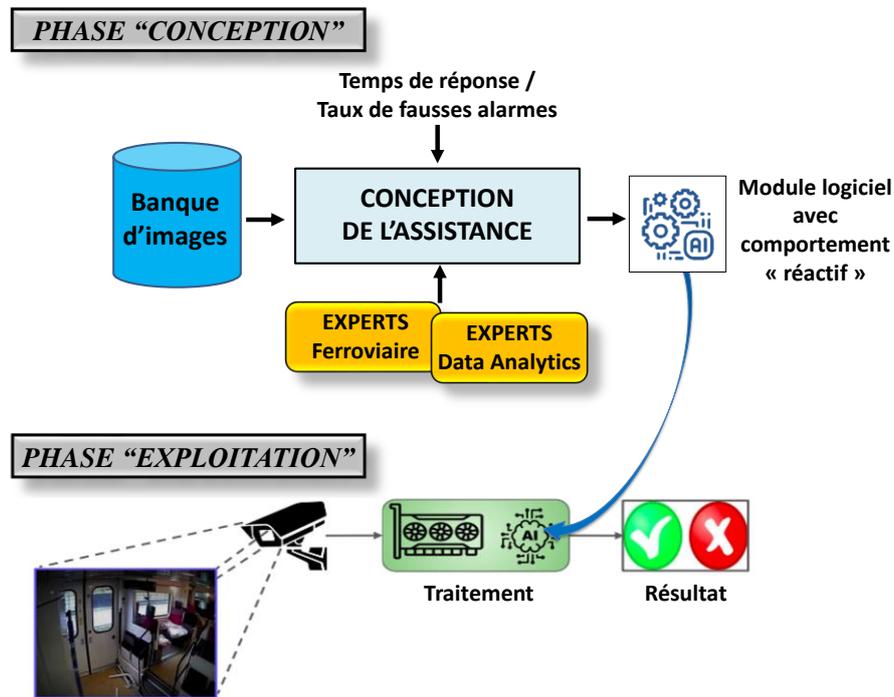


Figure III-11: Détection de défauts par vision embarquée

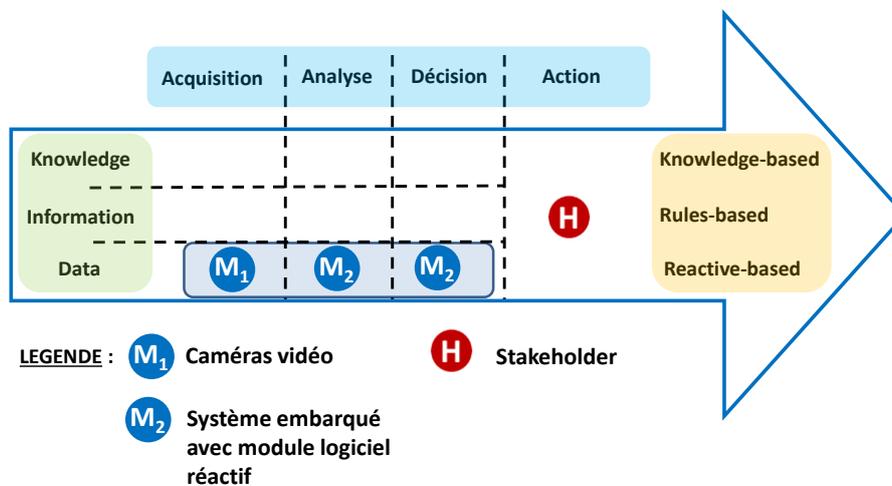


Figure III-12: Modèle AADA relatif à l'exemple n°1

### III-4-2/ Exemple n°2 : Assistance de type « Rule-based »

Ce deuxième exemple est inspiré des travaux de (Le Mortellec 2013) réalisés dans le cadre du projet FUI Surfer de 2010 à 2014 en partenariat avec la société Bombardier Transport. L'objectif de ces travaux était de développer une architecture de diagnostic embarquée.

Comme illustré à la Figure III-13, une architecture holonique de diagnostic a été conçue en exploitant l'holarchie à trois niveaux (i.e. porte, véhicule, train) de la figure 3-8. A chaque niveau de l'holarchie, une fonction  $f_{S_i}$  (notation contractée dans le cas d'une seule fonction) réalise la surveillance et le diagnostic du sous-système considéré. A un niveau  $i$ , la fonction  $f_{S_i}$  tient également compte du contexte local  $C_i$  pour inhiber (ou pas) un diagnostic remonté par des holons de niveau inférieur. Par exemple, un problème d'une ouverture de porte plus longue que d'habitude, détectée au niveau inférieur « portes », pourra être « inhibé » par le contexte du véhicule (au niveau intermédiaire « Véhicule »). En effet, un véhicule positionné sur un tronçon de voie avec un fort dévers, induira des frottements qui nuiront au bon fonctionnement de la porte. Cette approche par inhibition permet de réduire le nombre de fausses alarmes.

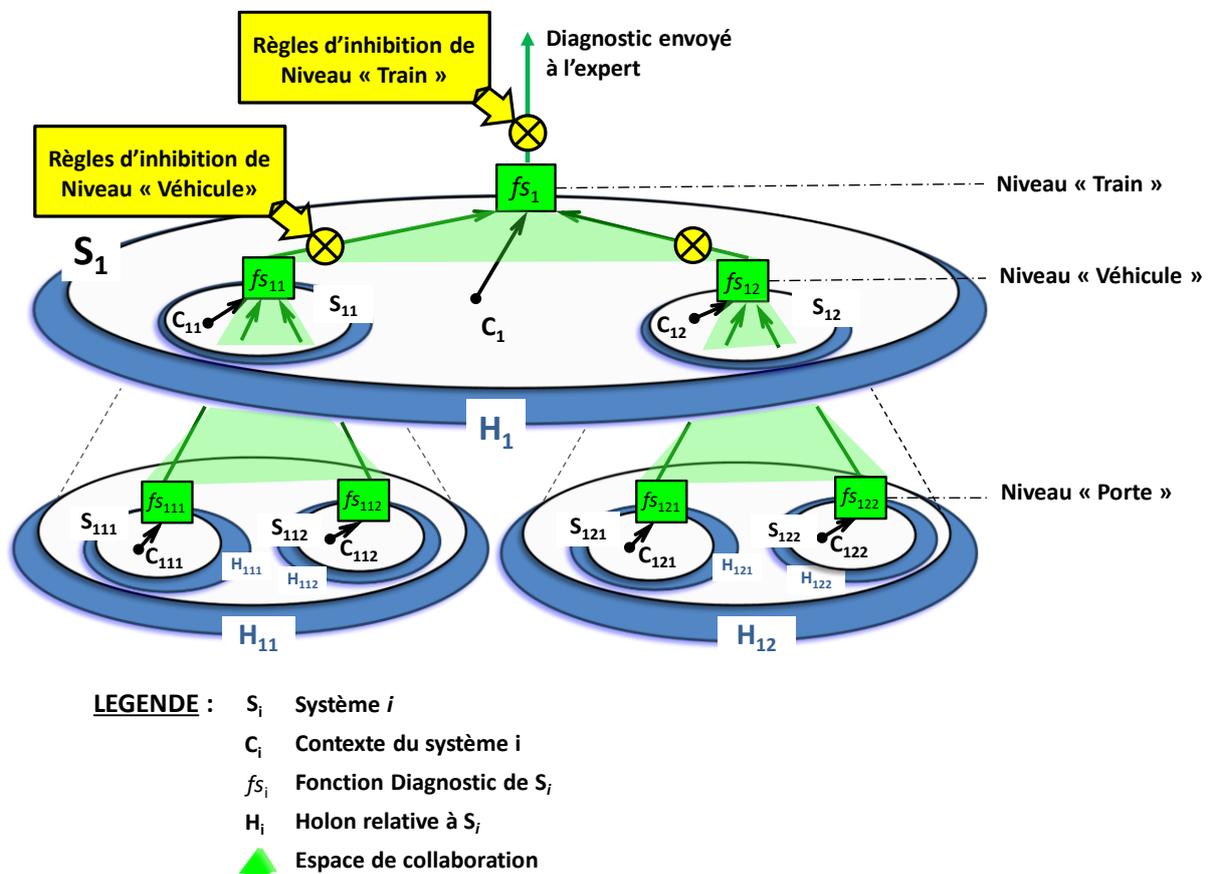


Figure III-13: Approche holonique de surveillance / diagnostic

Phase de conception : Comme décrit à la Figure III-14, en exploitant l'historique des défaillances au niveau des portes, et avec l'aide d'experts du ferroviaire, un ensemble de règles d'inhibition sont générées. Par exemple, une inclinaison du véhicule ou un passage du train dans un tunnel peuvent entraîner l'inhibition de certains diagnostics. Par exemple, un retard d'ouverture au niveau d'une porte (accès voyageurs) pourra être « inhibé » par le contexte du véhicule. En effet, un véhicule positionné sur un tronçon de voie avec un fort dévers, induira des frottements qui nuiront au fonctionnement normal de la porte.

De plus amples explications sur cette approche de filtrage des fausses alarmes par inhibition sont disponibles dans (Le Mortellec 2013).

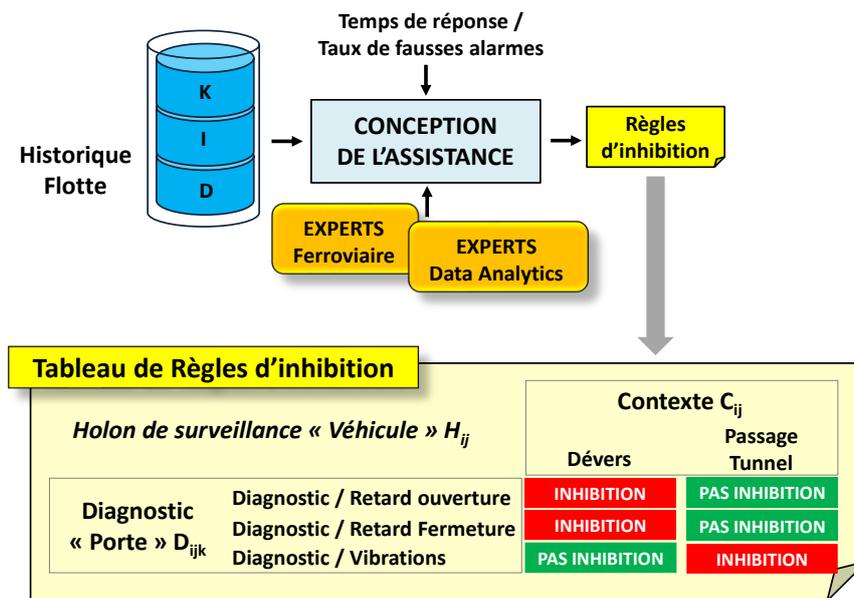


Figure III-14: Génération des règles d'inhibition (d'après (Le Mortellec 2013))

Phase d'exploitation : En considérant le modèle AADA, les deux premières phases sont entièrement prises en charge par une « machine » (voir la Figure III-15) :

- La partie Acquisition est assurée par la remontée des données mesurées au niveau des systèmes au travers du réseau embarqué du train
- Comme illustré à la Figure III-13, au niveau inférieur de l'holarchie, la partie Analyse est supportée par un holon qui établit un premier diagnostic (i.e. liste de composants suspects) à base d'un modèle du système surveillé (ici une porte). Le diagnostic délivré par cette méthode est ensuite transmis aux niveaux supérieurs de l'holarchie où une contextualisation sera réalisée.
- La décision d'envoyer ou non l'alarme (ainsi que le diagnostic établi) se prend en tenant compte des contextes à différents niveaux de l'holarchie. Cette décision, de type « Rule-based » repose sur l'exploitation des règles générées lors de la phase de conception. Comme explicité à la Figure III-15, la décision peut être implémentée de façon entièrement automatique (i.e. la machine applique les règles et remonte le diagnostic directement au stakeholder (ex : responsable maintenance) ou de façon mixte (i.e. le diagnostic généré est envoyé à un expert du système concerné qui valide ou non l'envoi au stakeholder). L'intervention de l'expert peut être considérée comme un filtre d'inhibition supplémentaire.
- La partie « Action » est confiée au stakeholder qui gèrera l'intervention de maintenance sur la porte.

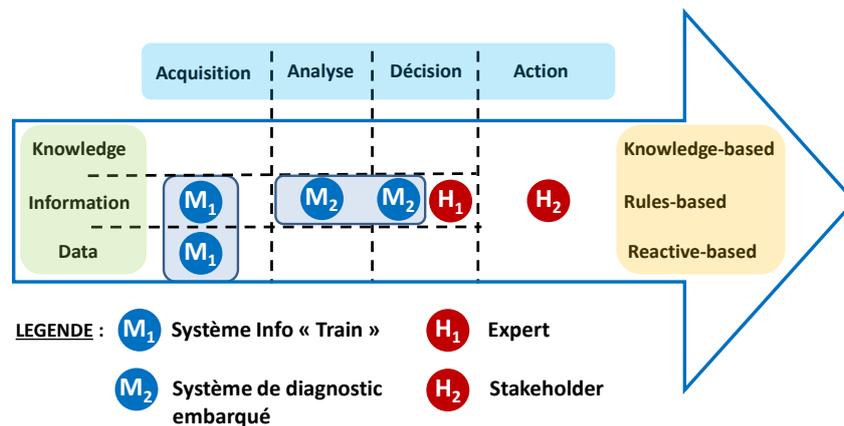


Figure III-15: Modèle AADA relatif à l'exemple n°2

### III-4-3/ Exemple n°3 : Assistance de type « Knowledge based »

Ce dernier exemple est issu de précédents travaux portant sur le développement d'une ontologie permettant de contextualiser les mesures, faites sur un système « cible » (ici une porte d'accès voyageurs). Les éléments de connaissances obtenus permettent de comprendre puis, si possible, d'expliquer ce qui peut être observé (i.e. la situation) de façon à élaborer un diagnostic.

Phase de conception : Comme illustré à la Figure III-16, à partir de l'historique d'utilisation des différents trains constituant la flotte, les experts ferroviaires, aidés de spécialiste du Data Analytics, mettent en évidence des relations qui semblent exister entre éléments d'information. Ces relations peuvent ensuite donner lieu à la création de liens sémantiques au sein d'une ontologie relative à l'utilisation des portes. Une ontologie est considérée comme une spécification explicite d'une conceptualisation (Gruber 1993). Les situations résultant de l'utilisation du système sont alors vues comme des cas, permettant de construire une base de connaissance (Noy and McGuinness 2001). L'ontologie, autorisant une représentation des connaissances, permet à une machine (i.e. ordinateur) d'explorer et d'exploiter, cette connaissance tout en restant compréhensible pour l'humain.

Phase d'exploitation :

- Relativement au modèle AADA, seule la première phase d'acquisition est réalisée automatiquement. Les différentes mesures, collectées directement sur la porte et d'autres collectées au niveau du train et liées au contexte, sont d'abord transformées en informations suivant un processus de contextualisation (voir Figure III-17). Toutes les données et informations sont stockées dans une base de données InfluxDB ("InfluxData" 2023). Un processus de « sémantification » exploite ensuite ces données et informations et élabore un ensemble de connaissances en créant des liens entre ces informations au travers d'une ontologie adéquate. Ces connaissances sont stockées dans une base de connaissances AllegroGraph ("AllegroGraph" 2023).

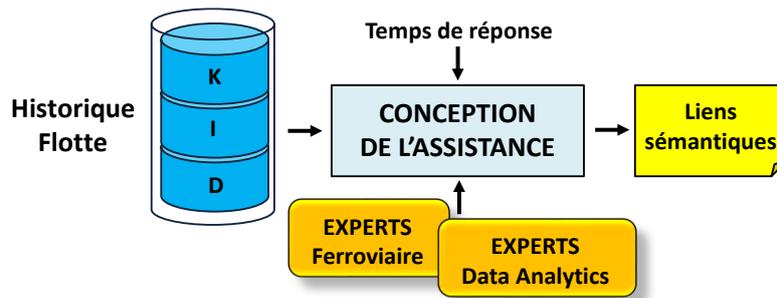


Figure III-16: Mise en évidence de liens sémantiques

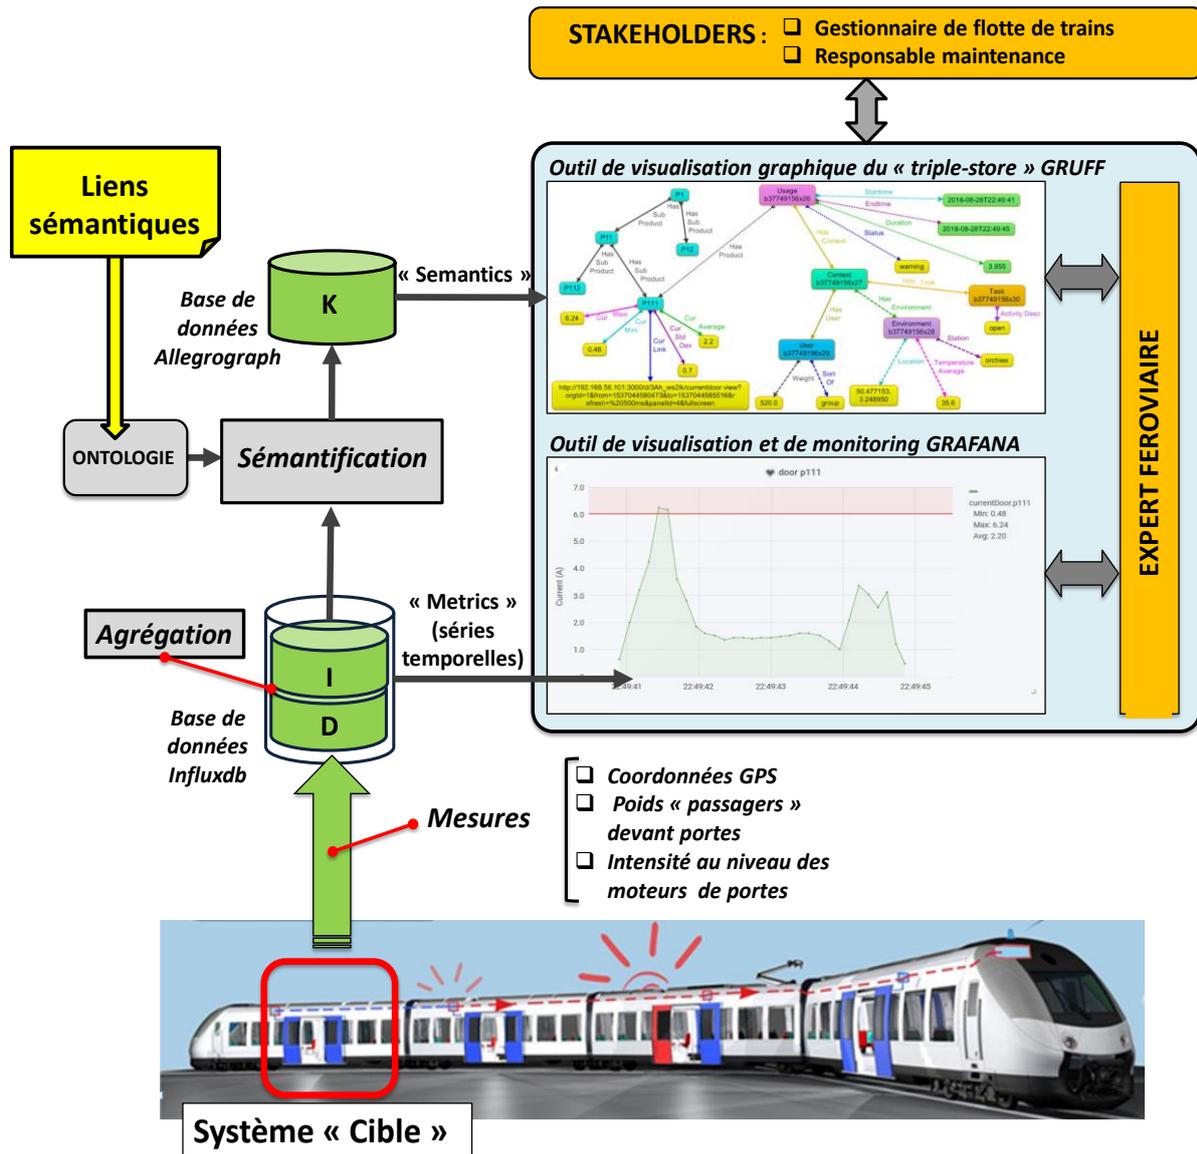


Figure III-17: Architecture de surveillance / diagnostic

- Comme décrit à la Figure III-18, les phases suivantes d'analyse et de décision sont confiées à un expert du ferroviaire. Ce dernier peut accéder à l'ontologie à l'aide d'outils de visualisation comme Gruff ("Gruff" 2023). L'expert a également à sa disposition les séries temporelles stockées dans InfluxDB et accessibles via l'outil de visualisation Grafana ("Grafana Labs" 2023). Par exemple, si un seuil maximum de courant est

dépassé sur un moteur de porte, il peut analyser la courbe de courant via Grafana et regarder les conditions de fonctionnement et le contexte via Gruff.

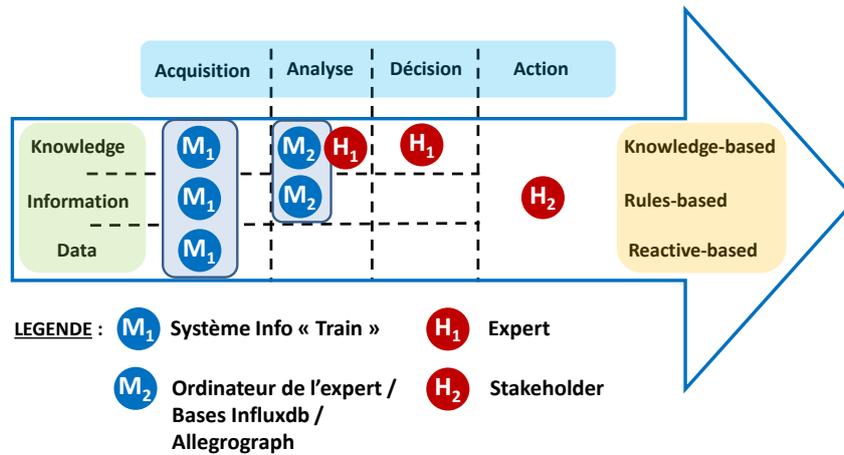


Figure III-18: Modèle AADA relatif à l'exemple n°3

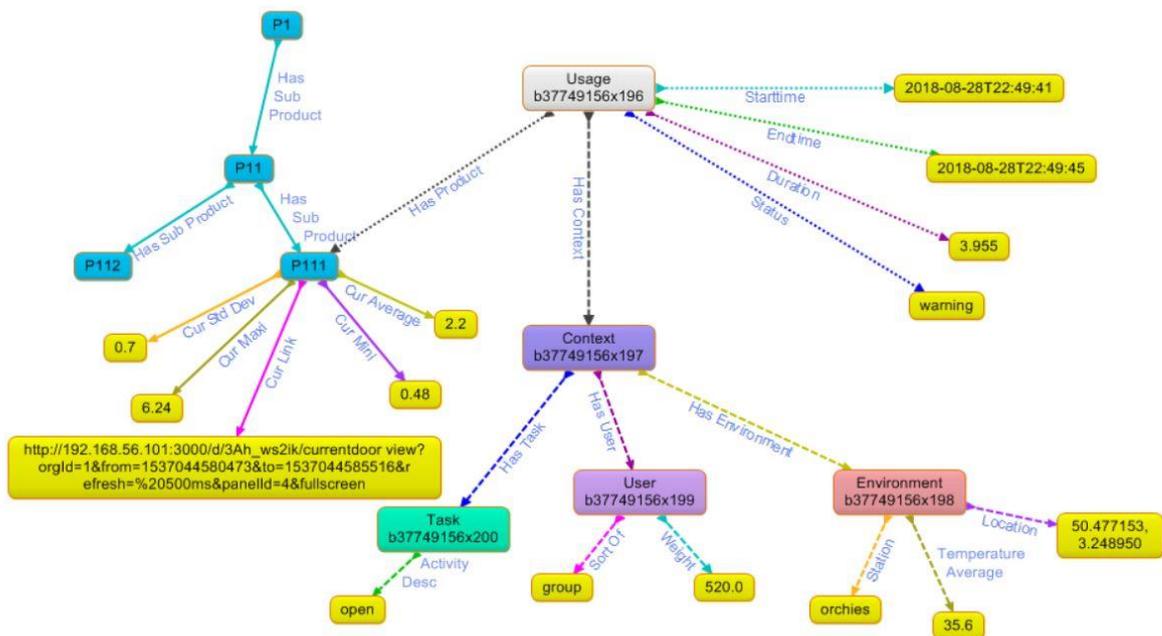


Figure III-19: Visualisation d'une instance de l'ontologie

Dans l'exemple de la Figure III-19, l'ampérage (min, max, moyen...) du courant moteur mesuré a été considéré (par un expert humain de référence) comme pertinent pour le fonctionnement de la porte. Le poids des passagers à proximité de la porte, la température extérieure et la localisation de la gare ont également été considérés comme pertinents au regard du contexte.

Au début de l'expertise, les faits étaient les suivants :

- Une alarme a été déclenchée par le système d'assistance embarqué relatif à la porte P<sub>111</sub>. Au moyen des données dynamiques dyn<sub>111</sub>, il a été possible de déterminer un courant supérieur à 6A (la limite théorique et prescrite stockée dans sta<sub>111</sub>).

- Le poids des passagers près de la porte, n'explique pas le problème car la valeur 520 kg n'est pas significative (i.e. inférieure à la valeur maximale 600 kg).
- La température extérieure et la localisation du train sur la voie ne donnent aucune explication à ce dépassement de seuil.

Cependant, après avoir affiché et analysé l'historique des informations de la courbe de courant de la porte et pris en compte la tâche (c'est-à-dire l'ouverture de la porte), l'expert suspecte un problème d'alignement mécanique sur la porte. L'expert propose alors au stakeholder une intervention de maintenance pour réaligner la porte.

- La dernière phase Action peut alors être prise en charge par le stakeholder.

La section suivante est dédiée à la proposition d'un guide méthodologique support.

## IV/ Guide méthodologique

D'un point de vue opérationnel, afin de mettre en application les propositions de ce chapitre, il est indispensable de détailler la partie « ascendante » de la boucle cybernétique reliant le système « cible » au(x) stakeholder(s). Cette analyse doit être menée dans le sens « stakeholder » vers système « cible » pour à partir des besoins exprimés, être en mesure de caractériser l'ensemble des données, informations et connaissances à obtenir sur le système « cible » et de spécifier l'assistance à développer. Contrairement aux approches trop souvent utilisées en Big data, où l'on stocke énormément de données sans trop savoir ce qu'en feront les stakeholders, nous privilégions une approche plus frugale dans laquelle les données à extraire sont déterminées par une analyse des besoins des stakeholders.

Le guide proposé s'appuie logiquement sur l'ensemble des modèles proposés dans les sections précédentes. Comme illustré à la Figure III-20, huit étapes sont distinguées :

Les trois premières étapes permettent d'identifier les systèmes « cibles » concernés, les stakeholders concernés et de préciser les besoins de ces derniers.

- **Etape 1 : identification du système et des sous-systèmes ciblés :** Cette première étape consiste à caractériser le système « cible » étudié et si besoin à le décomposer en un ensemble de sous-systèmes, conformément à l'approche holonique précédemment présentée. Dans le cas d'un système complexe, un graphe de décomposition du système en sous-systèmes doit être produit. Les fonctions primaires supportées par le produit sont également précisées.
- **Etape 2 : identification des stakeholders :** Cette identification des stakeholders se fait en recherchant qui doit prendre des décisions en lien direct avec une problématique associée au système « cible » ou à un/plusieurs de ses sous-systèmes.
- **Etape 3 : détermination des besoins pour chaque stakeholder :** Il s'agit ici de préciser le résultat ( $out_i^n$ ) attendu permettant au stakeholder de mener à bien son activité. L'obtention de ces besoins peut se faire, par exemple, par verbalisation en reprenant des approches issues du domaine de l'ergonomie et la psychologie (Courage and Baxter 2004) ou encore une approche basée sur l'ingénierie des exigences (Sutcliffe 2012).

Chaque besoin est associé à une boucle cybernétique en lien direct avec une fonction secondaire qui doit être détaillée.

Les étapes suivantes, qui vont de pair, doivent ensuite être menées pour chaque fonction secondaire considérée.

- **Etape 4 : identification de la catégorie associée à la boucle cybernétique** : On précise ici la problématique associée à la fonction secondaire considérée en caractérisant à quelle catégorie elle appartient (i.e. Surveillance, Amélioration, Evolution)
- **Etape 5 : caractérisation de l'activité décisionnelle** : Comme vu précédemment dans la section II, ce processus peut être caractérisé en s'aidant du modèle de Rasmussen, et en distinguant les niveaux cognitifs (i.e. « Reactive-based », « Rules-based » et « Knowledge-based »). Cette caractérisation fait appel à des experts du système (ex. experts du système « cible », experts des facteurs humains pour les aspects décisionnels) pour aider à rendre explicite le(s) processus décisionnel(s) au sein de la fonction secondaire et les flux informationnels associés.
- **Etape 6 : Caractérisation de l'assistance décisionnelle** : Il s'agit de définir ici le type d'assistance qui doit être développée (i.e. Prescriptif ; Prédicatif, Descriptif, Diagnostic).
- **Etape 7 : Caractérisation du partage d'activités Humain / Machine** : Ce partage est déterminé selon le modèle AADA entre l'Humain et la machine. Lors de cette étape, certains critères de performance de l'assistance décisionnelle doivent être définis (e.g. vitesse d'obtention d'un résultat, taux de confiance de ce résultat).
- **Etape 8 : Description des éléments informationnels** : Cette étape est cruciale car elle va déterminer les flux informationnels disponibles pour la prise de décision. Comme illustré à la Figure III-17, différents flux de données peuvent être distingués :
  - Les éléments informationnels dynamiques : Ces éléments collectés directement au niveau du système « cible » et de son contexte se doivent d'être suffisamment explicatifs pour appréhender l'entièreté du domaine d'intérêt du système. Si les éléments disponibles au niveau du système ne sont pas pertinents, il convient de réaliser des mesures supplémentaires sur le système ou son contexte. Il est alors nécessaire d'explicitier les mesures (précision, fréquence d'acquisition...) devant être réalisées sur le système et son contexte de telle sorte que des données pertinentes soient obtenues.
  - Les éléments informationnels statiques : De même que pour les éléments précédents, les éléments statiques doivent être définis. Comme vu précédemment, ces éléments sont constitués de valeurs, d'information de référence assez peu susceptible de changement.
  - Les flux informationnels au sein de la holararchie : On doit s'attacher ici à décrire les flux informationnels disponibles au sein de l'espace de partage de la fonction secondaire considérée. En cas de coopération entre fonctions secondaires identiques associées à des instances différentes d'un même type de système, identifier les éléments informatifs d'entrée (venant des autres fonctions) et ceux de sortie (vers ces autres fonctions).

La description de ces différents flux informationnels s'appuiera sur le modèle DIK (Data / Information / Knowledge) préalablement explicité.

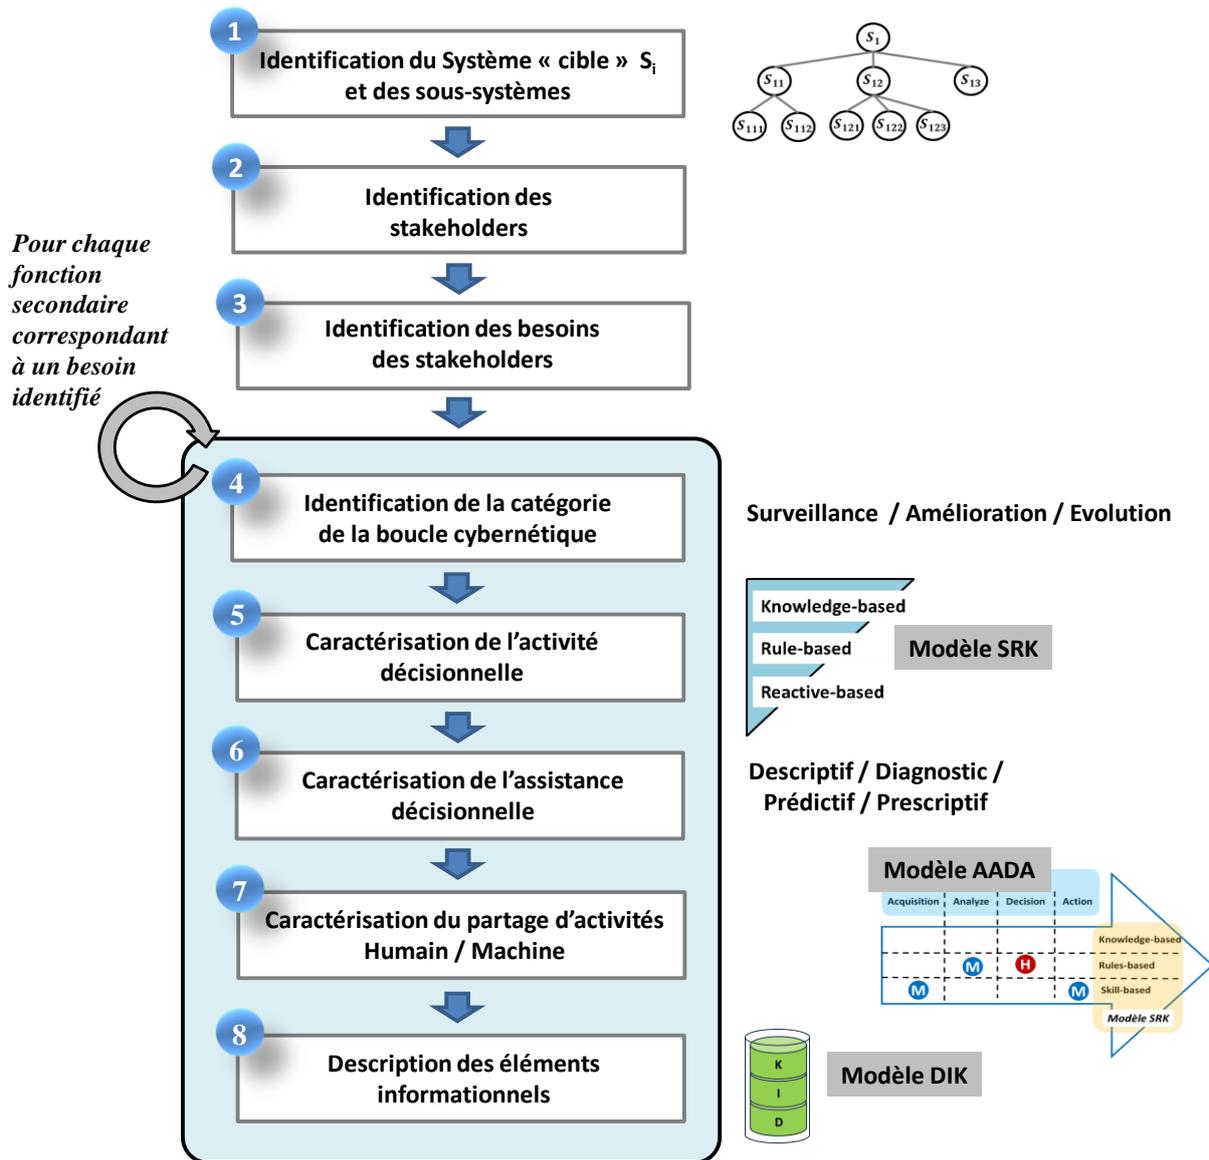


Figure III-20: Les huit étapes du guide méthodologique

## V/ Conclusion du chapitre

Ce chapitre a proposé une modélisation des boucles cybernétiques et des processus décisionnels associés à un système « cible » et a mis l'accent sur la place d'une assistance décisionnelle.

Après avoir présenté les différentes entités en interaction dans le cadre d'un domaine d'intérêt (systèmes « cible », fonctions primaires, utilisateurs et contexte), l'accent a été mis sur les fonctions secondaires (i.e. Surveillance, Amélioration, Evolution). L'étude a porté sur la proposition d'un modèle permettant de caractériser les boucles cybernétiques reliant le système « cible » et son contexte à un ou plusieurs stakeholders. Cette modélisation s'appuie sur plusieurs autres modèles servant de référentiels et guidant la réflexion :

- Une vision holonique permettant d'englober la décomposition tout-partie d'un système « cible » composite et d'associer à chaque sous-système, sa, ses, fonction(s) secondaire(s) et les flux informationnels.

- Une caractérisation Data, Information, Knowledge des flux informationnels au sein de la boucle cybernétique.
- Une classification « Reactive-based », « Rules-based », « Knowledge-based » de la nature des traitements décisionnels basés sur la typologie de Rasmussen.
- Une caractérisation permettant d'appréhender le partage des activités entre l'Humain et la Machine au travers du modèle AADA.

Pour accompagner la proposition et la rendre pleinement opérationnelle, un guide méthodologique a finalement été proposé.

Après avoir caractériser dans ce chapitre les attendus de l'assistance décisionnelle et avoir distingué les phases de conception et d'exploitation, le prochain chapitre est consacré aux différentes approches permettant de la concevoir.

# Chapitre IV

## Conception de l'assistance décisionnelle

### Introduction

Après avoir présenté dans le chapitre précédent le positionnement de l'assistance décisionnelle au sein des boucles cybernétiques, le présent chapitre est consacré aux différentes approches permettant de concevoir cette assistance.

Dans une première partie, les différentes approches utilisées pour le cycle de développement de l'assistance décisionnelle sont successivement présentées.

La seconde partie est consacrée à une présentation de plusieurs méthodologies permettant de choisir l'algorithme de Machine Learning le mieux adapté pour supporter l'assistance décisionnelle. L'accent est plus particulièrement mis sur la présentation de l'approche « Automated Machine Learning » permettant à un stakeholder de développer une assistance sans connaissance approfondie des différentes méthodes de Machine Learning.

### I/ Le cycle de développement de l'assistance

La communauté « Data Science » a très tôt développé des méthodologies permettant de supporter le cycle de développement d'un « modèle d'intérêt ». Ce dernier est vu comme un ensemble « algorithme et paramètres associés » permettant de supporter l'assistance décisionnelle.

Dans la suite de ce chapitre, le terme de « modèle » sera donc utilisé en ce sens.

Les différentes méthodologies de développement sont présentées ci-après dans un ordre chronologique permettant de mieux appréhender les évolutions au fil du temps.

#### I-1/ La méthodologie KDD

Avant la révolution de l'IA et du Machine Learning, initiée dans les années 2010, les entreprises ont adopté des méthodologies qui se concentraient sur l'exploitation des données (Zaki and Meira, Jr 2014) (Haoxiang and S 2021).

L'une des plus anciennes méthodologies est connue sous le nom de découverte de connaissances dans les bases de données (KDD) (Joudaki et al. 2015; Fayyad and Stolorz 1997; Fayyad, Piatetsky-Shapiro, and Smyth 1996). Dans cette approche, cinq étapes sont considérées (voir Figure IV-1) :

Etape n°1. Sélection : Cette étape consiste à créer un ensemble de données cibles, ou à se concentrer sur un sous-ensemble de variables ou d'échantillons de données, qui servira de base à l'élaboration du modèle.

Etape n°2. Prétraitement : Cette étape a pour objectif de nettoyer et de prétraiter les données cibles afin d'obtenir des données cohérentes.

Etape n°3. Transformation : Cette étape consiste à transformer les données à l'aide de méthodes de réduction de la dimensionnalité.

Etape n°4. Exploration/Fouille de données : Cette étape est dédiée à la recherche des modèles d'intérêt sous une forme de représentation particulière (ex : ensemble de règles) en fonction de l'objectif recherché.

Etape n°5. Interprétation/évaluation : Cette ultime étape a pour rôle d'interpréter et d'évaluer les modèles extraits.

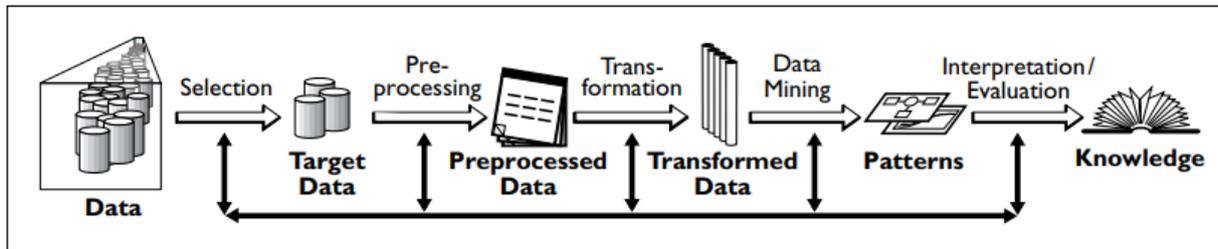


Figure IV-1: Vue d'ensemble des étapes du processus KDD (Fayyad, Piatetsky-Shapiro, and Smyth 1996)

Cependant, tout comme les méthodologies en cascade, le KDD souffre d'une certaine rigidité difficilement compatible avec des besoins évolutifs des stakeholders.

### I-2/ La méthodologie SEMMA

SEMMA est un processus d'exploration de données développé par l'institut SAS (Azevedo and Santos 2008). Comme explicité à la Figure IV-2, ce processus comporte cinq étapes : échantillonner, explorer, modifier, modéliser et évaluer.

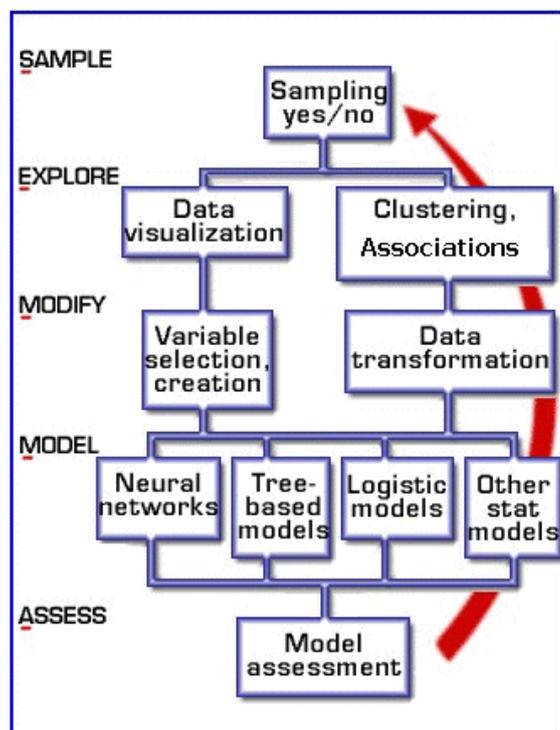


Figure IV-2: Les étapes de la méthode SEMMA

La première étape est relative à la sélection de l'échantillon, qui implique la collecte et la sélection des données pertinentes pour l'analyse. Ensuite, vient la phase d'exploration des



La méthodologie commence par une première boucle entre la compréhension des besoins de l'entreprise et la compréhension des données disponibles. Elle se poursuit par une seconde boucle entre la préparation des données et la modélisation permettant un affinement du modèle. Vient ensuite l'étape d'évaluation permettant un rebouclage avec les besoins exprimés par l'entreprise. Enfin le processus s'achève classiquement par une étape de déploiement

L'ensemble de ces étapes se situe au sein d'une plus grande boucle permettant une itération du processus global et ainsi un traitement des données et une évolution du modèle en continu.

Cependant, la méthodologie CRISP-DM v1.0 a été publiée il y a près de vingt ans et la méthodologie CRISP-DM n'a pas été mise à jour depuis. Les seuls développements ultérieurs ont été produits par IBM et Microsoft qui ont proposé leurs propres variantes en détaillant les étapes de traitement des données et de modélisation. Toutefois, les deux entreprises exploitent principalement leurs variantes dans le cadre de leurs propres projets et en favorisant leurs propres produits. Ces méthodologies ne répondent donc pas aux besoins des entreprises ou du monde de la recherche qui souhaitent utiliser des approches génériques et techniquement neutres.

Le KDD, SEMMA et CRISP-DM ont largement été utilisées par la communauté des data scientists et plus spécifiquement pour le data mining. Cependant, de par la rigidité des processus, elles trouvent leur limite dans le cadre du développement de modèles à base d'intelligence artificielle (Schröer, Kruse, and Gómez 2021; Frye, Krauß, and Schmitt 2021).

#### **I-4/ La méthodologie CPMAI**

De façon à pallier en partie aux limites des approches précédentes, la méthodologie Cognitive Project Management for AI (CPMAI) a été développée par la société Cognilytica. Cette méthodologie vise une gestion efficace des projets utilisant des approches IA (Frye, Krauß, and Schmitt 2021; Aboukadri, Ouaddah, and Mezrioui 2023). Elle repose sur une approche itérative et agile de la gestion de projet, permettant aux équipes de data scientists de collaborer étroitement et de s'adapter rapidement aux évolutions du contexte et des données. Le CPMAI fournit un ensemble de bonnes pratiques permettant une définition claire des objectifs du projet et facilitant la planification des ressources, la gestion des risques, la mesure des performances et la communication avec les stakeholders.



Figure IV-4: Les différentes étapes de la méthodologie CPMAI

Dans la Figure IV-4, six principales phases sont distinguées et une progression entre les phases (en avant ou en arrière) est possible pendant la génération du modèle en fonction des besoins des stakeholders et des difficultés rencontrés lors du développement.

Phase n°1 (Compréhension du métier) : Cette phase initiale se concentre sur la compréhension des objectifs et des exigences du projet du point de vue du métier, puis, suite à l'étude du ou des besoins du stakeholder, sur la traduction de ces exigences en une définition des objectifs à atteindre.

Phase n°2 (Compréhension des données) : La phase de compréhension des données commence par une collecte initiale et se poursuit par des activités visant à se familiariser avec les données, à identifier les problèmes de qualité des données, à découvrir des sous-ensembles intéressants afin de formuler des hypothèses pour la génération du modèle. Les données proviennent de sources variées, telles que les données historiques (ex : données transactionnelles, données issues d'enquêtes, historique de la maintenance...). Elles peuvent être également issues de différents départements de l'entreprise ou de sources externes telles que par exemple des données météorologiques, des localisations GPS, ou des informations sur le trafic.

Pour mener à bien cette étape, le data analyst doit répondre à plusieurs questions :

- Quels sont les attributs de la base de données qui semblent les plus significatifs ?
- Quels sont les attributs qui semblent sans intérêt et peuvent être exclus ?
- Le nombre de données permet-il de tirer des conclusions pouvant être généralisées ou d'effectuer des prévisions précises ?

- La fusion de données issues de plusieurs sources est-elle faisable ?
- Le mode de traitement des valeurs manquantes est-il envisageable ?

Par la suite, la description des données est importante afin d'orienter au mieux le choix des outils de préparation des données dans l'étape suivante.

Dans la majorité des techniques de modélisation, le temps de traitement dépend du volume des données. Les grands jeux de données permettent de produire des modèles plus précis, mais augmentent également le temps de traitement.

**Phase n°3 (Préparation des données) :** Cette phase de préparation couvre toutes les activités visant à élaborer un ensemble de données final, répondant à des critères quantitatifs et qualitatifs, à partir des données brutes initiales. En fonction de la collecte initiale de données réalisée lors de la phase précédente et des besoins exprimés par les stakeholders, seules les données pertinentes sont retenues. Cette phase s'accompagne également d'un nettoyage des données. Ce dernier peut se faire en appliquant différentes techniques, comme explicité dans le Tableau IV-1 ci-dessous :

<b>Problème posé par les données</b>	<b>Solution possible</b>
Données manquantes	Exclure les lignes ou les caractéristiques, ou insérer une valeur estimée dans les blancs.
Erreurs dans les données	Procéder de manière logique pour découvrir manuellement les erreurs et les corriger, ou exclure les caractéristiques.
Codage des incohérences	Décider d'une méthode de codage unique, puis convertir et remplacer les valeurs.
Métadonnées erronées ou manquantes	Examiner manuellement les champs suspects et rechercher la signification correcte.

*Tableau IV-1 : Solutions pour le nettoyage des données*

**Phase n°4 (Développement du modèle) :** Cette phase comprend le choix d'un algorithme, l'entraînement du modèle, la définition et l'ajustement des hyperparamètres. La construction du modèle suppose que les besoins de stakeholders et les exigences en matière de données aient été bien déterminées et les données préparées dans le bon format.

**Phase n°5 (Évaluation du modèle) :** Cette étape permet de mesurer la performance du modèle et de déterminer s'il convient ou non à l'utilisation prévue. Il existe plusieurs métriques d'évaluation des modèles, pouvant varier en fonction du type de problème à résoudre (classification, régression, etc.) et des objectifs spécifiques de l'application. Dans le cas de la classification binaire, une métrique couramment utilisée est la matrice de confusion, qui permet de déterminer le nombre de vrais positifs, de vrais négatifs, de faux positifs et de faux négatifs. À partir de cette matrice, plusieurs métriques peuvent être calculées, telles que la précision, le rappel, le F1-score et l'aire sous la courbe ROC (Receiver Operating Characteristic) (Shekar and Dagnew 2019; Ku 2018).

**Phase n°6 (Opérationnalisation du modèle) :** Cette phase concerne le déploiement du modèle pour une utilisation dans différents environnements (e.g. cloud, périphérique Edge, ordinateur individuel, serveur hébergé).

La suite de ce chapitre explore les différentes approches utilisables pour le choix de l'algorithme.

## **II/ Choix des algorithmes permettant l'obtention du modèle**

Comme vu précédemment le choix de l'algorithme est une étape clé dans le développement de l'assistance. Cette section présente en premier les approches classiquement utilisées reposant sur des guides de choix et décrit ensuite une solution plus innovante : l'Automated Machine Learning.

### **II-1/ Approches exploitant des guides de choix**

De nombreuses sociétés en informatique, proposent des guides de choix d'algorithmes, pour la phase de développement du modèle, destinés aux utilisateurs qui souhaitent identifier et appliquer des algorithmes de Machine Learning. Un tel guide propose différents algorithmes en fonction de plusieurs critères, tels que la taille, la qualité et la nature des données, le temps de calcul disponible et aussi du besoin spécifié par le stakeholder.

La taille des données a une influence directe dans le choix de l'algorithme. Comme vu dans la revue de littérature dans le chapitre II, certains algorithmes sont plus efficaces pour traiter de grandes quantités de données que d'autres. La qualité des données peut également être un facteur important, car certains algorithmes peuvent s'avérer plus résilients aux erreurs de données. La nature des données, telles que des données textuelles ou des images, joue également un rôle important pour le choix d'algorithme.

Un autre critère important dans le choix de l'algorithme est le temps de calcul disponible. Par exemple, les réseaux de neurones peuvent nécessiter des ressources informatiques plus importantes que d'autres algorithmes, ce qui peut avoir un impact sur la rapidité et la précision de l'apprentissage si le stakeholder souhaite avoir un résultat rapide.

Enfin, le besoin du stakeholder est un critère crucial dans le choix de l'algorithme. Les algorithmes Machine Learning peuvent être utilisés pour des tâches de classification, de prédiction ou de recommandation. Le choix de l'algorithme doit donc être adapté à la tâche spécifique pour laquelle il sera utilisé.

La Figure IV-5 et la Figure IV-6 donnent des exemples de guides de choix proposés par des sociétés reconnues dans le domaine du Machine Learning. Par exemple, en appliquant le guide de choix de Scikit-Learn, si le jeu de données initial pour l'apprentissage contient plus que 50 lignes et si la prédiction concerne des catégories labélisées, on vérifie si le jeu de données contient plus que 100k lignes, si c'est le cas, l'algorithme SGD Classifier est proposé, sinon l'algorithme Linear SVC est proposé. Si l'un de ces deux algorithmes ne donne pas de résultats pertinents, la suite du guide propose d'autres algorithmes.

Ces guides sont principalement conçus pour des utilisateurs et des analystes de données débutants et bien souvent des hypothèses simplificatrices sont introduites. En parallèle de ces guides, des méthodes multicritères peuvent également être utilisés pour le choix des algorithmes. L'objectif de ces méthodes est de trouver un algorithme apte à assurer un compromis entre les différents critères cités précédemment (Ali, Lee, and Chung 2017). Bien qu'intéressantes, ces méthodes multicritères ne seront pas détaillées plus avant dans ce mémoire.

L'utilisation des guides ou des approches multicritères nécessitent cependant des connaissances dans les domaines du Big Data, de l'IA et une certaine maîtrise des techniques du ML. Cependant, ces stakeholders n'étant pas nécessairement experts en techniques du ML, la génération de l'assistance repose alors principalement sur des experts en ML et des data scientists. De plus, le déploiement des techniques de ML est un processus qui peut s'avérer coûteux en temps (Baier, Jöhren, and Seebacher 2020) et potentiellement sujets à des erreurs humaines (Sarangpure et al. 2023). Pour pallier à ces freins, une nouvelle approche appelée Automated Machine Learning (AutoML) a récemment été proposée (Bahri et al. 2022; ZhengRuiqi et al. 2023). Cette nouvelle approche est présentée dans la partie suivante.

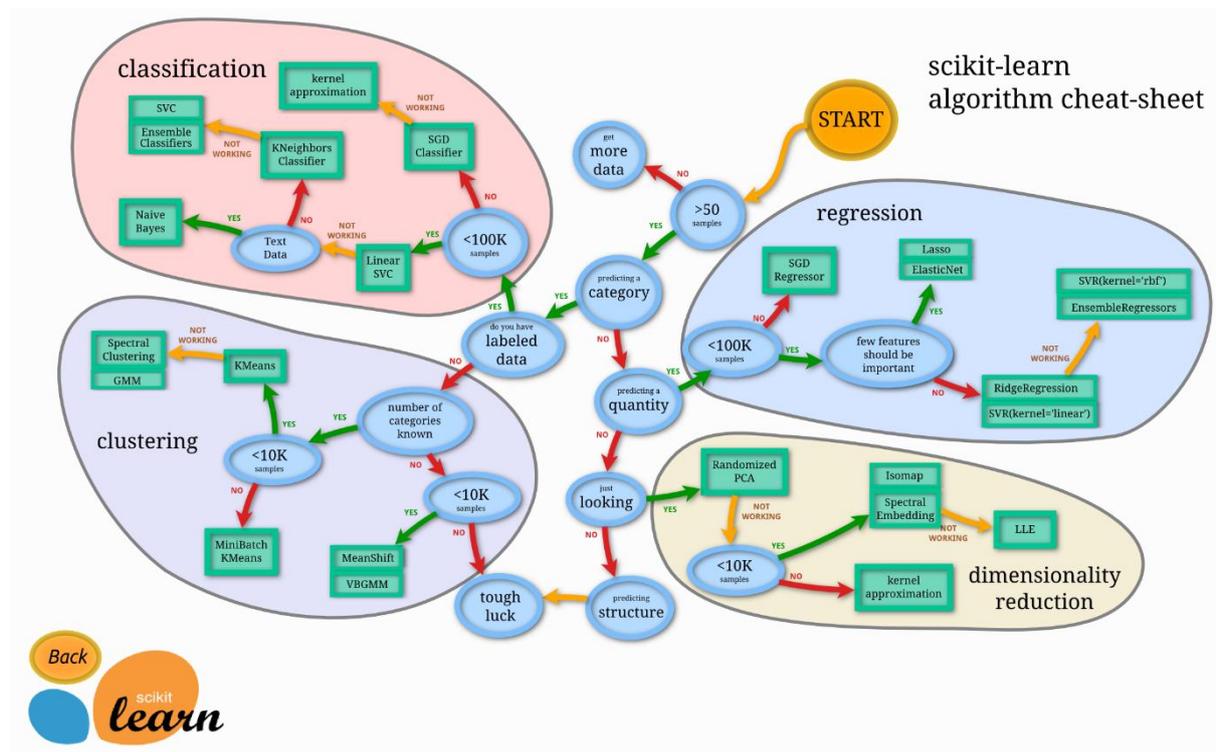


Figure IV-5: Guide de choix d'algorithmes ML proposé par Scikit-Learn

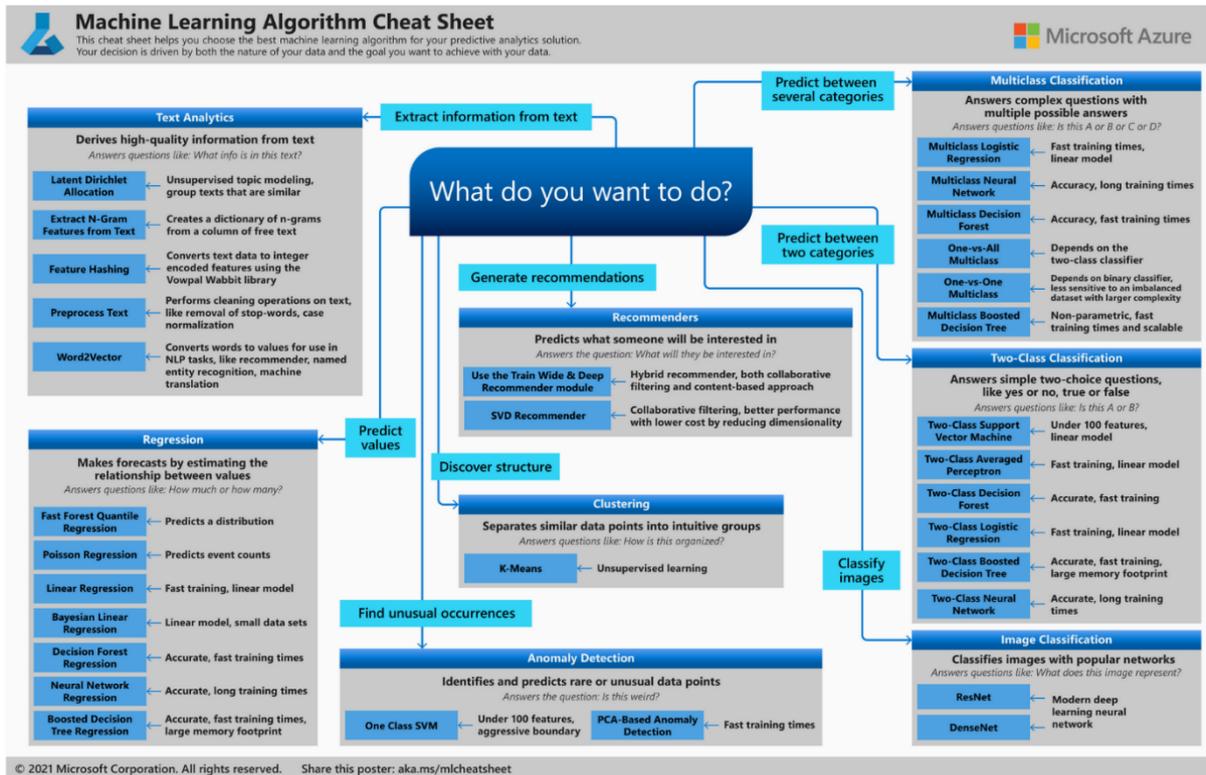


Figure IV-6: Guide de choix d'algorithme pour un Modèle ML proposé par Microsoft

## II-2/ L'approche Automated Machine Learning (AutoML)

Après une description des principes de fonctionnement de l'AutoML, des exemples d'utilisation sont présentés.

### II-2-1/ Le principe de fonctionnement

Les progrès récents du ML ont entraîné une demande croissante de systèmes automatiques aptes à assister les développeurs et les débutants en ML dans le développement des applications. Cette demande a donné naissance au développement d'une approche générique apte à traiter une grande variété de problèmes : l'Automated Machine Learning (dénommée aussi AutoML). Dans le cadre de cette approche, deux objectifs principaux sont visés :

- (i) Offrir des solutions prêtes à l'emploi aux utilisateurs non experts pour exploiter les données et développer des outils de ML efficaces sans avoir à développer de code (ou très peu) ;
- (ii) Faire gagner du temps aux experts dans leur processus de prise de décision au niveau des algorithmes et des paramétrages en utilisant de nouvelles technologies informatiques puissantes.

L'AutoML est également connu sous d'autres termes tels que le One Button Data Mining (Stiglic et al. 2012) ou l'Automated Data Science (Olson, Edu, and Moore 2016). Les outils informatiques existants, tels que AutoWEKA (Thornton et al. 2013), hyperopt-sklearn (Komer, Bergstra, and Eliasmith 2014), Auto-sklearn (Feurer et al. 2022), TPOT (Olson, Edu, and Moore 2016) et Auto-Keras (Jin, Song, and Hu 2019) permettent d'automatiser la plupart des phases de développement d'un modèle Machine Learning (prétraitements des données,

classificateurs, réglages d'hyperparamètres,...) et par conséquent de réduire l'effort des utilisateurs.

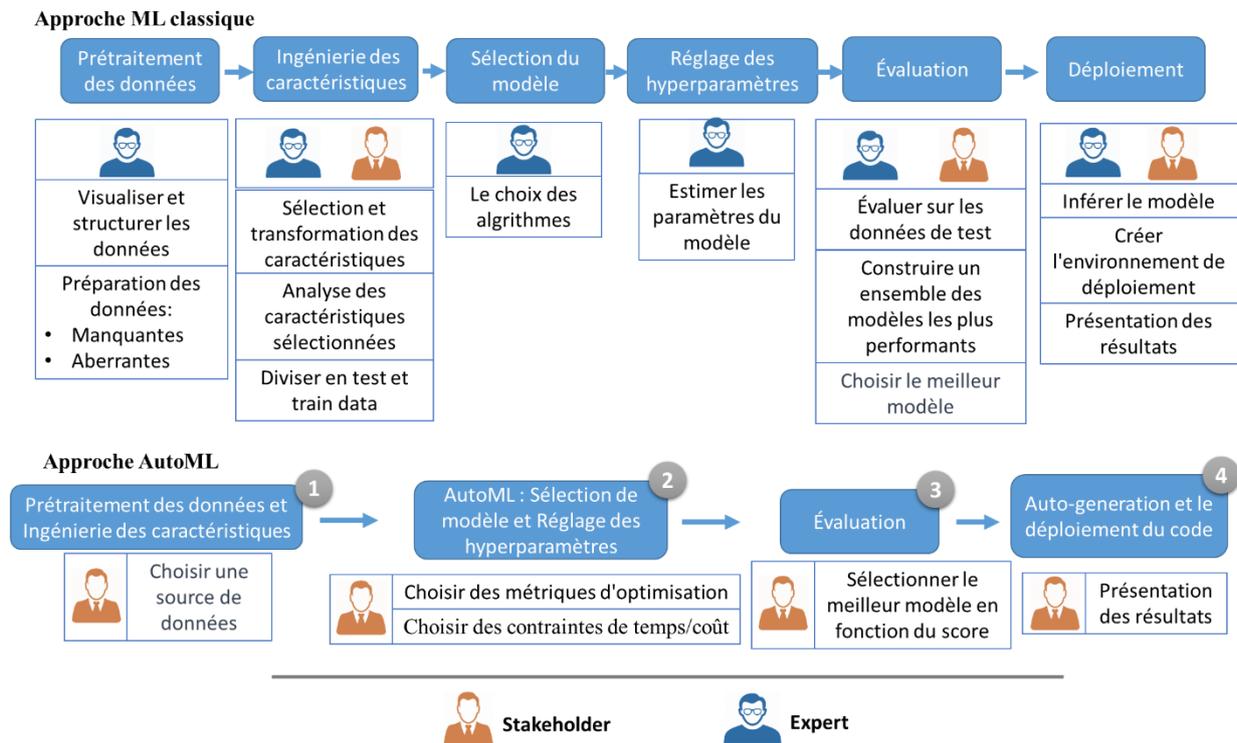


Figure IV-7: Le workflow AutoML par rapport au workflow du Machine Learning traditionnel.

Comme illustré à la Figure IV-7, dans les approches ML classiques, et selon le cas d'utilisation, des équipes d'experts (par exemple, des spécialistes des données, des développeurs de logiciels) accompagnent les stakeholders pour analyser le problème et développer un modèle. Cet accompagnement peut s'avérer particulièrement coûteux pour les entreprises (Lwakatare et al. 2019). En revanche, l'utilisation de l'approche AutoML réduit considérablement ce besoin en experts du ML.

Les étapes associées à l'approche AutoML sont les suivantes :

- (1) Prétraitement des données et ingénierie des fonctionnalités : cette étape traite les problèmes liés aux données tels que les valeurs manquantes, les valeurs aberrantes, les données bruitées ou modifiées. Pour résoudre le problème des valeurs manquantes dans le prétraitement des données, l'AutoML utilise des techniques telles que l'imputation des valeurs manquantes. L'imputation consiste à estimer ou à remplacer les valeurs manquantes par des valeurs calculées à partir des autres observations dans les données. Différentes approches peuvent être utilisées pour l'imputation des valeurs manquantes, telles que l'imputation par la moyenne ou la médiane ou l'imputation par régression (De Goeij et al. 2013).
- (2) Sélection du modèle et réglage des hyperparamètres : Cette deuxième étape permet de sélectionner automatiquement l'algorithme à utiliser mais également la configuration optimale des hyperparamètres (c'est-à-dire les paramètres ajustables de l'algorithme) pour obtenir de bonnes performances d'apprentissage.

La Figure IV-8 illustre les différentes étapes de ce choix.

- Dans un premier temps (étape n°1 sur la figure), le stakeholder définit les métriques d'optimisation pour évaluer les résultats (par exemple : la précision, le score f1,  $R^2$ , le Mean Squared Error) (Jiao and Du 2016). Il définit également les contraintes en termes de temps ou de coût (par exemple la durée maximale de traitement) que le processus AutoML doit respecter.
  - L'étape suivante (c'est-à-dire le processus de sélection du modèle) peut être considérée comme un seul problème d'optimisation d'hyperparamètres (HPO) avec un espace de configuration hiérarchique. Une première itération (étape n°2 sur la figure) sélectionne un algorithme (modèle  $\{1,2,\dots,n\}$ ) et une deuxième itération (étape n°3) sélectionne les hyperparamètres correspondants (paramètres  $\{1, 2,\dots,i\}$ ). Pour faire face à des espaces de configuration aussi complexes et structurés, différents algorithmes d'optimisation peuvent être utilisés, comme Random Search (Florea and Andonie 2020; Bergstra, Ca, and Ca 2012) ou Grid Search (R. Liu et al. 2006; Shekar and Dagneu 2019). Random Search définit l'espace de recherche comme un domaine délimité de valeurs d'hyperparamètres et échantillonne aléatoirement des points à l'intérieur. Grid Search définit l'espace de recherche comme une grille de valeurs d'hyperparamètres et évalue chaque position dans la grille. Des méthodes plus avancées sont parfois utilisées, telles que l'optimisation bayésienne et l'optimisation évolutive (Zhang et al. 2020; Hutter, Kotthoff, and Vanschoren 2019).
- (3) Évaluation : le processus AutoML donne enfin un classement des meilleurs modèles sélectionnés en fonction des métriques et des contraintes d'optimisation introduites à la première étape. Le stakeholder choisit alors le modèle avec le score le plus élevé (étape n°4 sur la figure).
- (4) Déploiement : Enfin, le stakeholder peut donc implémenter le modèle généré dans un environnement de développement puisque les outils AutoML les plus avancés fournissent un code exécutable (étape n°5 sur la Figure IV-8).

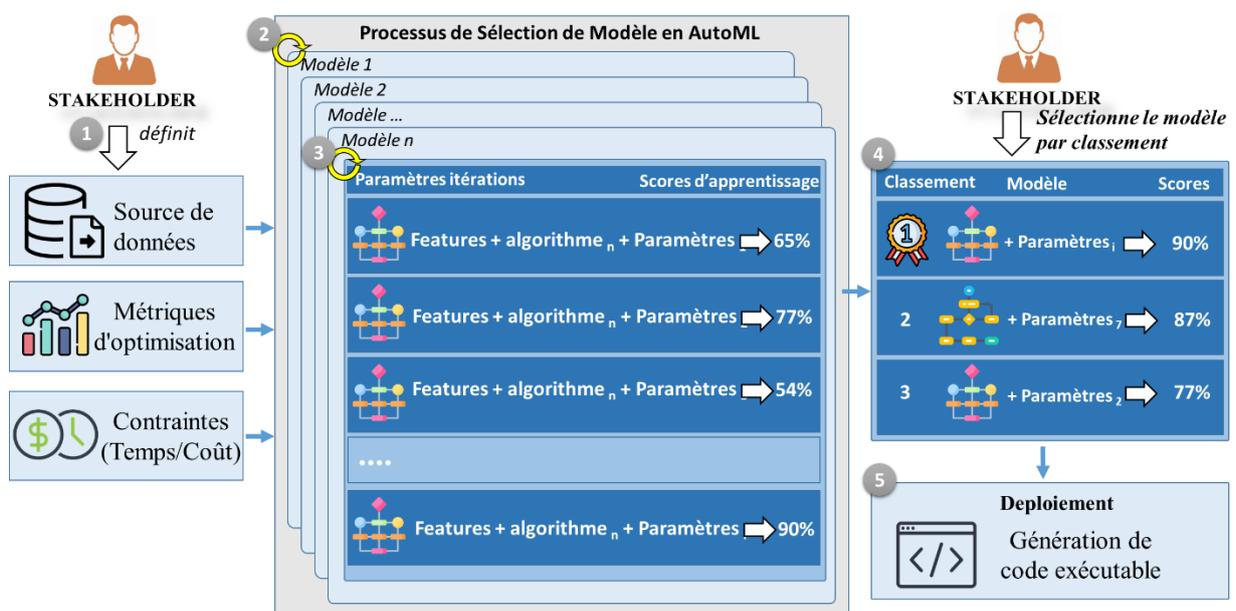


Figure IV-8: Les étapes successives du processus AutoML

## **II-2-2/ Exemples d'utilisation**

Dans cette section, sont listés quelques travaux utilisant une approche AutoML dans différents domaines d'application.

Domaine manufacturier : Dans (Garouani et al. 2022), l'auteur propose un cadre pour aider les décideurs à choisir un modèle approprié pour la prédiction dans un contexte de maintenance. Dans (Krauß et al. 2020), une approche basée sur AutoML est utilisée pour prédire la qualité des produits dans un contexte de gestion de production. Pour vérifier la qualité des matières premières pour les outils et minimiser l'erreur dans les opérations de fraisage, un processus AutoML est proposé dans (Denkena et al. 2020). Le système a été évalué sur des données de fraisage d'un ensemble de poches.

Domaine du transport : Dans (Kocbek and Gabrys 2019), les auteurs ont utilisé une approche AutoML pour identifier les défauts sur les voies ferroviaires dans le but de réduire les coûts de maintenance et d'améliorer la sécurité. Cette approche est évaluée sur les données recueillies lors d'une compétition internationale de modélisation prédictive. Dans (X. Shi et al. 2021), l'approche AutoML est utilisée pour prédire le risque associé aux véhicules autonomes. L'évaluation est basée sur l'ensemble de données de simulation de nouvelle génération (NGSIM) pour la prédiction du risque basée sur le comportement.

Domaine de l'environnement : Dans (Martin Salvador, Budka, and Gabrys 2016), les auteurs présentent une technique hybride basée sur AutoML pour l'évaluation des changements environnementaux dans l'industrie chimique. L'approche est évaluée sur sept ensembles de données issus d'usines chimiques.

Domaine de la logistique : Dans (Jackson and Velazquez-Martinez 2021), les auteurs proposent un cadre basé sur les techniques AutoML pour la classification des solutions de transport (rentables ou non) dans le domaine des chaînes d'approvisionnement alimentaire. Le cadre proposé aide les décideurs à prendre des décisions rapides sur le moyen de transport à utiliser.

Dans la section suivante, une architecture de développement de l'assistance ; utilisant l'approche AutoML est proposée.

## **II-2-3/ Architecture de développement de l'assistance avec AutoML**

Cette architecture complète la proposition de la Figure III-10 du chapitre III en détaillant la phase de « Conception ». Comme explicité à la Figure IV-9, en adaptant les phases de CPMAI présenté précédemment, quatre étapes sont distinguées :

- Etape n°1 (Collecte de données) : Cette étape exploite la base des données historiques (c'est-à-dire les données obtenues de l'utilisation du système « cible » ou d'autres systèmes similaires, y compris leur environnement) ainsi que d'autres bases de données de l'entreprise (par exemple, l'historique des interventions de maintenance, l'historique de production).
- Etape n°2 (Prétraitement des données) : Cette seconde étape est dédiée à la configuration du processus AutoML par l'utilisateur. Ce dernier doit sélectionner les données, les métriques d'optimisation et les contraintes associées au processus AutoML. Les données sont également réparties en un ensemble d'apprentissage et un ensemble de test. C'est une étape importante dans le domaine de la science des données en général, en particulier pour la création de modèles basés sur les données dans un processus ML pour éviter

l'overfitting (Vabalas et al. 2019). L'ensemble de données d'apprentissage est utilisé pour entraîner et développer des modèles. Après la génération du modèle, l'ensemble de données de test est utilisé pour mesurer la façon dont le modèle traite de nouvelles observations.

- Etape n°3 (Sélection et formation du modèle) : Cette étape est le cœur de l'approche AutoML comme expliqué dans la section précédente. En utilisant l'ensemble de données d'apprentissage précédent, le « meilleur » modèle de ML est déterminé comme expliqué
- la Figure IV-9. À la fin de cette étape, sa performance est vérifiée sur l'ensemble de données de test selon les critères d'évaluation choisis.
- Etape n°4 (Implémentation) : Cette étape est dédiée à la mise en œuvre de l'assistance basée sur le ML dans la boucle décisionnelle entre le système cible et l'utilisateur comme détaillé dans le chapitre III.

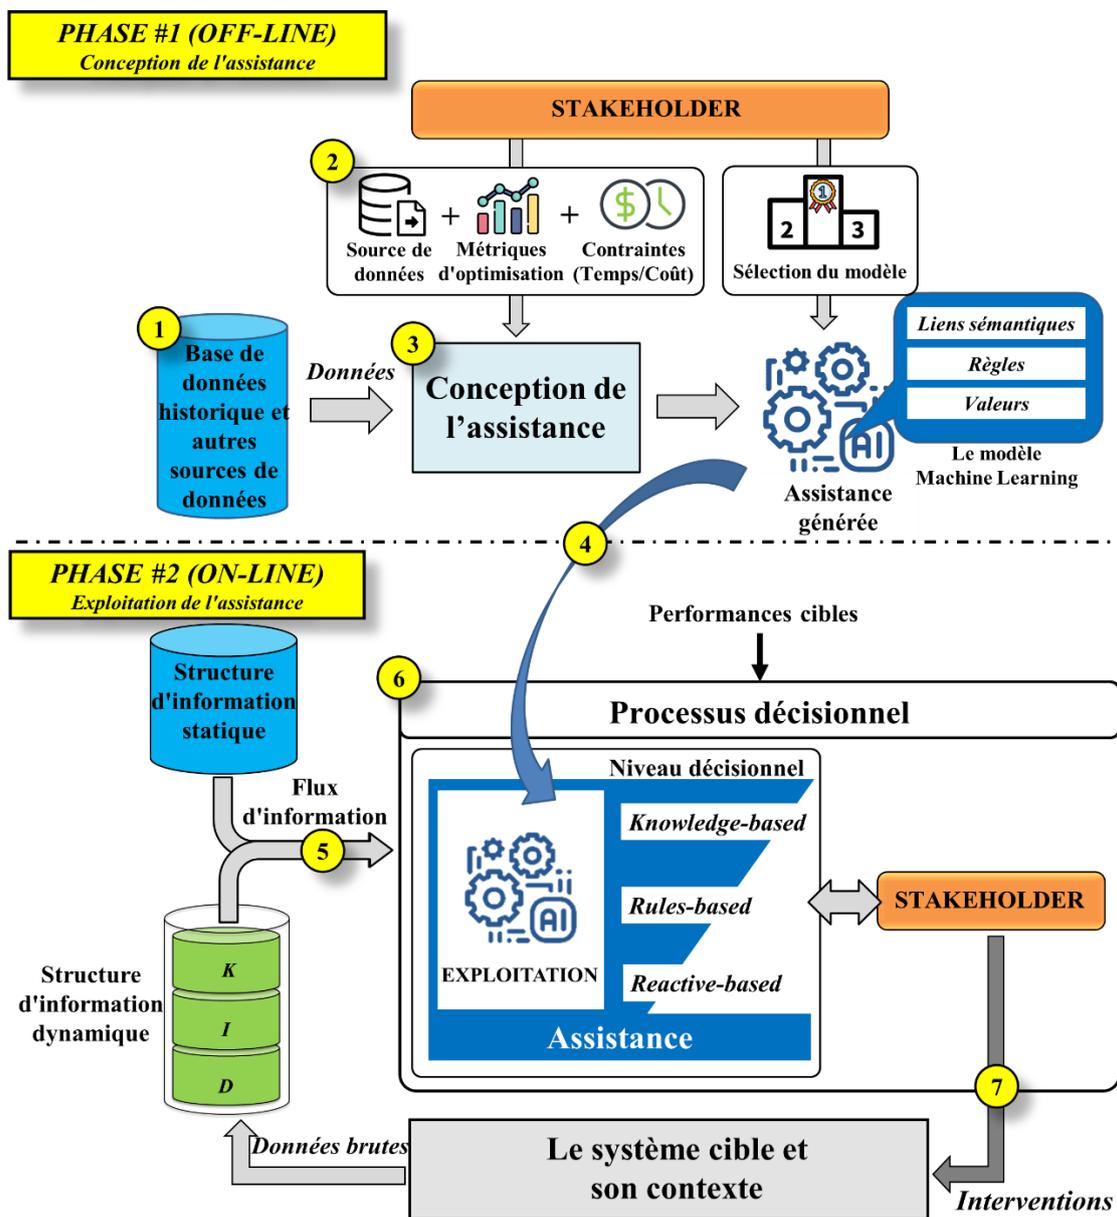


Figure IV-9: Phase de conception via AutoML et d'exploitation de l'assistance

### **III/ Conclusion du chapitre**

Après avoir rappelé les différentes méthodologies associées au cycle de développement de l'assistance, ce chapitre a mis l'accent sur une nouvelle approche : l'Automated Machine Learning.

L'adoption de la méthode AutoML peut être très bénéfique pour les entreprises qui cherchent à générer rapidement des modèles de Machine Learning pour des cas d'application spécifiques. La méthode AutoML en combinaison avec la méthodologie CPMAI offre une alternative efficace aux méthodes traditionnelles telles que CRISP-DM, SEMMA et KDD, qui peuvent prendre du temps et nécessiter des connaissances approfondies en data analytics.

Via AutoML ; les décideurs qui ne sont pas des experts en data analytics peuvent également générer des modèles de qualité sans avoir besoin de compétences spécialisées. Le gain offert par cette approche, en réduisant le temps et les coûts nécessaires pour générer des modèles de Machine Learning, peut permettre aux entreprises de se concentrer davantage sur l'interprétation des résultats plutôt que sur la génération de modèles. Toutefois, il est important de noter que la méthode AutoML n'est pas toujours la meilleure option pour toutes les applications de Machine Learning, car elle peut manquer de la flexibilité offerte par les méthodes traditionnelles (He, Zhao, and Chu 2021; Truong et al. 2019).

Le chapitre suivant va présenter l'exploitation des concepts introduits dans ce chapitre et dans le chapitre III au travers de plusieurs cas d'étude dans les domaines du transport routier et du ferroviaire.

# Chapitre V

## Applications des concepts

### Introduction

Ce chapitre est dédié à une application des concepts, du guide méthodologique et des méthodes de génération d'assistance présentés dans les chapitres précédents dans un but de validation.

L'application du guide méthodologique à travers ses 8 étapes contribue à une compréhension approfondie et frugale des besoins des stakeholders. Cette compréhension peut être vue comme la réponse détaillée des deux premières phases de la méthodologie CPMAI présentée dans le chapitre 4 et qui sont respectivement les phases de compréhension du métier et de compréhension des données.

Il est important de rappeler que le modèle d'architecture proposée dans le chapitre 3 et les approches de génération de l'assistance présentées dans le chapitre 4 sont technologiquement agnostiques.

Les deux cas applicatifs traités dans ce chapitre relèvent du domaine du transport routier et ferroviaire et sont issues de travaux réalisés en partenariat avec les sociétés STMF et Alstom.

Chaque étude a pour objectif de valider l'assistance décisionnelle apportée aux boucles cybernétiques existant entre le système « cible » et les différents stakeholders.

Pour chacun des cas applicatifs une présentation sera réalisée en premier, puis une deuxième partie sera dédiée à la présentation de l'écosystème qui supporte les chaînes informationnelles et décisionnelles. La description des données disponibles, les outils et logiciels utilisés, ainsi que les approches adoptées sont successivement détaillés.

### **I/ Application n°1 : Optimisation de la maintenance pour STMF**

Le cas d'utilisation concerne une flotte de véhicules transportant des substances dangereuses. Les informations opérationnelles relatives au transport de matières dangereuses sont fournies par la STMF (Mallouk, Abou El Majd, and Sallez 2018), une entreprise marocaine leader dans ce secteur (Voir Figure V-1).

Plus spécifiquement, le cas d'application se concentre sur la gestion des pneus des camions, étant donné que les défaillances des pneus peuvent avoir des conséquences dramatiques. Assurer un haut niveau de fiabilité des véhicules est un paramètre très important pour mener à bien les missions de livraison. Un accident mineur, comme un éclatement de pneu, peut provoquer le détachement du réservoir contenant la substance dangereuse avec des conséquences dramatiques pour l'entreprise de transport, les autres usagers de la route et l'environnement.

L'objectif principal est d'établir un diagnostic des pneus pour évaluer leur durée de vie et calculer le nombre de kilomètres restants avant qu'un pneu ne soit considéré comme non utilisable.

Ce cas d'application met en évidence le défi de gérer une flotte de plus de 288 véhicules avec environ 3456 pneus opérationnels et une centaine en stock. En plus, à chaque véhicule est

associé un ensemble d'informations liées à son environnement spécifique, telles que la tâche effectuée, le conducteur qui l'opère et le contexte dans lequel il opère. Pour faciliter la prise de décision, l'objectif est de créer une assistance décisionnelle capable de fournir des éléments d'aide à la décision pour le centre de maintenance de STMF.

Par exemple, dans le cas d'un camion fonctionnant dans un environnement où les routes sont particulièrement dégradées ; les informations associées à ce camion peuvent indiquer une usure plus rapide des pneus par rapport à d'autres véhicules opérant sur des routes moins dégradées. L'assistance décisionnelle peut tenir compte de ces données et recommander une rotation des pneus plus fréquente pour ce camion, afin de prévenir les pannes dues aux pneus et d'optimiser leur durée de vie.

De plus, l'assistance peut également prendre en compte les caractéristiques des conducteurs. Par exemple, si un conducteur a tendance à conduire de manière agressive, cela peut entraîner une usure prématurée des pneus. En surveillant et en analysant les données relatives au comportement de conduite de chaque conducteur, l'assistance peut identifier les conducteurs nécessitant une formation supplémentaire sur les bonnes pratiques de conduite, afin de minimiser l'usure des pneus et d'améliorer la sécurité globale de la flotte tout en minimisant l'impact négatif sur l'environnement.

En combinant les informations spécifiques à chaque véhicule, aux conducteurs et à leur contexte, l'assistance fournit des éléments d'aide à la décision aux différents stakeholders de STMF et en particulier ceux du centre de maintenance. Cela permet de planifier efficacement l'entretien de la flotte en fonction des diagnostics des pneus et d'autres paramètres pertinents (par exemple les prévisions météorologiques, la planification des missions...), ce qui réduit les risques d'accidents liés à des défaillances de pneumatiques et évite les temps d'arrêt non planifiés des camions et optimise l'utilisation des pneus en les remplaçant au bon moment plutôt que de manière systématique.



*Figure V-1: Des véhicules citerne de STMF*

## I-1/ Application du guide méthodologique et analyse des fonctions secondaires

Le guide méthodologique utilisé est celui proposé dans le chapitre III et s'appuie logiquement sur l'ensemble des différents modèles proposés.

### I-1-1/ Etape 1 : Identification du système et des sous-systèmes ciblés

La première étape du guide est dédiée à l'identification du système et à sa décomposition en sous-systèmes. Le système considéré dans ce cas applicatif est l'ensemble des véhicules de transport.

L'étude se focalise sur les véhicules de type poids lourd, dont la fonction primaire est de transporter la marchandise d'un point de départ à une destination. L'accent est mis sur les pneus de ces véhicules, un sous-système qui met en contact le véhicule avec la chaussée et qui a une importance capitale pour assurer la sécurité du véhicule de la marchandise transportée (i.e. les produits dangereux).

Chaque véhicule se compose d'un tracteur et d'une remorque. Le tracteur se compose de deux essieux dont l'un est amovible (i.e. l'axe des roues de direction qui sert à orienter le véhicule). La remorque se compose de trois essieux dont l'un est généralement relevable (i.e. l'essieu est automatiquement relevé ou abaissé si les conditions de charge le permettent). Nous supposons que tous les essieux comportent des roues simples, donc un véhicule est composé de dix pneus au total.

L'arbre de décomposition de la flotte de véhicules est décrit à la Figure V-2 avec indiqués en orange les systèmes et sous-systèmes qui se seront considérés dans l'étude.

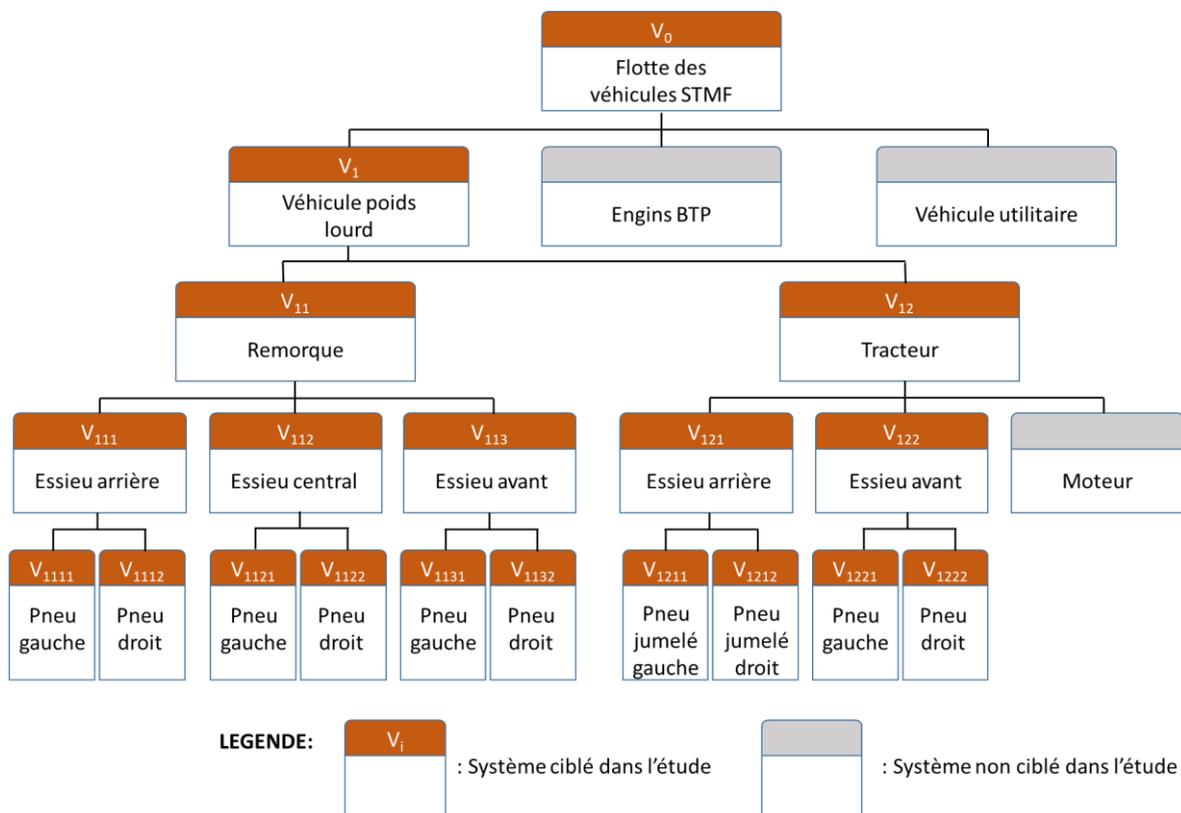


Figure V-2: Arbre de décomposition

Comme explicité précédemment, seul le système « Véhicules poids lourd » et ses sous-systèmes « pneus » seront considérés dans l'étude. Il en résulte l'architecture holonique présentée sur la Figure V-3.

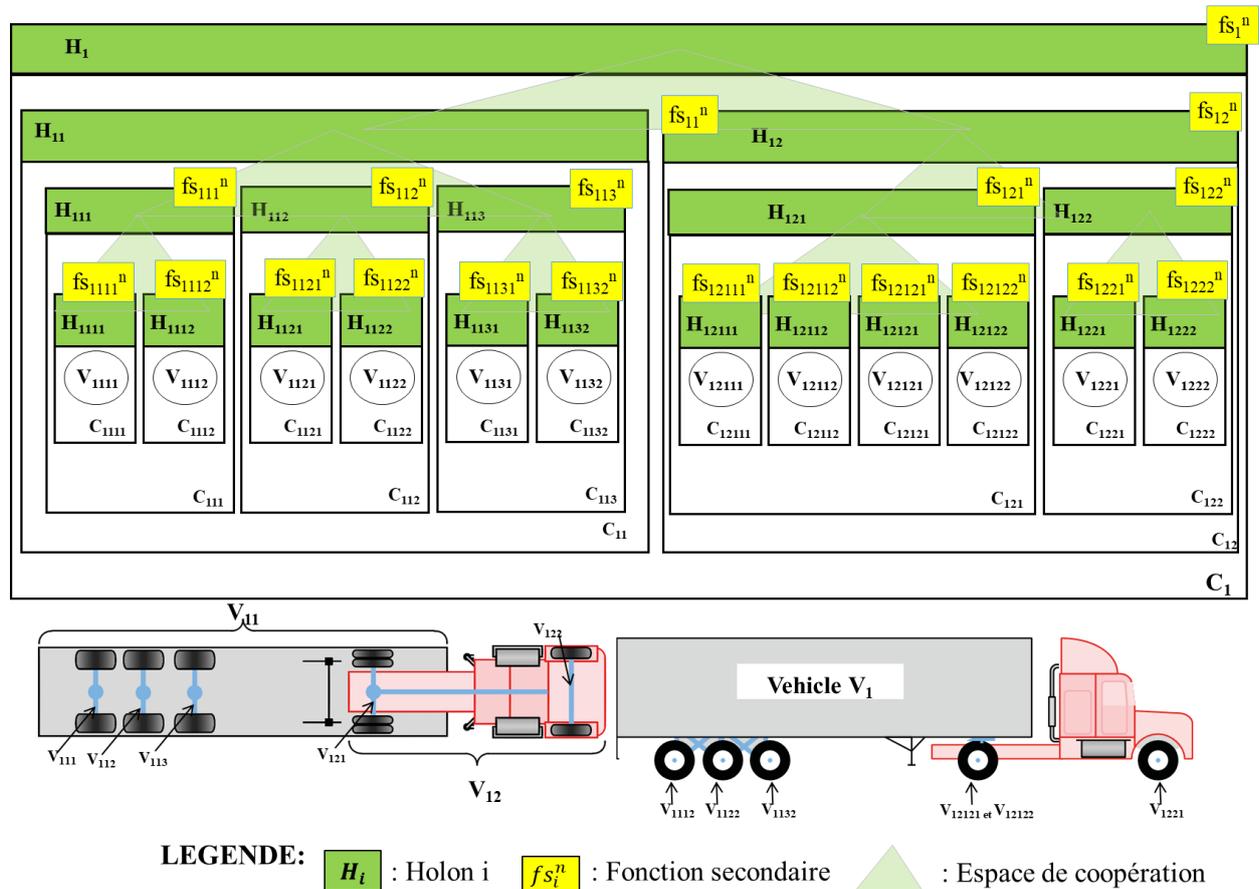


Figure V-3: Architecture holonique associée au système et aux sous-systèmes ciblés

### I-1-2/ Etape 2 : Identification des stakeholders

La deuxième étape du guide méthodologique est consacrée à l'identification des stakeholders relatifs à l'étude considérée. Dans le cadre de cette application, deux stakeholders sont distingués :

- Le stakeholder « **Responsable de la maintenance** » son rôle est crucial pour garantir la sécurité et la conformité des véhicules lors du transport de substances dangereuses. En ce qui concerne les pneus de la flotte de véhicules, le responsable de maintenance a pour objectif principal de les maintenir en bon état de fonctionnement afin de minimiser les risques potentiels liés à leur usure ou à leur défaillance. Il veille à ce que les pneus des véhicules (i.e. tracteurs et remorques) soient régulièrement inspectés pour détecter tout signe d'usure (en utilisant des jauges de profondeur cf. Figure V-4), de dommage ou de détérioration. Des vérifications visuelles et physiques sont alors effectuées pour s'assurer que les pneus sont en bon état et qu'ils répondent aux normes de sécurité requises (i.e. respect de l'usure maximale tolérée). Ce stakeholder met en place un programme de maintenance préventive pour les pneus, comprenant des actions telles que la rotation régulière des pneus, le contrôle de la pression d'air, l'équilibrage et l'alignement des roues. Ces mesures contribuent à prolonger la durée de vie des pneus et à prévenir les problèmes potentiels (i.e.

l'éclatement d'un pneu). Il veille aussi à ce qu'il y ait toujours des pneus de secours disponibles en cas de besoin urgent de remplacement. Il est également chargé de demander l'approvisionnement de nouveaux pneus, en avance, en communiquant des demandes d'achat au « **Responsable du stock** ».

- Le **stakeholder** « **Responsable du stock** » assure l'approvisionnement en pneus pour la flotte de véhicule. Il est chargé de maintenir des niveaux de stock appropriés. Il doit évaluer, conjointement avec le stakeholder « **Responsable de maintenance** » et les responsables d'exploitation, les besoins en pneus en tenant compte des spécificités des véhicules, des distances de transport, des conditions de route et des réglementations en matière de sécurité. La gestion efficace des stocks assure la disponibilité des pneus nécessaires, minimisant ainsi les risques de pénurie ou de retards dans les opérations de transport.



*Figure V-4: Exemple de jauge d'usure pour pneus*

### **I-1-3/ Etape 3 : Détermination des besoins pour chaque stakeholder**

Cette étape repose sur la détermination du flux out<sub>i</sub><sup>n</sup> (cf. Figure III-9) permettant aux différents stakeholders de mener à bien leurs activités.

**Besoin 1 associé au stakeholder « Responsable du stock » :** Ce besoin concerne la détermination d'un seuil kilométrique pour le remplacement des pneus. Ainsi, le responsable du stock peut programmer des alertes de stock faible et s'assurer d'avoir un stock suffisant avant que les pneus n'atteignent la fin de leur durée de vie. Pour ce faire, ce stakeholder a besoin d'exploiter les informations relatives à l'utilisation des pneus et d'établir une planification d'approvisionnement (i.e. élaborer des demandes d'achat). En déterminant l'usure moyenne des pneus, il prédit leur durée de vie restante. Cela garantit que des nouveaux pneus soient disponibles avant que les pneus en cours d'utilisation ne soient complètement usés.

**Besoin 2 associé au stakeholder « responsable de la maintenance » :** Ce besoin concerne l'amélioration de la durée de vie des pneus en élaborant des recommandations de permutation des pneus. Des instructions précises (i.e. des règles) peuvent être générées selon le type de dégradation des pneus pour déplacer les pneus d'une position à une autre sur le véhicule, en tenant compte de l'état de la dégradation des pneus (voir Figure V-5) et des schémas recommandés de permutation (voir Figure V-6). Cela permet de garantir une usure plus uniforme et une meilleure durée de vie des pneus.

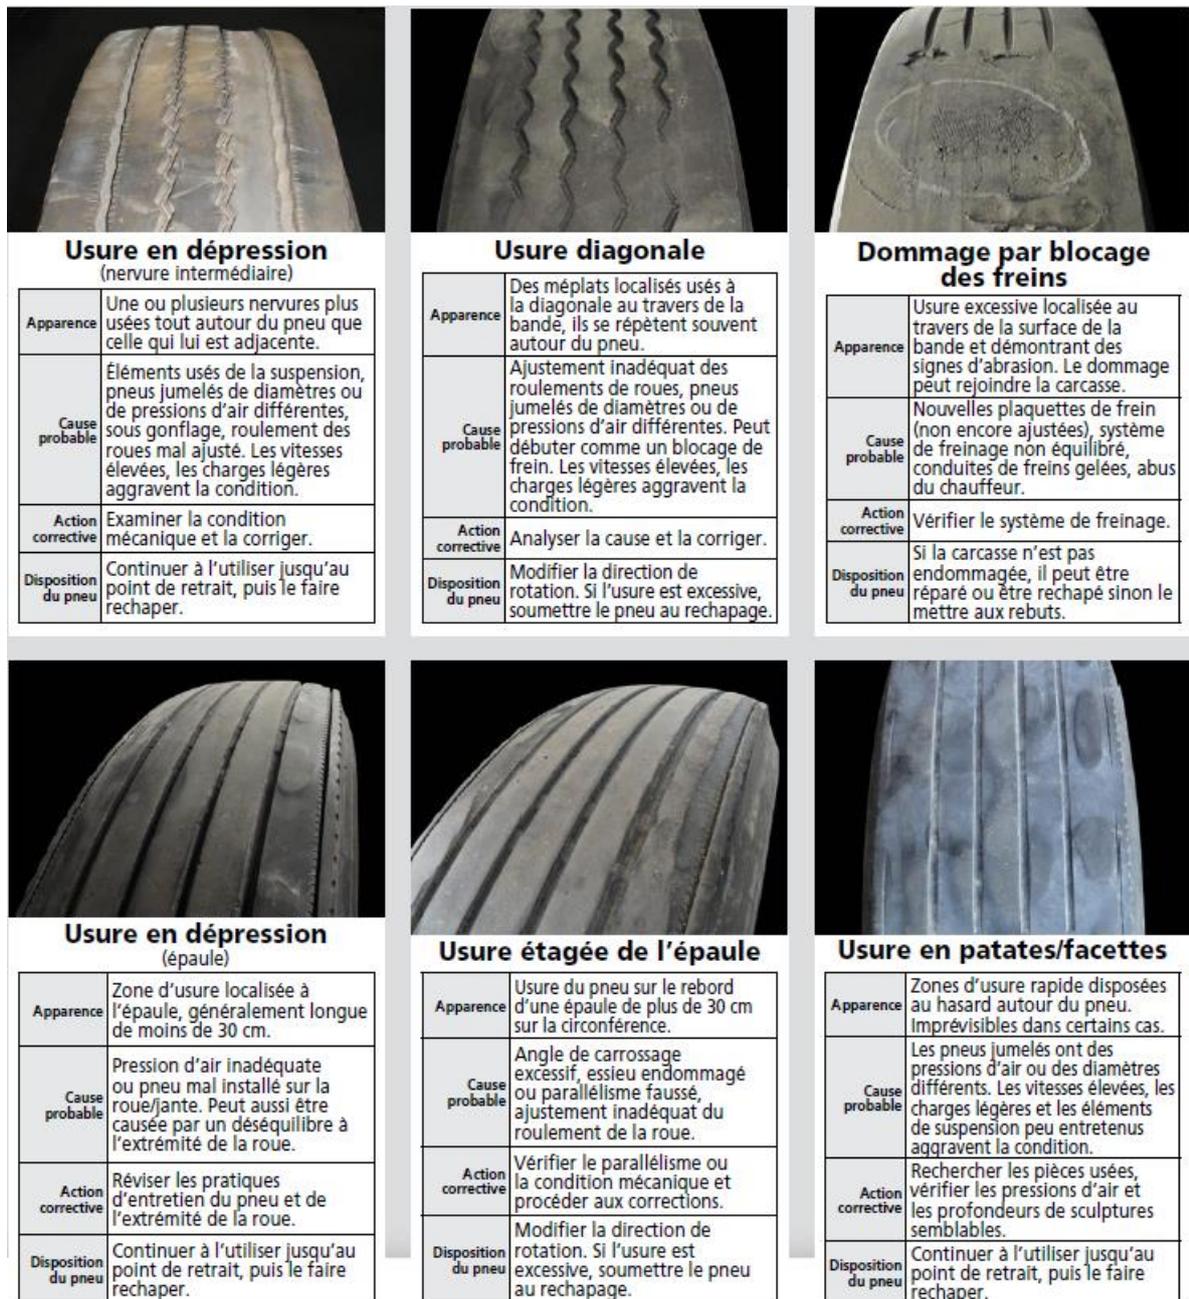


Figure V-5: Les différents types d'usure sur essieux remorque

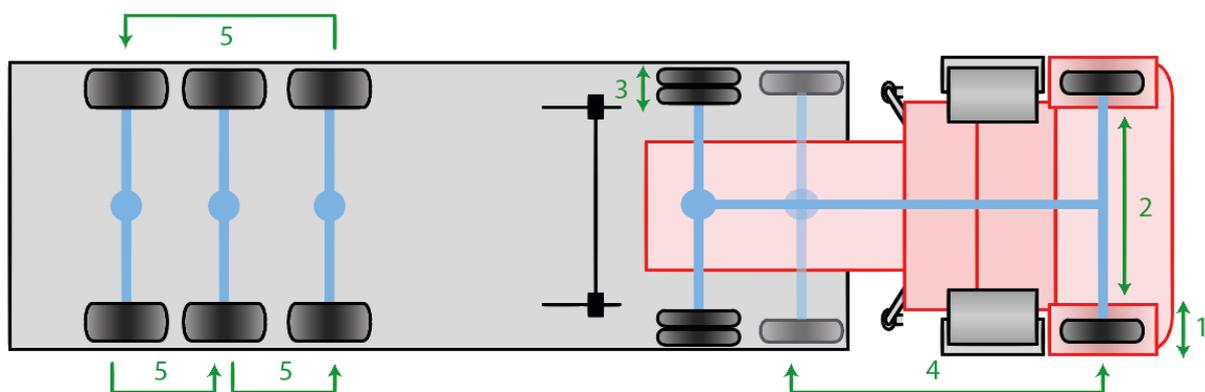


Figure V-6: Les stratégies de permutation possibles

Comme explicité à la figure V-6, plusieurs stratégies de permutation des pneus sont possibles :

**(1) La rotation des pneus sur les jantes**, tout en maintenant leur position sur le véhicule, est une pratique courante qui contribue à lutter contre l'usure unilatérale de l'épaulement et peut également être bénéfique dans des applications où les pneus sont susceptibles de subir une usure excessive des flancs ou des abrasions.

**(2) Permuter le pneu de droite et celui de gauche sur le même essieu** permet d'égaliser les effets des taux d'usure résultant des caractéristiques de la route telles que le carrossage ou les abrasions des flancs causées par les trottoirs (généralement dans le cas des missions en milieu urbain).

**(3) Permuter les pneus extérieurs et intérieurs** égalise l'usure entre les pneus jumelés et amène le flanc externe à l'intérieur.

**(4) Permuter les pneus d'un essieu à un autre** maximise la durée de vie des pneus entre le premier et le deuxième essieu de direction pour les tracteurs 6x2 où les différences de forces de virage entraînent des taux d'usure plus élevés sur l'essieu directeur. Cette stratégie est aussi appliquée pour permuter un pneu avec un autre pneu du même essieu ou autre essieu de la remorque. Le cas de la permutation des pneus de direction ne concerne pas STMF qui exploite une flotte de tracteur avec un seul essieu de direction. Par contre la permutation entre pneus de la remorque est possible.

**(5) Permuter les pneus de la remorque** de l'essieu 1 ( $V_{111}$ ) vers l'essieu 3 ( $V_{113}$ ), de l'essieu 3 ( $V_{113}$ ) vers l'essieu 2 ( $V_{112}$ ) et de l'essieu 2 ( $V_{112}$ ) vers l'essieu 1 ( $V_{111}$ ) maximise la durée de vie et la résistance à l'usure irrégulière sur l'ensemble des essieux de la remorque.

Les prochaines sections sont consacrées à une analyse des fonctions secondaires relatives aux deux besoins identifiés. Pour chacune d'elles, trois parties sont considérées :

- Une première partie présente la continuité de l'application du guide méthodologique (étapes de 4 à 8) et caractérise :
  - o La nature de l'activité et des décisions en s'appuyant sur la typologie de Rasmussen SRK.
  - o Les éléments informationnels statiques et dynamiques.
  - o Les mesures réalisées au niveau du produit et de son contexte.
- Une seconde partie présente la génération de l'assistance décisionnelle relative à cette fonction secondaire en appliquant les concepts exposés dans le chapitre 4.
- Une dernière partie détaille l'exploitation de l'assistance décisionnelle et la coopération Humain-Cyber-Physique à travers l'architecture SHCP proposée dans le chapitre 3.

## **I-2/ Itération sur besoin 1**

### **I-2-1/ Analyse de la fonction secondaire liée au besoin 1**

#### **I-2-1-1/ Étape 4 : Identification de la catégorie associée à la boucle cybernétique**

Il s'agit d'une activité de type « Surveillance » visant à déterminer le seuil kilométrique (i.e. nombre de kilomètres qu'un pneu parcourt avant sa fin de vie) qui déclenche la demande d'achat d'un pneu.

### **I-2-1-2/ Etape 5 : Caractérisation de l'activité décisionnelle**

Le niveau décisionnel de cette fonction secondaire est de type « Reactive-based » ; comme décrit dans le logigramme (Figure V-7) dès le seuil kilométrique atteint, une notification est envoyée au stakeholder « Responsable de Stock ».

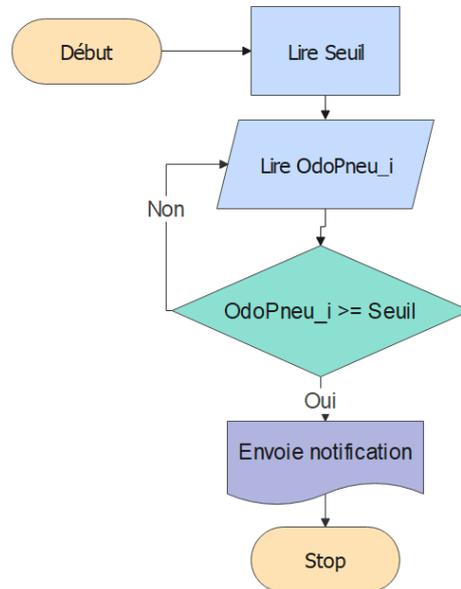


Figure V-7: Logigramme décrivant l'activité reactive-based du Besoin 1 STMF

### **I-2-1-3/ Etape 6 : Caractérisation de l'assistance décisionnelle**

L'assistance décisionnelle qui doit être développée est de type « prédictif ». Elle répond à la question "Ce qui pourrait se passer" avec une projection dans le futur.

### **I-2-1-4/ Etape 7 : Caractérisation du partage d'activités Humain / Machine**

Le modèle AADA (Figure V-8) décrit le partage d'activités entre l'Humain et la Machine. Ce modèle sera enrichi par le modèle SRK et DIK dans la section "Phase d'exploitation".

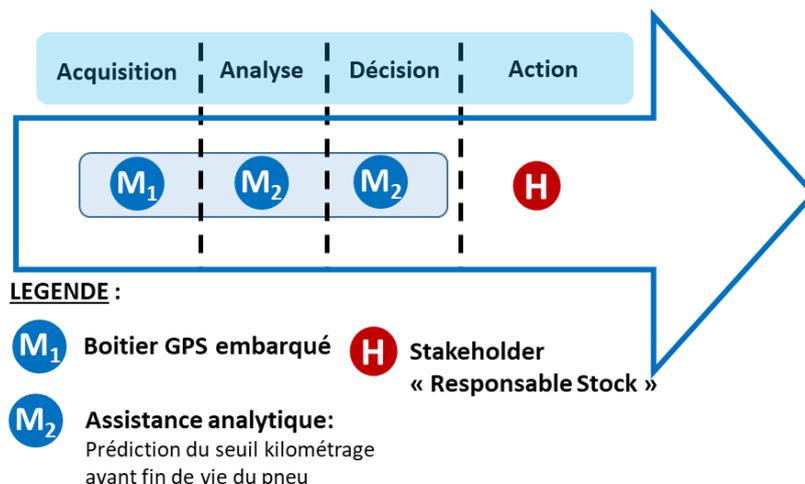


Figure V-8: Modèle AADA pour le Besoin 1

### **I-2-1-5/ Etape 8 : Description des éléments informationnels**

Les données statiques (issues d'un historique) et dynamiques sont respectivement représentées par les deux tables suivantes :

### Eléments informationnels statiques :

NIVEAUX DU MODELE DIK	DONNEES STATIQUES UTILISEES
KNOWLEDGE (K)	Pas utilisée
INFORMATION (I)	Etat général des routes de la région à livrer, le profil du conducteur du véhicule, date d'attachement et détachement des pneus, la saison
DATA (D)	L'identifiant du véhicule, l'identifiant du pneu

### Eléments informationnels dynamiques :

NIVEAUX DU MODELE DIK	DONNEES DYNAMIQUES UTILISEES
KNOWLEDGE (K)	Pas utilisé
INFORMATION (I)	Pas utilisé
DATA (D)	La géolocalisation du véhicule, l'odomètre des pneus

#### **I-2-2/ La génération de l'assistance décisionnelle relative au besoin 1**

Cette partie concerne la préparation des données et le développement du modèle (i.e. la conception de l'assistance décisionnelle). Le besoin du stakeholder « responsable de stock » au sein de STMF ne nécessite pas forcément l'intervention des experts en data analytics pour faire un travail d'analyse de donnée et d'élaboration des modèles prédictifs très poussés. De ce fait, l'approche AutoML, présentée dans le chapitre 4, est adoptée. Dans une première partie la préparation des données est présentée, par la suite, les différents paramétrages et configuration du modèle AutoML sont décrits et finalement les résultats sont exposés.

#### **I-2-2-1/ Le jeu de données**

	Marque	Marque pneu	Date attachement	Date dettachement	Saison (Environnement)	Formation chauffeurs	Trajets/mission	Odometre
0	1	Dunlop	42405	42669	1	1	1	73472
1	1	Dunlop	42669	42911	4	1	1	81326
2	1	Dunlop	42911	43322	4	1	1	78554
3	2	goodyear	43322	43733	4	1	1	106130
4	3	general	43733	44013	4	1	1	92463
5	3	general	44013	0	4	1	1	53695
6	4	Michelin	42527	42911	4	1	1	115420
7	3	General	43979	0	2	1	1	57698
8	3	General	43733	0	3	1	1	48963

*Figure V-9: Extrait de la base de données historique des interventions montage/démontage des pneus*

Le jeu de données concerne l'historique des montages et démontages des pneus au sein des différents véhicules de la flotte STMF entre 2016 et 2020. Les attributs, présentés à la Figure V-9, pris en considération dans l'étude sont la marque, la date d'attachement et de détachement, la saison durant laquelle se déroulait l'attachement, le nombre de formations reçues par les chauffeurs, le type de trajet et l'odomètre relevé lors du montage. Les données collectées au niveau « embarqué » sont fusionnées avec les données des systèmes d'information au niveau « distant » (formation du conducteur, marque, date de montage des pneus...).

### I-2-2-2/ Préparation des données :

Les données historiques des interventions sur les pneus sont saisies dans une application dédiée et stockées dans une base de données MySQL. La partie nettoyage des données et imputation des données manquantes n'est pas nécessaire dans ce cas applicatif puisque le système informatique exigeait la saisie complète des différentes informations relatives aux ordres de maintenance effectués.

### I-2-2-3/ Développement du modèle

FLAML (C. Wang et al. 2019) est une bibliothèque Python, libre de droit, conçue pour automatiser efficacement les opérations de Machine Learning (AutoML), notamment la sélection de modèles et leurs hyperparamètres. La bibliothèque FLAML est utilisée pour concevoir un modèle prédictif de régression pour estimer le nombre de kilomètres parcourus par un pneu avant d'atteindre sa fin de vie. Pour cela, trois exigences sont à remplir avant le lancement de l'auto-apprentissage.

**La source de données :** La source de données sera le jeu de données présenté dans la section précédente.

**Le critère d'optimisation :** Le coefficient de détermination  $R^2$  (R-carré) est retenu pour comparer les différents algorithmes proposés par l'AutoML.

**La contrainte en termes de temps :** Le besoin 1 du stakeholder « responsable de stock » n'est pas considéré comme une urgence, donc la contrainte de la durée d'exécution de l'AutoML peut prendre des valeurs maximales pour obtenir des résultats pertinents.

La Figure V-10 résume la configuration simplifiée du processus AutoML. La Figure V-11 présente la configuration de la bibliothèque FLAML.

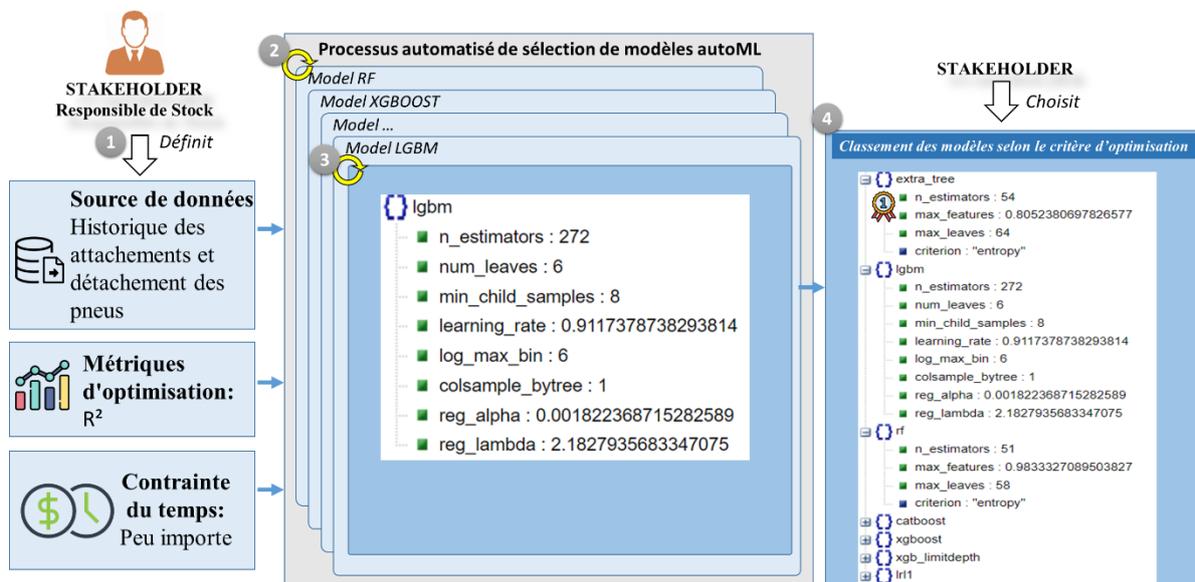


Figure V-10: Illustration du paramétrage AutoML selon le besoin 1 du cas applicatif STMF

```

from flaml import AutoML
from sklearn.datasets import load_iris
import pandas as pd
from sklearn.model_selection import train_test_split

# Initialize an AutoML instance
automl = AutoML()
# Specify automl goal and constraint
automl_settings = {
    "time_budget": 60, # in seconds
    "metric": 'r2',
    "task": 'regression',
    "log_file_name": "STMF_Reg.log",
}

df = pd.read_csv("data pneu stmf v5.csv")
# 'Date attachement'
columns = ['Marque', 'Date attachement', 'Saison (Environnement)', 'Formation chauffeurs', 'Trajets/mission']

labels = df['Odometre'].values
features = df[list(columns)].values

X_train, X_test, y_train, y_test = train_test_split(features, labels, test_size=0.60)

#X_train, y_train = fetch_california_housing(return_X_y=True)

# Train with labeled input data
automl.fit(X_train=X_train, y_train=y_train,
          **automl_settings)
# Predict
print(automl.predict(X_train))
#print ('Meilleur modele:')
print(automl.model.estimator)

```

Figure V-11: Code associé au développement du modèle AutoML pour le besoin 1

#### I-2-2-4/ Résultats

L’algorithme « Extra\_tree » est classé premier selon le critère d’optimisation R<sup>2</sup>. En plus de ce classement, l’outil AutoML FLAML donne le meilleur hyper-paramétrage associé au jeu de donnée de l’étude. Le Tableau V-1 présente l’hyper-paramétrage de l’algorithme Extra\_tree.

n_estimators	max_features	max_leaves
5	0.4068	6

Tableau V-1: Hyper-paramétrage optimal de l’algorithme Extra\_tree

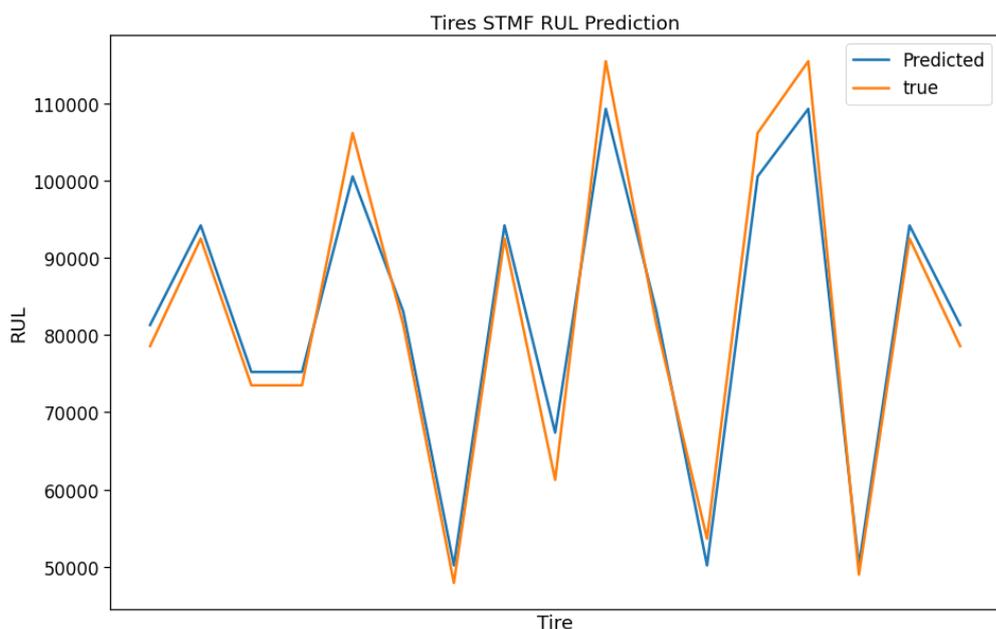


Figure V-12: Comparaison entre les données réelles et les données prédites avec le modèle proposé par le processus AutoML

Avec un score de 97%, le modèle proposé par l'approche AutoML est considéré comme très pertinent. La Figure V-12 présente une comparaison visuelle des données réelles avec celles prédites.

### I-2-3/ L'exploitation de l'assistance décisionnelle et la coopération Humain-Système-Cyber-Physique relative au besoin 1

Dans cette phase d'exploitation et comme explicité à la Figure V-13, en se référant au modèle AADA, les phases (i.e. Acquisition, Analyse, et Décision) sont prises en charge par une « machine », tandis que l'action est confiée au stakeholder même :

- L'acquisition des éléments informationnels dynamiques : La géolocalisation des véhicules est assurée par un boîtier GPS installé à bord des véhicules et qui fournit la longitude et la latitude de ce dernier, ainsi un odomètre prévisionnel est établi. Une fois le véhicule revenu d'une mission, une inspection systématique relève l'odomètre exact du tableau de bord du véhicule et valide celui du pneu.
- L'analyse des données est effectuée par l'assistance décisionnelle développée. La sortie de cette phase est le seuil kilométrique maximal avant la fin de vie d'un pneu.
- La décision, de type « reactive-based », est prise automatiquement, sans intervention humaine, dès que l'odomètre actuel d'un pneu atteint le seuil kilométrique. Une alarme est alors envoyée au stakeholder (i.e. le responsable de stock) afin de préparer la demande d'achat.
- L'action est confiée au stakeholder qui élabore et envoie la demande d'achat au fournisseur approprié.

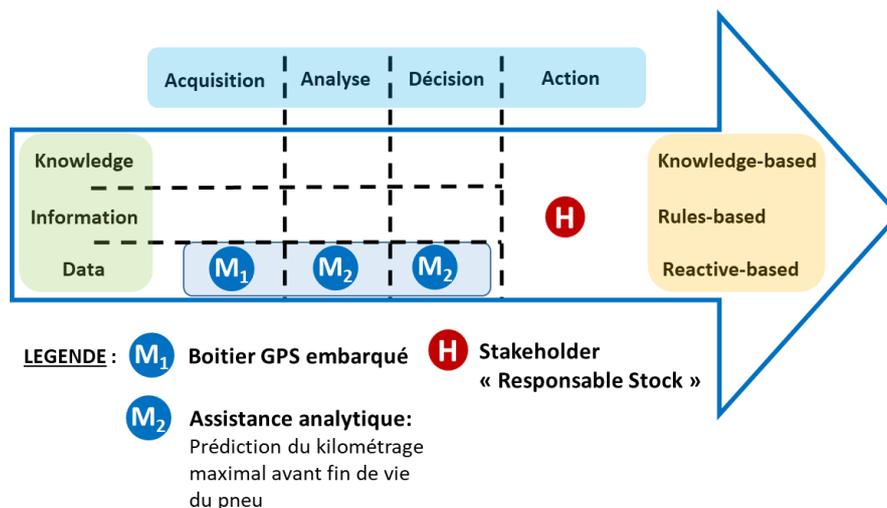


Figure V-13: Modèle SHCP relatif au besoin 1

### **I-3/ Itération sur besoin 2**

Comme expliqué précédemment dans l'étape 3 de l'application du guide méthodologique, les permutations ne peuvent pas être effectuées entre deux types différents de pneus. Pour cette raison, la suite de l'étude ne concernera que les trois essieux de la remorque qui sont du même type.

#### **I-3-1/ Analyse de la fonction secondaire liée au besoin 2**

##### **I-3-1-1/ Etape 4 : Identification de la catégorie associée à la boucle cybernétique**

Il s'agit d'une activité de type « Amélioration » visant à améliorer l'exploitation du pneu en maximisant sa durée de vie utile.

##### **I-3-1-2/ Etape 5 : Caractérisation de l'activité décisionnelle**

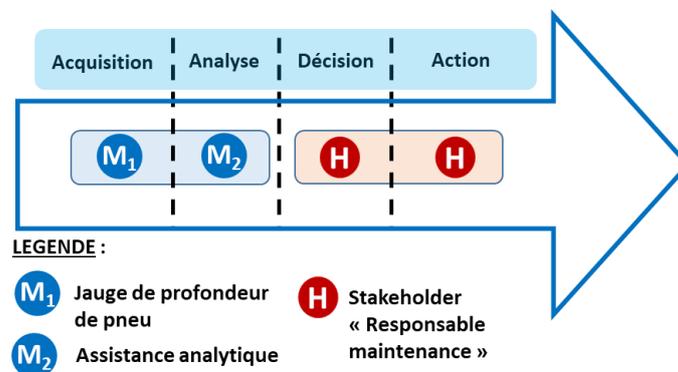
Le niveau décisionnel de cette fonction secondaire est de type « Rule-based ». La prise de décision (i.e. la nouvelle position du pneu dégradé) est procédurale. Elle devra être prise en considérant une suite de règles tenant compte de la position actuelle du pneu, de son état et de l'état des différents essieux.

##### **I-3-1-3/ Etape 6 : Caractérisation de l'assistance décisionnelle**

L'assistance décisionnelle qui doit être développée est de type prescriptif. Elle identifie les résultats possibles et présente la meilleure option. Elle répond à la question "quelle devrait être la prochaine position optimale du pneu pour l'exploiter au maximum ?".

##### **I-3-1-4/ Etape 7 : Caractérisation du partage d'activités Humain / Machine**

Le modèle AADA (Figure V-14) décrit le partage d'activités entre le stakeholder « Responsable maintenance » et les entités artificielles M<sub>1</sub> et M<sub>2</sub>.



*Figure V-14: Modèle AADA pour le besoin 2*

##### **I-3-1-5/ Etape 8 : Description des éléments informationnels**

Dans cette section les données statiques et les données dynamiques utilisées sont successivement présentées.

Éléments informationnels statiques :

NIVEAUX DU MODELE DIK	DONNEES STATIQUES UTILISEES
KNOWLEDGE (K)	Pas utilisée
INFORMATION (I)	Type du pneu (i.e. pneu de direction, traction ou remorque) Position des pneus
DATA (D)	L'identifiant du véhicule L'identifiant du pneu Taux d'usure par kilomètre Ecart minimal d'usure dans un même essieu Ecart minimal entre les essieux Profondeur initiale d'un pneu neuf Profondeur minimale d'un pneu avant remplacement

Éléments informationnels dynamiques :

NIVEAUX DU MODELE DIK	DONNEES DYNAMIQUES UTILISEES
KNOWLEDGE (K)	Pas utilisé
INFORMATION (I)	Etat des pneus (i.e. profondeur des sculptures du pneu) Etat des essieux
DATA (D)	La géolocalisation du véhicule L'odomètre des pneus

**I-3-2/ La génération de l'assistance décisionnelle relative au besoin 2**

Comme dans le cas du besoin 1, le stakeholder « responsable de maintenance » n'est pas un expert en analyse de donnée. Aussi, l'intervention d'un expert en data analytics n'est pas privilégiée dans un premier temps et l'approche AutoML est utilisée. Les différents paramétrages de la génération de l'assistance sont présentés par la suite.

**I-3-2-1/ Le jeu de données**

	id	etat essieu avant	etat essieu central	etat essieu arriere	ecart essieu avant	ecart essieu central	ecart essieu arriere	decision	
	0	1	2.783760	12.000000	6.806023	0.023314	0.000000	10.387954	PERMU_E
	1	2	2.902080	12.000000	7.241880	0.027394	0.000000	9.516240	PERMU_E
	2	3	2.751437	12.000000	2.024983	0.060909	0.000000	0.646474	PERMU_E
	3	4	2.725663	12.000000	6.881820	0.020674	0.000000	10.236360	PERMU_E
	4	5	2.900246	12.000000	6.912900	0.001337	0.000000	10.174200	PERMU_E
	...	...	...	...	...	...	...	...	...
	1646	1572	7.790134	4.767960	4.211391	8.022703	0.377743	4.354217	PERMU_E
	1647	1573	4.460507	4.020283	4.453213	3.805226	1.601280	4.294877	PERMU_X
	1648	1574	3.269250	3.154093	3.463586	2.653500	1.394974	2.413971	PERMU_X
	1649	1575	4.945573	2.919433	3.879724	0.205071	1.008746	1.178443	PERMU_E
	1650	1576	3.889251	1.862850	5.896599	0.029777	0.231009	0.428631	PERMU_E

*Figure V-15: Extrait de la base de données historique des interventions de permutation des pneus*

Le jeu de données concerne l'historique des interventions de permutation des pneus qui ont donné les meilleures performances en termes de consommation de pneus sur un horizon d'un an. La première catégorie des attributs, pris en considération dans l'étude et présentés dans la Figure V-15, concerne les états des essieux. L'état d'un essieu est la moyenne de la profondeur actuelle de la bande de roulement des pneus des deux côtés de l'essieu en question. La deuxième catégorie concerne l'écart d'usure entre les deux pneus d'un même essieu. Les états et écarts des essieux avant, central et arrière sont considérés. La dernière catégorie est la variable cible qui est la décision à prendre. Deux stratégies de permutations sont considérées. PERMU\_X qui combine la stratégie (2) et (4) (cf. Figure V-6). Cette décision consiste à identifier un pneu avec une usure importante et à le permuter avec un autre pneu (i.e. l'autre pneu du même essieu ou d'un autre essieu) tout en respectant l'écart d'usure dans un même essieu. PERMU\_E fait référence à la stratégie de permutation (5). Elle consiste à permuter les pneus de l'essieu avant avec ceux de l'essieu arrière, les pneus de l'essieu arrière avec ceux de l'essieu central et les pneus de ce dernier avec ceux de l'essieu avant.

#### **I-3-2-2/ Préparation des données :**

Comme pour le besoin 1, les données historiques des interventions sur les pneus sont saisies dans une application dédiée et stockées dans une base de données MySQL. La partie nettoyage des données et imputation des données manquantes n'est pas nécessaire dans ce cas applicatif.

#### **I-3-2-3/ Développement du modèle**

La bibliothèque FLAML est utilisée pour concevoir un modèle prédictif de classification afin de générer un arbre de décision à exploiter dans l'assistance décisionnelle. Trois exigences sont à remplir avant le lancement de l'auto-apprentissage.

**La source de données :** La source de données sera le jeu de données présenté dans la section précédente.

**Le critère d'optimisation :** La précision (i.e. Accuracy) est retenue pour comparer les différents algorithmes proposés par l'AutoML.

**La contrainte en termes de temps :** Ce besoin 2 du stakeholder « responsable de maintenance » s'exprime à chaque retour de mission. Le stakeholder doit alors prendre une décision de permutation rapidement afin de réserver les ressources humaines adéquates pour effectuer les permutations de pneus. La contrainte de la durée d'exécution de l'AutoML est ici fixée à 2 minutes.

La Figure V-16 résume la configuration simplifiée du processus AutoML. La Figure V-17 présente la configuration de la bibliothèque FLAML.

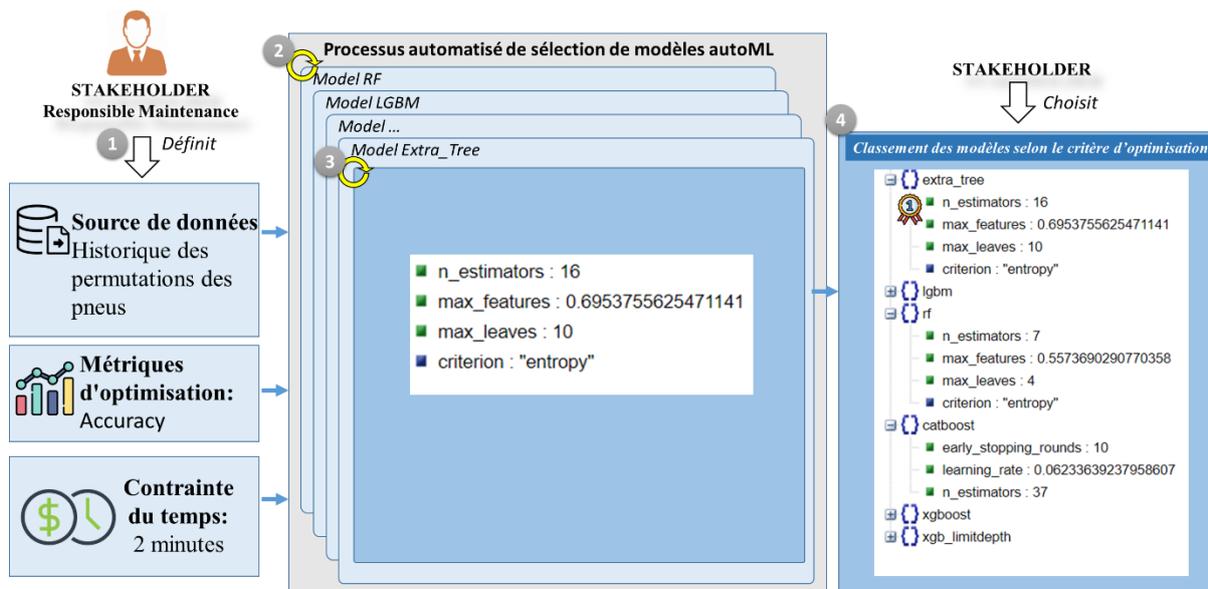


Figure V-16: Illustration du paramétrage AutoML pour le besoin 2 du cas applicatif STMF

```

from flaml import AutoML
from sklearn.datasets import load_iris
import pandas as pd
from sklearn.model_selection import train_test_split

# Initialize an AutoML instance
automl = AutoML()
# Specify automl goal and constraint
automl_settings = {
    "time_budget": 120, # in seconds
    "metric": 'accuracy',
    "task": 'classification',
    "log_file_name": "STMF_Classi.log",
}

df = pd.read_csv("Histo_Permuv12.csv")
# 'Date attachement'
columns = ['etat essieu avant', 'etat essieu central', 'etat essieu arriere', 'ecart essieu avant', 'ecart essieu central', '

labels = df['decision'].values
features = df[list(columns)].values

X_train, X_test, y_train, y_test = train_test_split(features, labels, test_size=0.60)

#X_train, y_train = fetch_california_housing(return_X_y=True)

# Train with labeled input data
automl.fit(X_train=X_train, y_train=y_train,
          **automl_settings)
# Predict
print(automl.predict(X_train))
#Print ('Meilleur modele:')
print(automl.model.estimator)

```

Figure V-17: Code associé au développement du modèle autoML pour le besoin 2

### I-3-2-4/ Résultats

L'algorithme « Extra\_tree » est classé premier selon le critère d'optimisation Accuracy. Le meilleur hyper-paramétrage associé au jeu de donnée de l'étude est présenté dans le Tableau V-2.

n_estimators	max_features	max_leaves	criterion
16	0.6953	10	entropy

Tableau V-2: Hyper-paramétrage optimal de l'algorithme Extra\_tree pour le besoin 2

Le Tableau V-3 présente la matrice de confusion associée au jeu de données de test ( 50% du jeu de données initial). Les différents critères d'évaluation sont comparés dans le Tableau V-4.

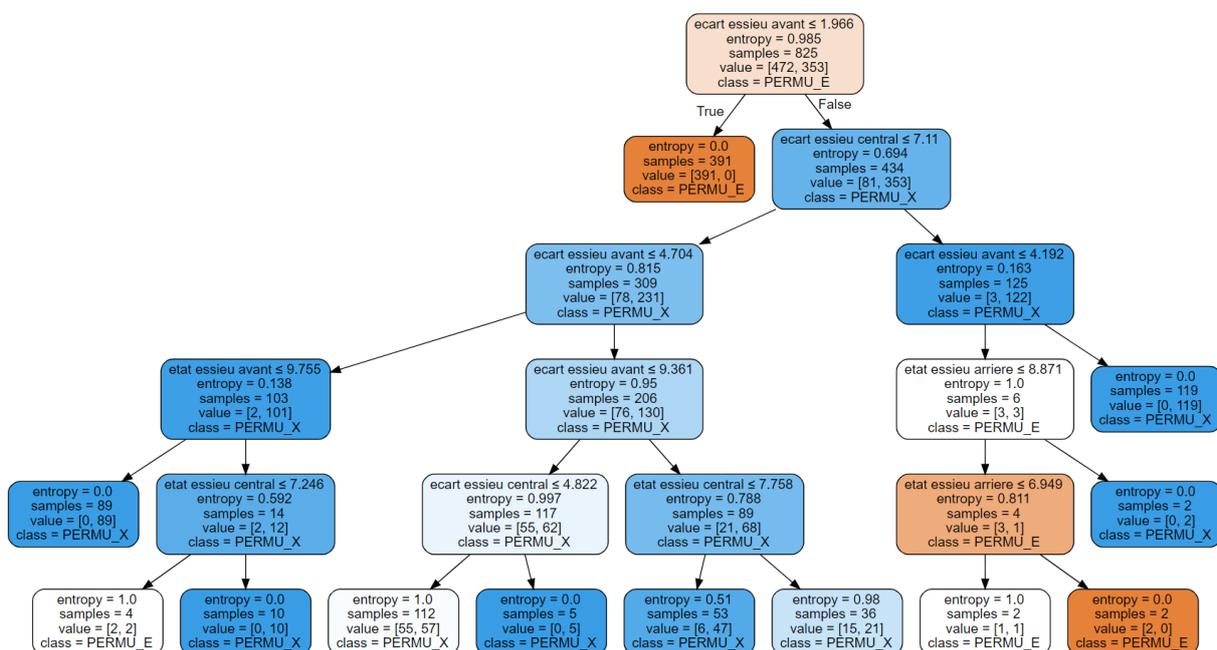
Avec une Accuracy de 90%, l'arbre de décision développé peut être considéré comme très pertinent. Dans la section suivante, son exploitation montrera son efficacité pour améliorer la durée de vie des pneus. La Figure V-18 présente l'arbre de décision généré et un extrait des règles procédurales déduites de cet arbre.

	Actuel Positif	Actuel Négatif
Prédit Positif	370	75
Prédit Négatif	3	378

Tableau V-3: Matrice de confusion associé au besoin 2

	Précision	Recall	F1-Score	Support
PERMU_X	0.99	0.83	0.90	445
PERMU_E	0.83	0.99	0.91	381

Tableau V-4: Comparaison entre les critères d'évaluation



1. Si l'écart d'usure entre les pneus du même **essieu avant** est **inférieur ou égal à 1,966**, alors la classe est "**PERMU\_E**" (probabilité : 100%) basée sur 391 échantillons.
2. Si l'écart d'usure entre les pneus du même **essieu avant** est **supérieur à 1,966**, l'écart d'usure entre les pneus du même **essieu central** est **supérieur à 7,11**, et l'écart d'usure entre les pneus du même **essieu avant** est **supérieur à 4,192**, alors la classe est "**PERMU\_X**" (probabilité : 100%) basée sur 119 échantillons.
3. Si l'écart d'usure entre les pneus du même **essieu avant** est **supérieur à 1,966**, l'écart d'usure entre les pneus du même **essieu central** est **inférieur ou égal à 7,11**, l'écart d'usure entre les pneus du même **essieu avant** est **supérieur à 4,704** mais **inférieur ou égal à 9,361**, et l'écart d'usure entre les pneus du même **essieu central** est **inférieur ou égal à 4,822**, alors la classe est "**PERMU\_X**" (probabilité : 50,89%) basée sur 112 échantillons.
4. Si l'écart d'usure entre les pneus du même **essieu avant** est **supérieur à 1,966**, l'écart d'usure entre les pneus du même **essieu central** est **inférieur ou égal à 7,11**, l'écart d'usure entre les pneus du même **essieu avant** est **inférieur ou égal à 4,704**, et l'état des pneus du même **essieu avant** est **inférieur ou égal à 9,755**, alors la classe est "**PERMU\_X**" (probabilité : 100%) basée sur 89 échantillons.
5. Si l'écart d'usure entre les pneus du même **essieu avant** est **supérieur à 1,966**, l'écart d'usure entre les pneus du même **essieu central** est **supérieur à 7,11**, l'écart d'usure entre les pneus du même **essieu avant** est **inférieur ou égal à 4,192**, l'état des pneus du même **essieu arrière** est **inférieur ou égal à 8,871**, et l'état des pneus du même **essieu arrière** est **supérieur à 6,949**, alors la classe est "**PERMU\_E**" (probabilité : 100%) basée sur 2 échantillons.

Figure V-18: L'arbre de décision généré et extrait des règles

### I-3-3/ L'exploitation de l'assistance décisionnelle et la coopération Humain-Système- Cyber-Physique relative au besoin 2

Dans cette phase d'exploitation et comme explicité dans la Figure V-19, en se référant au modèle AADA, les phases Acquisition et Analyse sont prises en charge par les entités artificielles « M<sub>1</sub> » et « M<sub>2</sub> », tandis que la Décision et l'Action sont confiées au stakeholder même :

- L'acquisition concerne les éléments informationnels dynamiques : A chaque fois qu'un véhicule rentre d'une mission, une inspection systématique est effectuée. Lors de cette dernière, la profondeur de la bande de roulement des pneus (i.e. sculptures) est mesurée à l'aide d'une jauge électronique. L'odomètre du véhicule est aussi relevé et sa valeur mise à jour dans la base de données.
- L'analyse des données est effectuée par l'assistance décisionnelle développée. La sortie de cette phase (i.e. out<sub>i</sub><sup>n</sup>) consiste en un arbre décisionnel contenant les différentes règles et conditions procédurales à suivre pour prendre une décision de permutation. L'assistance décisionnelle propose (i.e. « prescrit ») des stratégies de permutation selon la situation actuelle.
- La décision, de type « rule-based », est prise par le stakeholder en appliquant les règles générées par l'assistance. Les pneumatiques des véhicules étant des éléments cruciaux au niveau sécuritaire, il est donc de sa responsabilité d'appliquer ou non une recommandation proposée par l'assistance décisionnelle.
- L'action est confiée au stakeholder « responsable de la maintenance » qui élabore l'ordre de maintenance à exécuter par les mécaniciens pour la permutation des pneus.

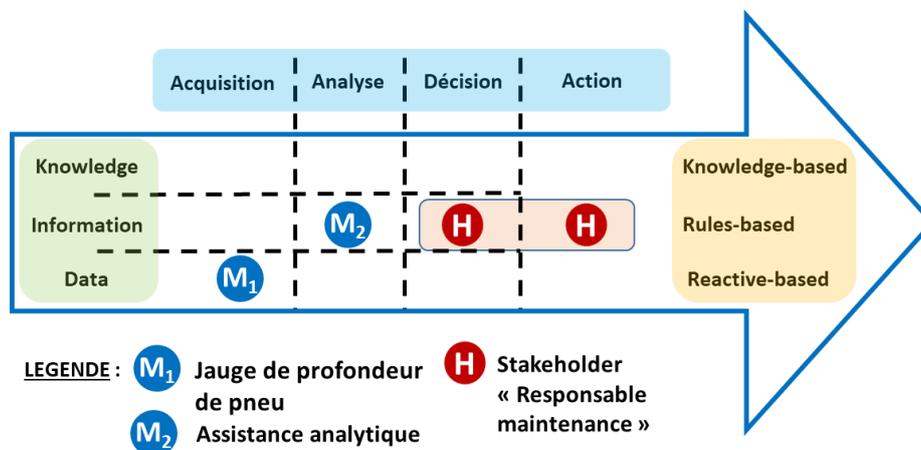


Figure V-19: Modèle HCP relatif au besoin 2

### I-3-4/ Expérimentation de l'assistance décisionnelle

La durée de vie d'un pneu pouvant aller jusqu'à 2 ans rend difficile l'évaluation de l'assistance décisionnelle générée dans l'immédiat. Un modèle de simulation (Figure V-20) à base de système multi-agents a donc été développé afin d'évaluer l'assistance décisionnelle selon les différentes missions au sein de STMF et la législation concernant les pneumatiques et la dégradation des pneus.

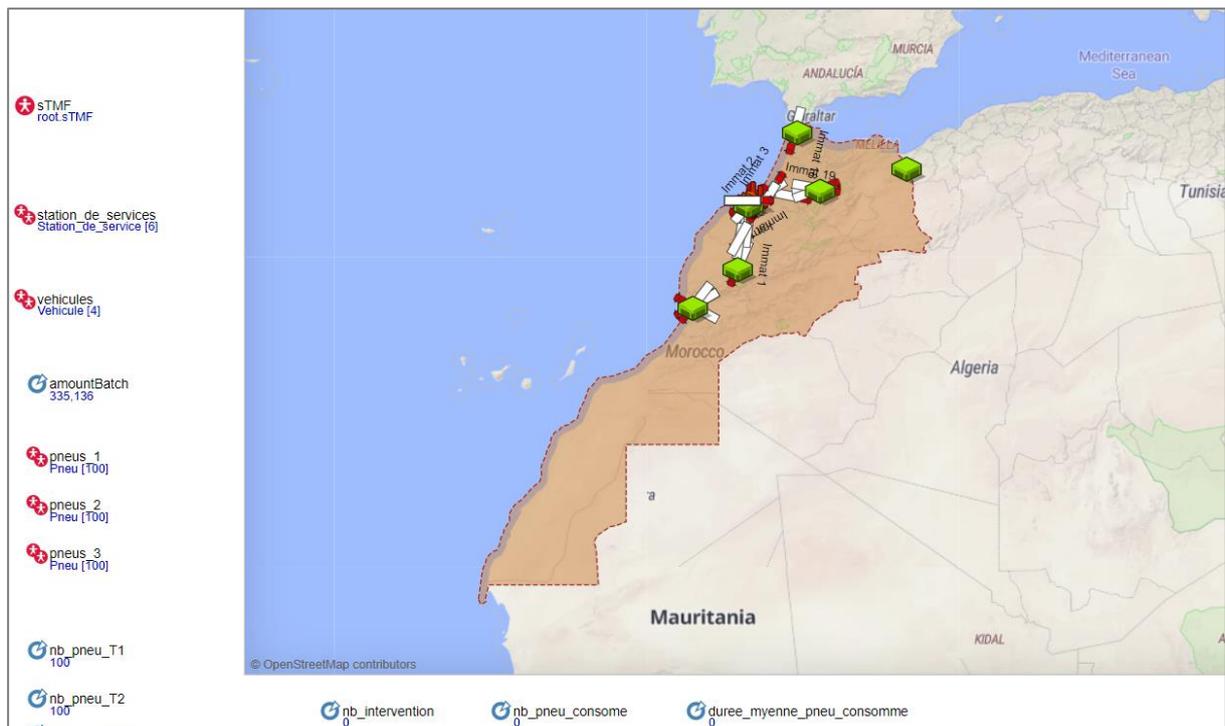


Figure V-20: Interface de l'outil de simulation

#### I-3-4-1/ Paramétrage de la simulation

Le Tableau V-5 présente les différents agents et leurs paramètres utilisés pour la simulation.

Les agents	Paramétrages	Valeurs initiales	Description
<b>Siège de STMF</b>	Coordonnées Géographiques	Ain Harrouda	Le siège de STMF se situe dans la ville de Ain Harrouda, à côté de Mohammadia
	Nombre de véhicules	20 véhicules	L'expérimentation se fait sur une sous-flotte destinée à transporter des produits H224 (i.e. Liquides et vapeurs extrêmement inflammables)
<b>Destinations à livrer</b>	Coordonnées géographiques	Casablanca, Tanger, Fès, Marrakech, Oujda, Agadir	Les différentes villes à livrer
	Fréquence des commandes	Entre 3 et 5 par semaine	Une estimation selon la fréquence réelle des commandes
<b>Commandes</b>	Quantité	Entre 1.500 et 11.000 Litres	Une estimation selon la fréquence réelle des commandes
<b>Batch de commandes</b>	Liste des commandes	Dynamique	Sera attribué au moment de la préparation des commandes
<b>Véhicule</b>	Capacité	45.000 Litres	La capacité maximale d'une citerne
	Liste pneus de direction	2 pneus de direction	Les pneus installés dans l'essieu direction
	Liste pneus de traction	4 pneus de traction	Les pneus installés dans l'essieu traction

Les agents	Paramétrages	Valeurs initiales	Description
	Liste pneus de remorque	6 pneus de remorque	Les pneus installés dans la remorque
	Kilométrage cumulé	0 km	L'odomètre du véhicule
<b>Pneus de remorque</b>	Position	Essieu avant, essieu central, essieu arrière	La position du pneu pour faciliter l'identification et la permutation
	Etat côté gauche	12 millimètres	Etat de la bande de roulement d'un côté du pneu
	Etat côté droit	12 millimètres	Etat de la bande de roulement de l'autre côté du pneu
	Marque	Michelin, Continental, Dunlop	La marque du pneu
	Kilométrage cumulé	0 km	L'odomètre du pneu

Tableau V-5: Les paramètres de la simulation

#### I-3-4-2/ Les paramètres statiques

En France comme au Maroc, les réglementations concernant les pneus et les essieux des poids lourds sont définies par le Code de la route et le Code de la sécurité routière. Les extraits concernant notre cas d'étude sont explicités ci-après.

L'usure des pneus : Les pneus des poids lourds doivent avoir une profondeur de sculpture minimale de 1,6 mm sur toute la bande de roulement. Cependant pour l'expérimentation, le seuil de remplacement des pneus est fixé à 3 mm pour assurer une meilleure adhérence et sécurité.

Permutation des pneus : Au moment de la permutation, la différence entre la profondeur des rainures principales de deux pneumatiques montés sur un même essieu ne doit pas dépasser 5 mm (Figure V-21).



Figure V-21 : La profondeur des sculptures sur un même essieu

### **I-3-4-3/ Les perturbations**

Deux types de perturbations sont considérés :

-des perturbations internes, causées par l'un des acteurs du système (i.e. Conduite agressive, dégradation du système de direction ou de suspension...). Ce type de perturbation augmente le taux de la dégradation des pneus par kilomètre de 5%.

- des perturbations externes (i.e. Etat des routes, température externe...). Ces perturbations augmentent le taux d'usure des pneus de 3%.

### **I-3-4-4/ Résultats**

Le Tableau V-6 présente les résultats de simulation, en considérant un horizon d'un an. L'utilisation de l'assistance décisionnelle développée a permis d'accroître la durée de vie des pneus de 3604 km (différence entre les scénarios 1 et 4), permettant un gain de 80 pneus en une année. Pour un coût moyen des pneus de 500 euros et un coût d'intervention moyen de 20 euros, l'utilisation de l'assistance décisionnelle engendrera un gain pour STMF d'environ 27.120 euros par année. Cette économie s'accompagne également d'une réduction de l'impact sur l'environnement en améliorant l'exploitation des pneus.

<i>SCENARIOS</i>	<i>NOMBRE DE PNEUS CONSOMMES</i>	<i>DUREE DE VIE MOYENNE DES PNEUS CONSOMMES</i>	<i>NOMBRE D'INTERVENTIONS</i>	<i>COUT</i>
<b><i>1-SANS L'ASSISTANCE DECISIONNELLE</i></b>	<b>925</b>	<b>52.773</b>	<b>932</b>	<b>481K €</b>
<b><i>2-AVEC L'ASSISTANCE DECISIONNELLE (Stratégie PERMU_E seule)</i></b>	<b>875</b>	<b>55.373</b>	<b>2064</b>	<b>478K €</b>
<b><i>3-AVEC L'ASSISTANCE DECISIONNELLE (Stratégie PERMU_X seule)</i></b>	<b>918</b>	<b>55.686</b>	<b>114</b>	<b>461K €</b>
<b><i>4-AVEC L'ASSISTANCE DECISIONNELLE (PERMU_X et PERMU_E)</i></b>	<b>845</b>	<b>56.377</b>	<b>1576</b>	<b>454K €</b>

*Tableau V-6 : Les résultats de la simulation*

La section suivante est dédiée à la présentation du second cas d'étude relatif au transport ferroviaire.

## II/ Application n°2 : Amélioration de la croissance de fiabilité pour Alstom

Alstom est l'un des principaux acteurs mondiaux de l'industrie ferroviaire et est impliqué dans la conception, la fabrication et la fourniture de systèmes de transport et d'infrastructures connexes.

Depuis de nombreuses années, les capacités d'acquisition de données à bord des trains se sont développées rapidement et parfois si vite que les responsables/utilisateurs n'arrivent pas à tirer pleinement profit de toutes les données générées par les systèmes embarqués (capteurs, calculateurs, etc.). Il en résulte une quantité massive de données, mais assez peu d'informations directement exploitables. La Figure V-22 explique le flux de traitement des données depuis leur obtention à l'état brut jusqu'à la création d'informations pertinentes.

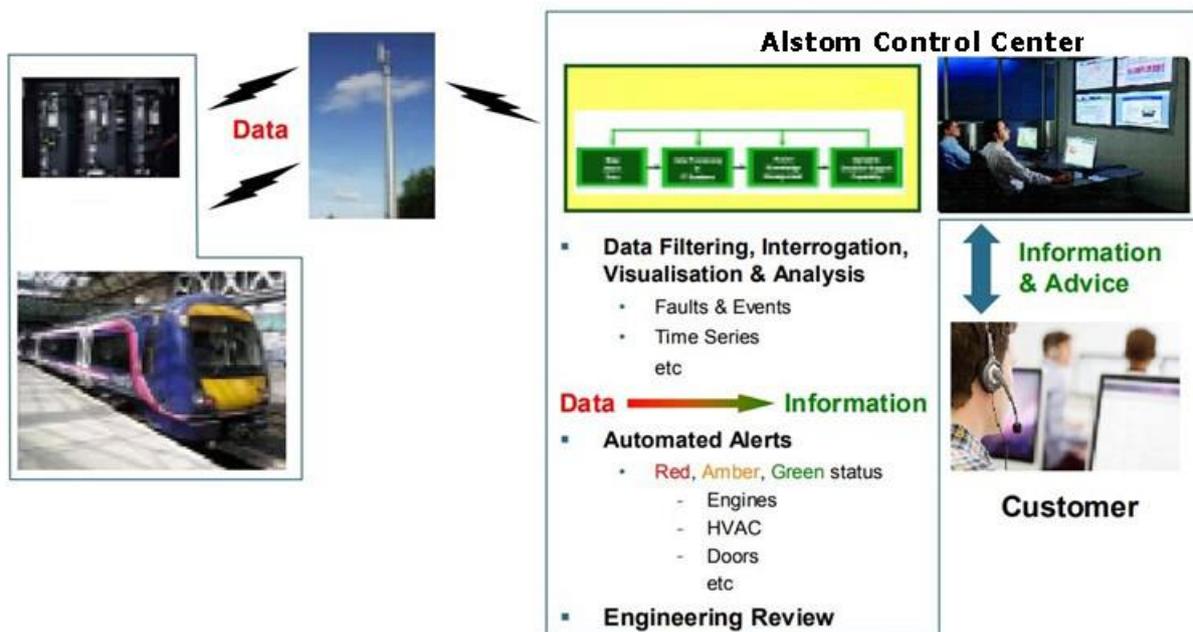


Figure V-22: Le flux des données brutes - Informations via Alstom. Inspiré de (Dubé 2007)

Les systèmes (i.e. équipements ferroviaire) pouvant être surveillés (cf. Figure V-23) comprennent systèmes dits « intelligents » tels que les portes (accès voyageurs), les freins, les climatisations, les équipements électriques, etc.

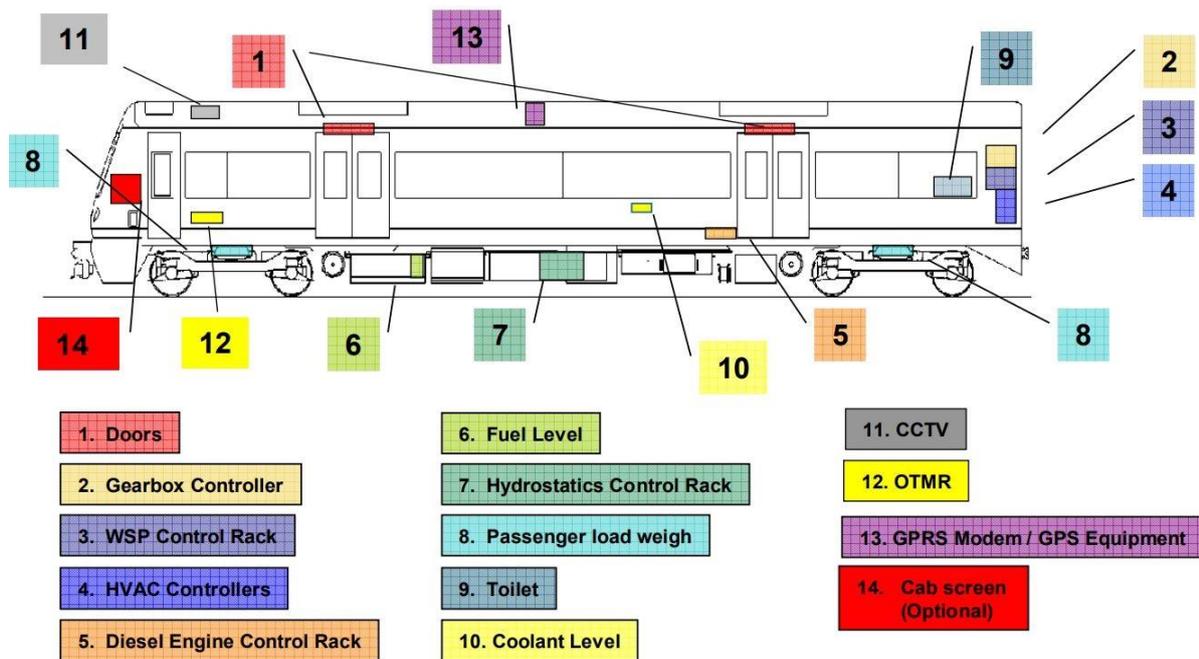


Figure V-23: Exemple de systèmes surveillés

Afin d'utiliser les données produites par les trains et d'exploiter le potentiel de ce flux d'informations, un système spécifique de transmission puis de traitement des données a été mis en place par Alstom.

Cependant, l'analyse des données s'avère chronophage et propice aux erreurs. Dans ce contexte, un contrat de Recherche avec le LAMIH vise le développement d'une assistance décisionnelle.

Le guide méthodologique, proposé dans le chapitre 3, est repris pour ce cas applicatif en respectant les mêmes étapes et itérations.

## II-1/ Application du guide méthodologique et analyse des fonctions secondaires

### II-1-1/ Etape 1 : Identification du système et des sous-systèmes ciblés

Le système d'accès voyageurs et plus spécifiquement son équipement de contrôle/commande ('Door Control Unit' ou 'DCU') constitue le système cible retenu pour l'étude. Le fonctionnement de ce système est crucial pour le bon déroulement des missions de transport. Premièrement, il contribue à la sécurité des passagers en veillant à ce que les portes soient correctement fermées et verrouillées pendant le déplacement du train. Deuxièmement, ce système permet de détecter d'éventuels obstacles ou dysfonctionnements lors de l'ouverture ou de la fermeture des portes, garantissant ainsi la protection des passagers et la prévention des incidents lors des arrêts aux différentes gares.

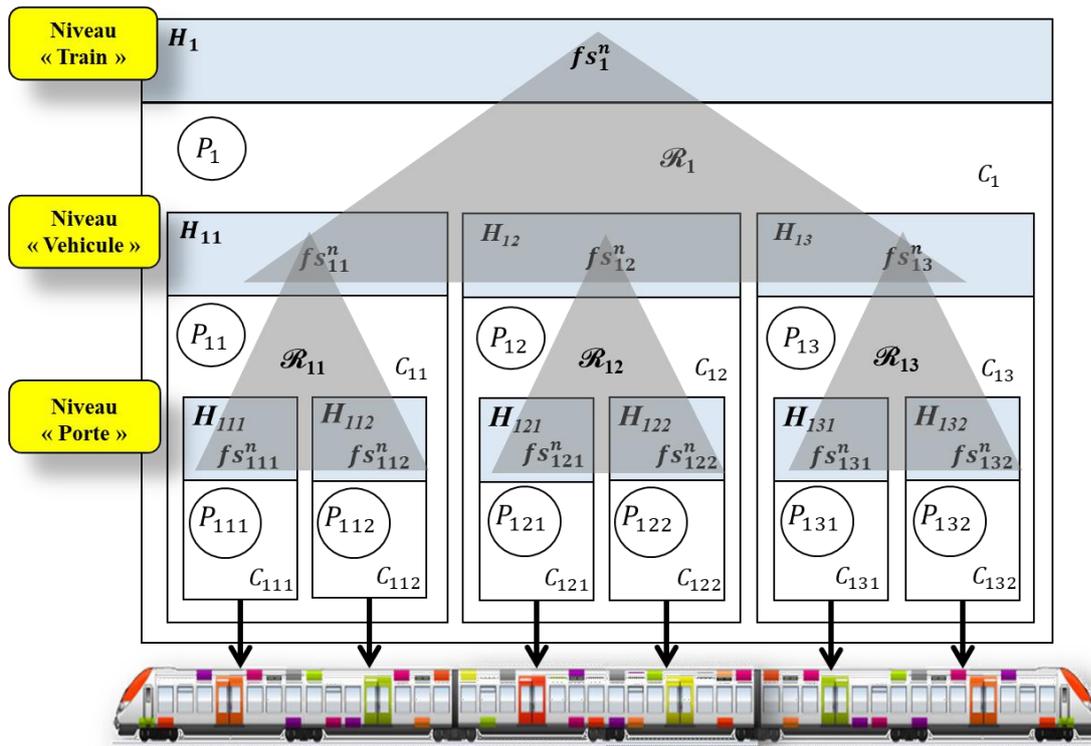


Figure V-24: Modèle holonique appliqué au système cible DCU

La Figure V-24 illustre l'architecture holonique associée à un système de transport ferroviaire, considéré comme un système complexe constitué de plusieurs sous-systèmes. Trois niveaux de décomposition sont pris en compte : le niveau du train, le niveau du véhicule et le niveau de la porte d'accès voyageurs (i.e. le système cible).

#### **II-1-2/ Etape 2 : Identification des stakeholders**

L'étude est menée en partenariat avec l'équipe des ingénieurs « fiabilistes » d'Alstom Crespin. Ainsi, un seul type de stakeholders ou « experts » est considéré.

**L'ingénieur « fiabiliste » :** Il est chargé de garantir la fiabilité et la sûreté des systèmes constitutifs des trains, y compris le système d'accès voyageurs. Il mène des analyses approfondies sur les systèmes et identifie les éventuelles défaillances ou vulnérabilités.

#### **II-1-3/ Etape 3 : Détermination des besoins de l'ingénieur « Fiabiliste »**

Un seul besoin est identifié : Il concerne la prédiction des signaux avant-coureurs, même faibles, d'une panne du système dont les données sont transmises au DCU. En possession de données hétérogènes et massives (i.e. relevant du Big Data) issus du système cible et d'autres systèmes du train, l'ingénieur a besoin de caractériser des liens logiques et des hypothèses fiables expliquant l'occurrence de la panne.

#### **II-1-4/ Etape 4 : Identification de la catégorie associée à la boucle cybernétique**

Il s'agit d'une activité de type « surveillance » qui s'intéresse au système cible comme aux autres systèmes en lien avec ce dernier.

#### **II-1-5/ Etape 5 : Caractérisation de l'activité décisionnelle**

Le niveau décisionnel de cette fonction secondaire est de type « knowledge-based ». Les sources de données Big Data ne montrent aucun lien évident entre les différents systèmes. De

plus, l'ingénieur concerné n'a pas d'hypothèses initiales pour débiter l'analyse, d'où le besoin d'élaborer une interprétation conceptuelle des liens sémantiques entre les différents systèmes basée sur la connaissance.

### II-1-6/ Etape 6 : Caractérisation de l'assistance décisionnelle

L'assistance décisionnelle qui doit être développée est de type descriptif. Elle répond à la question "Que s'est-il passé?". Avec une « projection » dans le passé, les données sont analysées pour comprendre et décrire une situation s'étant produite dans le passé afin d'éclairer une situation présente.

### II-1-7/ Etape 7 : Caractérisation du partage d'activités Humain / Machine

Le modèle AADA (Figure V-25) décrit le partage d'activités entre l'Humain et la Machine.

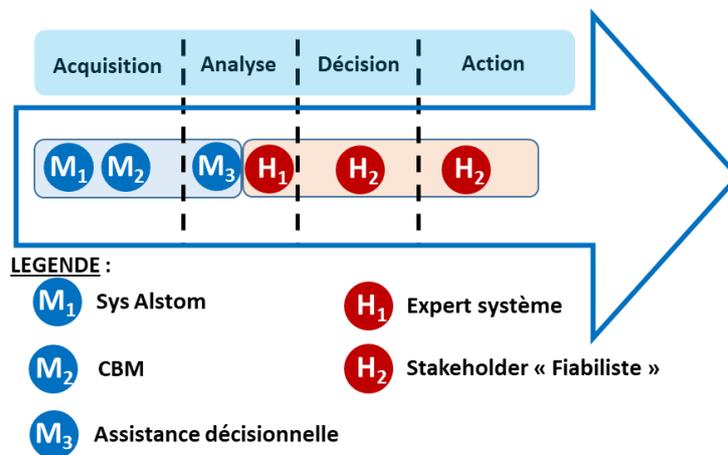


Figure V-25: Modèle AADA pour le besoin d'Alstom

### II-1-8/ Etape 8 : Description des éléments informationnels

Les éléments informationnels statiques font référence aux données historiques. Tandis que les éléments informationnels dynamiques sont disponibles après chaque événement (i.e. panne) qui nécessite une prise de décision.

Éléments informationnels statiques :

NIVEAUX DU MODELE DIK	DONNEES STATIQUES UTILISEES
KNOWLEDGE (K)	Les schémas de contrôle des systèmes Les PV d'intervention
INFORMATION (I)	Les conditions d'utilisation normales des portes La description des événements
DATA (D)	La durée d'un événement (données historique)

## Eléments informationnels dynamiques :

NIVEAUX DU MODELE DONNEES DYNAMIQUES UTILISEES DIK	
<b>KNOWLEDGE (K)</b>	Pas utilisé
<b>INFORMATION (I)</b>	L'énergie consommée (i.e. données CBM)
<b>DATA (D)</b>	Code d'événement La durée d'un événement La géolocalisation du train

### II-2/ La génération de l'assistance décisionnelle relative au besoin

L'activité décisionnelle est de type « knowledge-based » ce qui nécessite une présentation explicite des résultats. L'utilisation d'approches de type « boîte noire », tel que l'AutoML, ne donne pas la possibilité d'interpréter les différentes étapes d'analyse menée par l'assistance décisionnelle. Cela ne permet donc pas à l'ingénieur de s'approprier sereinement le résultat obtenu. Dans ce contexte, il est préférable de s'orienter vers l'utilisation d'un guide de choix d'algorithmes (cf. Figure IV-6).

#### II-2-1/ Présentation et compréhension du jeu de données

L'analyse du contexte de la panne se fait en se basant sur la base des données « bord-sol » transmises à distance par les trains. Cette analyse est effectuée sur les données « nettoyées » et transformées à l'aide de filtres développés en interne par Alstom. Ces filtres mettent en évidence les éléments les plus importants et structurent la liste des événements et des codes défauts afin que l'ingénieur analysant la panne dispose d'une vue complète du contexte associé (avant et après la panne). Les données transformées sont stockées dans le système d'Alstom pour être ensuite interrogées et manipulées via une interface Web intuitive. La Figure V-26 montre une capture d'écran du système d'exploitation des données.

State	Consist	Convoy	Last Refresh	Speed (km/h)	Last Event	Last DDS Received	Last RTS Received	Map	Last GPS Re...	Last Counter Recl...	Last File Received	La
...	...	...	25/10/2022 11:06:01	0.00	...	...	...	...	...	...	...	...
...	25000071	...	08/12/2022 13:50:51	0.11	004 020 000 000	17/11/2020 11:57:38	08/12/2022 13:50:51	Crespin-Labohain (465m NW)	08/12/2022 13:50:51	...	...	...
...	25000073	...	...	...	...	...	...	...	...	...	...	...
...	25000075	...	...	...	...	...	...	...	...	...	...	...
...	25000101	...	16/05/2022 16:06:03	0.10	...	...	16/05/2022 16:06:03	Crespin-Labohain (465m NW)	16/05/2022 16:02:40	...	...	...
...	25100051	...	27/01/2022 09:42:11	1000000.00	...	...	27/01/2022 09:42:11	...	...	...	...	...
...	25100071	...	02/11/2022 15:59:23	1000000.00	...	...	02/11/2022 15:59:23	...	...	...	...	...
...	25100073	...	19/04/2022 14:42:08	1000000.00	...	...	19/04/2022 14:42:08	...	15/03/2022 11:16:17	...	...	...
...	0013L	...	05/03/2020 20:00:18	0.00	004 012 001 000	04/03/2020 11:50:00	05/03/2020 20:00:18	St-Cyren-Viv (3.98km SW)	04/03/2020 11:50:00	02/07/2020 07:02:50	R2HPagesXML - 02/07/2020 13:21:50	040
...	002L	...	30/06/2021 15:14:35	0.07	...	06/04/2020 11:43:00	30/06/2021 15:14:35	...	...	...	...	060
...	0033L	...	06/03/2020 05:16:13	0.00	...	19/06/2020 08:53:31	06/03/2020 05:16:13	...	...	...	...	190
...	004L	...	01/07/2021 10:34:21	0.21	...	19/06/2020 08:54:29	01/07/2021 10:34:21	...	19/06/2020 08:54:29	...	...	190
...	005M	...	01/07/2021 08:42:14	0.11	...	...	01/07/2021 08:42:14	...	...	...	...	...
...	006C	...	19/06/2020 09:11:19	0.16	...	19/06/2020 09:11:19	06/01/2020 18:14:56	Wallstein (1.89km W)	19/06/2020 09:11:19	...	...	190
...	0072L	...	06/03/2020 05:18:00	0.00	...	19/06/2020 09:29:08	06/03/2020 05:18:00	Viv (5.88km NW)	19/06/2020 09:29:08	...	...	190
...	008L	...	06/03/2020 05:19:37	0.10	...	...	06/03/2020 05:19:37	...	...	...	...	...
...	009L	...	06/03/2020 05:20:55	0.00	...	...	06/03/2020 05:20:55	...	...	...	...	...
...	010L	...	06/03/2020 05:23:05	0.02	...	...	06/03/2020 05:23:05	...	...	...	...	...
...	011C	...	25/02/2020 10:51:42	0.06	...	...	25/02/2020 10:51:42	...	...	...	...	...
...	012L	...	06/03/2020 05:12:46	0.10	...	...	06/03/2020 05:12:46	...	...	...	...	...

Figure V-26: Capture du système d'exploitation des données d'Alstom

Les données utilisées pour l'étude concernent une occurrence de panne survenue le 27 novembre 2020 vers 06h00, identifiée sous le numéro d'intervention 1328333 et la désignation « UN OU PLUSIEURS ACCES VOYAGEURS SONT CONDAMNES ». Les données relatives à cette panne sont capturées 15 jours avant et 15 jours après.

Le jeu de données contient environ 90 000 lignes d'événements avec 18 colonnes (Figure V-27) représentant différentes variables telles que :

Voiture, Composition, Gravité, Système, Sous-système, Identifiant de l'événement, Code d'événement, Description de l'événement, Nom de l'événement, Date de début, Date de fin, Durée (événement actif), Lieu, Actif (i.e. Train), Décompte de la fréquence, Compte déclencheur d'événements, Texte opérateur, Texte du personnel de maintenance.

	A	B	C	D	E	F	G	H
1	Voiture	Composition	Gravité	Système	Sous-système	Identifiant de l'événement	Code d'événement	Description de l'événement
2	Z 55 06748	Z5500747	Info	BCU	BCU	224	5910	Allumage lampe VY(CO)Z
3	ZR 55 14747	Z5500747	Info	BCU	BCU	166	5894	Pression CG < 4,8 bars
4	Z 55 00747	Z5500747	Info	TCU	TCU	395	5300	LS(OV) allumée
5	Z 55 00747	Z5500747	Info	BCU	BCU	224	5910	Allumage lampe VY(CO)Z
6	Z 55 06748	Z5500747	Info	TCU	TCU	359	5300	LS(OV) allumée
7	Z 55 00747	Z5500747	Info	LIGH	LIGH	11	15159	Commutateur Z(ECL-VOY) sur OFF
8	Z 55 06748	Z5500747	Info	BCHA	BCHA	221	15554	Dépréparation rame IHM
9	Z 55 00747	Z5500747	Info	BCHA	BCHA	221	15554	Dépréparation rame IHM
10	ZR 55 21747	Z5500747	Info		DMC	1	0.1	DMC Sonorisation 48h
11	ZR 55 21747	Z5500747	Info		DMC	2	0.2	DMC Sonorisation 112h
12	ZR 55 21747	Z5500747	Info		DMC	4	0.4	DMC Réseau TCN 48h
13	ZR 55 21747	Z5500747	Info		DMC	5	0.5	DMC EMCO 48h
14	ZR 55 21747	Z5500747	Info		DMC	10	0.10	DMC ATESS 48h
15	ZR 55 21747	Z5500747	Info		DMC	11	0.11	DMC KVB 48h
16	ZR 55 21747	Z5500747	Info		DMC	12	0.12	DMC Ates 112h
17	ZR 55 21747	Z5500747	Info		DMC	13	0.13	DMC Afficheurs 112h
18	ZR 55 21747	Z5500747	Info		DMC	14	0.14	DMC Production d'air 48h
19	ZR 55 21747	Z5500747	Info		DMC	15	0.15	DMC Signalisation Extérieur 48h
20	ZR 55 21747	Z5500747	Info		DMC	16	0.16	DMC Climatisation Voyageurs 112h
21	ZR 55 21747	Z5500747	Info		DMC	18	0.18	DMC Retrovision 48h
	ZR 55 21747	Z5500747	Info		DMC	19	0.19	DMC Toilette 112h

Figure V-27: Capture du jeu de données

L'analyse porte sur la mise en évidence de liens entre le système cible DCU et les événements des autres systèmes. La Figure V-28 représente la fréquence d'apparition des erreurs des différents systèmes par rapport aux apparitions des erreurs de type DCU. Le jour de la panne est symbolisé par le pictogramme en forme d'éclair.

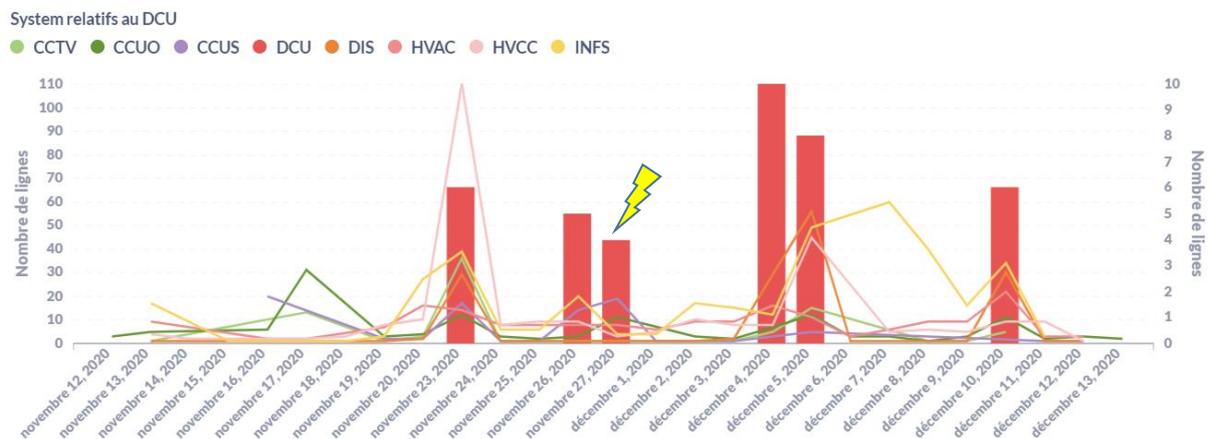


Figure V-28: Fréquence des autres systèmes par rapport aux événements DCU

Afin d'évaluer la dépendance entre deux variables aléatoires, un test de corrélation est réalisé. Le Tableau V-1 présente le résultat du test de corrélation en utilisant le coefficient de corrélation Pearson. L'analyse de la corrélation entre la fréquence de tous les événements et celle du DCU montre un fort lien entre le système DCU et les systèmes nommés DIS, HVAC, INFS.

Feature 1	Feature 2	Correlation
string	string	continuus
meta	meta	
<b>DCU</b>	<b>DIS</b>	<b>0,846</b>
<b>DCU</b>	<b>HVAC</b>	<b>0,621</b>
CCTV	DCU	0,524
DCU	HVCC	0,492
<b>DCU</b>	<b>INFS</b>	<b>0,407</b>
CCUO	DCU	0,351
CCUS	DCU	0,347

Tableau V-7: Test de corrélation entre la fréquence des événements DCU et celles des autres Systèmes

Dans un premier temps, l'analyse concernera les systèmes étudiés conjointement avec l'équipe Alstom, à savoir le système HVAC (Heating, Ventilation and Air-Conditioning) et le système INFS (qui concerne le streaming et les écrans). Le système DIS représente une très forte corrélation avec le DCU (84%), pourtant il sera exclu de cette première analyse puisque l'expert ferroviaire confirme qu'il n'existe aucune corrélation entre ce système et le DCU.

La Figure V-29 présente la saturation des événements des systèmes (DCU, HVAC et INFS) par zone géographique. Du vert vers le rouge, la figure illustre la fréquence des événements de la plus basse à la plus élevée. Cette représentation géographique enrichira l'analyse et la prise de décision.

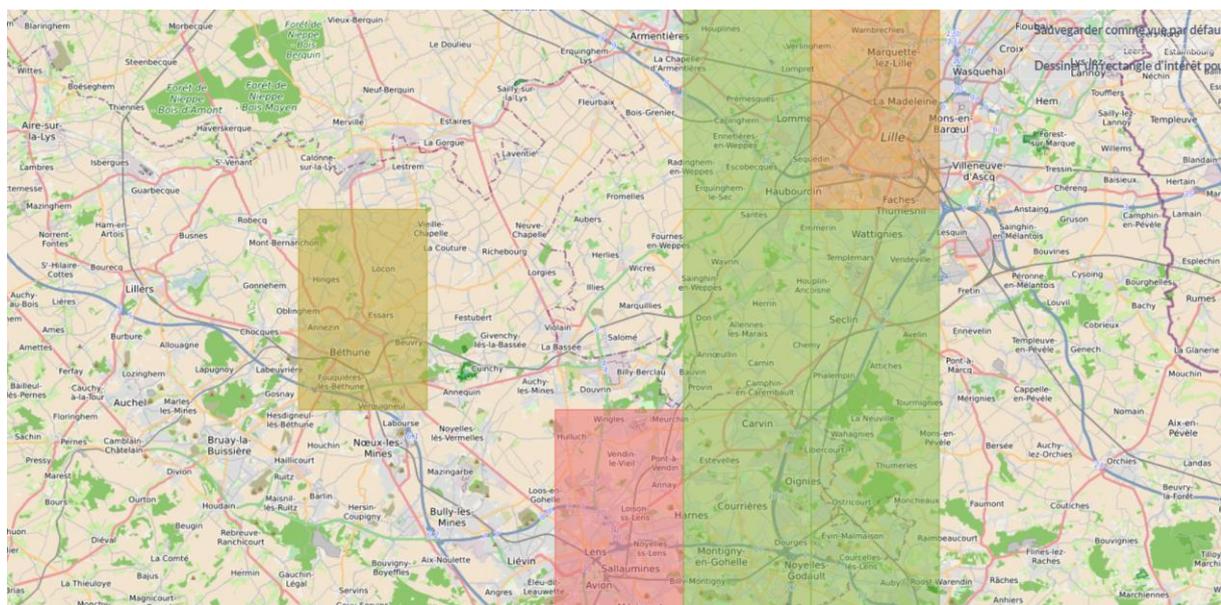


Figure V-29: Représentation géographique de la fréquence des événements

## II-2-2/ Les événements HVAC

L'ingénieur ne confirme pas la corrélation entre le HVAC et le DCU malgré la proximité des équipements (i.e. Le HVAC se situe à côté des accès voyageurs). Pourtant, l'analyse des données semble démontrer un lien entre la fréquence des événements HVAC et les événements DCU (voir le Tableau V-7 et la Figure V-30).

La première apparition des événements DCU (de type Low, Medium et High) est liée aux pics de la fréquence des événements HVAC (même filtre).

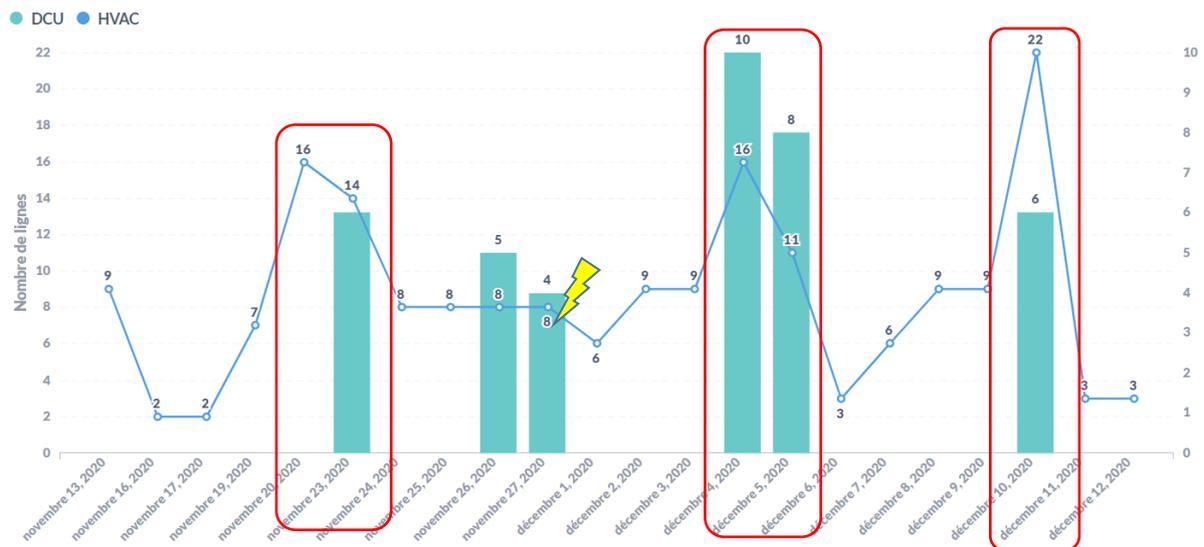


Figure V-30: Nombre d'évènement DCU et HVAC sur les 30 jours.

Filter appliqué : Tous les lieux sauf au Centre Technique ET Tous les types d'évènement sauf INFO

## II-2-3/ Les événements INFS des écrans

L'emplacement du système du streaming et des écrans est « éloigné » du système d'accès voyageur. Pourtant, l'analyse des données montre un lien avec les événements DCU (Figure V-31).

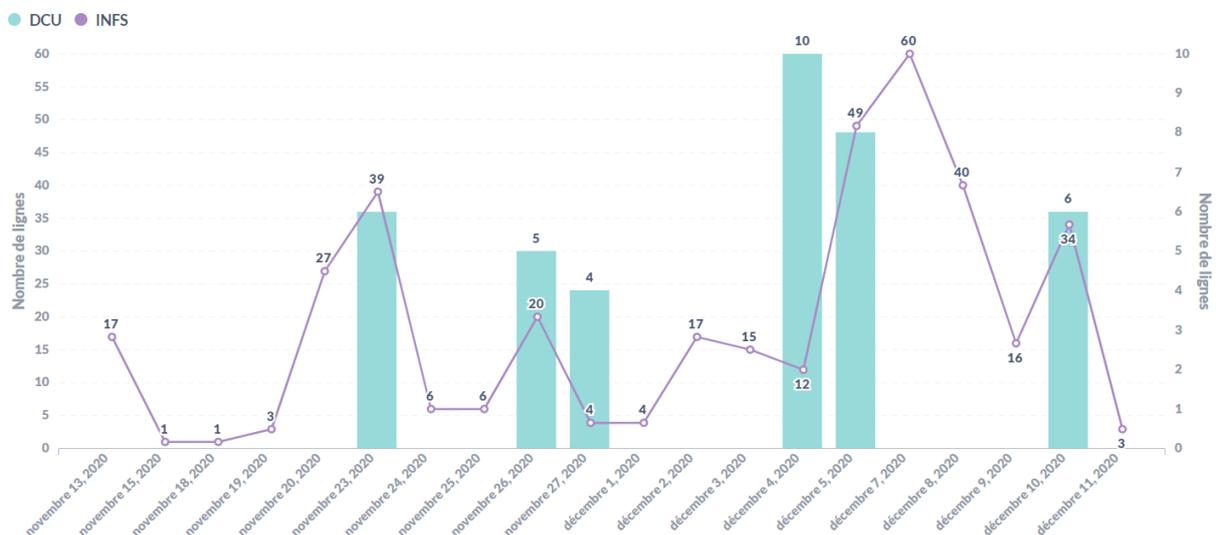


Figure V-31: Fréquence des Event INFS et DCU

Avec le même filtre appliqué précédemment, la Figure V-32 illustre les trois groupes de pics des événements INFS et les apparitions des événements sévères (Low, Medium et High) du système DCU.

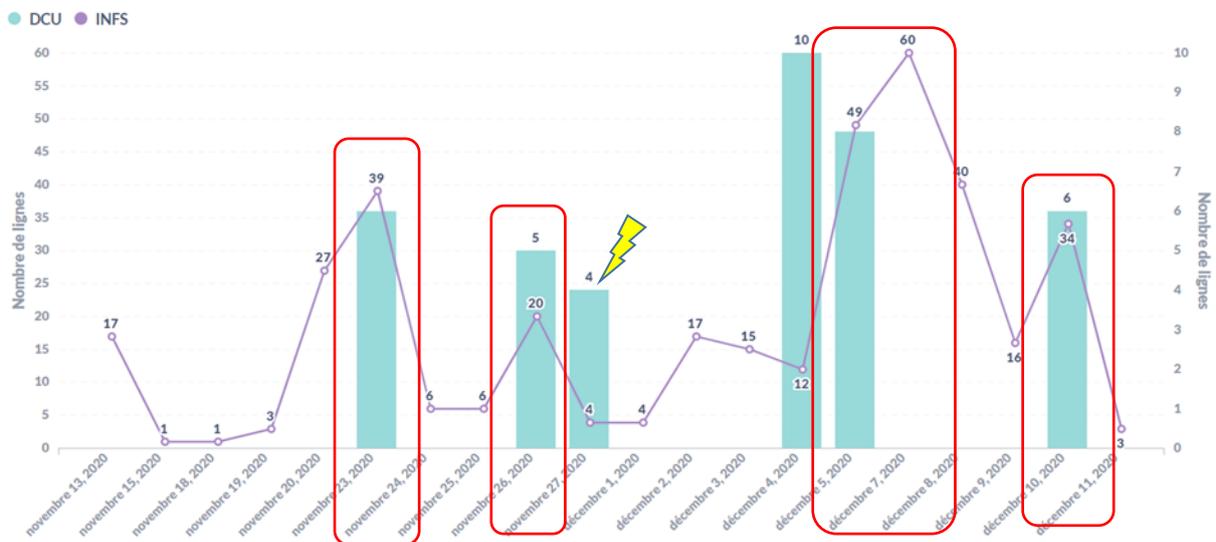


Figure V-32: Groupes de fréquence INFS-DCU

#### II-2-4/ Lien entre HVAC, INFS et DCU

En analysant la fréquence des trois systèmes selon l'axe temporel, il existe quatre groupes de fréquences (Figure V-33). Ce résultat est purement statistique et basé sur les données ce qui nécessite une analyse avancée par les experts des trois systèmes.

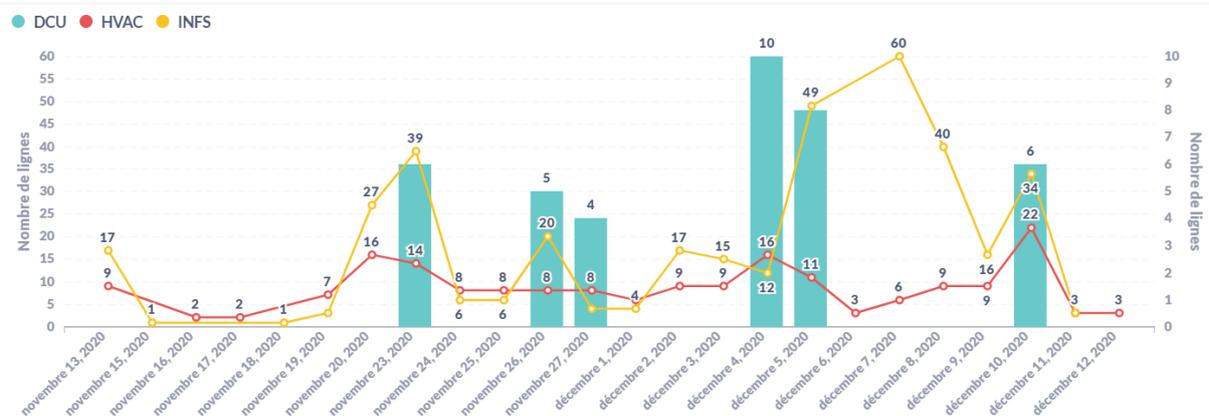


Figure V-33: Fréquence par jour des événements HVAC, INFS et DCU

Entre le début de la journée du 20 novembre 2020 et la fin de journée du 23, le nombre d'événements du système HVAC et INFS a augmenté par rapport à leur tendance normale (avant le 20). Cela s'est accompagné, comme expliqué avant, par les premières apparitions des événements du système DCU. Le même phénomène s'est reproduit le 26 novembre et aussi entre le 4 et le 5 décembre et entre le 9 et le 10 décembre.

Sachant que la panne a eu lieu le 27 novembre, le premier et le deuxième groupe entourés en bleu (Figure V-34) peuvent être considérés comme une signature ou un signe avant-coureur de la panne. Sauf que la même signature s'est reproduite deux fois encore après l'intervention (Changement du moteur) ayant normalement solutionné la panne.

En supposant que la signature est vraiment un signal faible qui précède la panne, deux grandes questions se posent donc :

1. Est-ce que l'intervention en changeant le moteur a bien résolu le problème (puisque la signature s'est reproduite) ?
2. En quoi consiste le vrai lien entre les trois systèmes ?

La première question peut être vérifiée si l'ingénieur peut avoir plus de données du même train ou des données issues d'autres trains avec le même type de panne.

La deuxième question nécessite un diagnostic plus approfondi. Une contrainte forte est que ce diagnostic doit se faire le jour de l'arrivée d'une panne. Vu les contraintes liées à la disponibilité des trains, l'immobilisation d'un train pour diagnostiquer chaque DCU et extraire les données avec l'outil de l'équipementier (i.e. le fabricant du DCU) reste délicate à effectuer. Pour cette raison, le centre de maintenance privilégie souvent le remplacement rapide des pièces défectueuses.

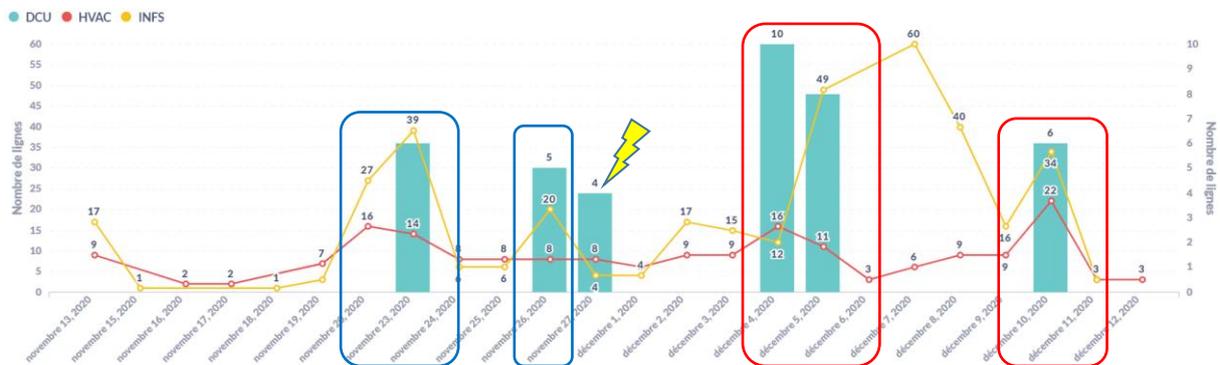


Figure V-34: Lien entre HVAC, INFS et DCU

### II-2-5/ Préparation des données

La base de données initiale comporte plus que 90000 lignes mais l'analyse a démontré une forte corrélation au niveau de la fréquence des événements par jour (Figure V-35) ce qui a réduit le nombre de lignes à 30 (15 jours avant et 15 jours après la panne). La Figure V-36 présente le tableau croisé résultant.

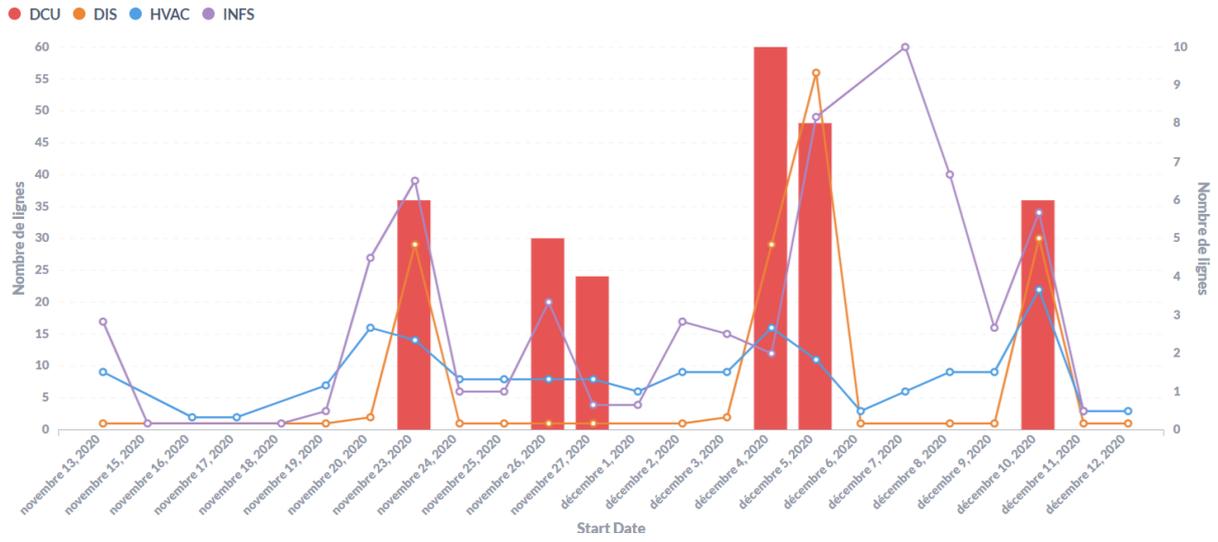


Figure V-35: Fréquence des évènements par jours

Jours	DCU	DIS	HVAC	INFS	Totaux des lig...
13 novembre, 2020		1	9	17	27
15 novembre, 2020				1	1
16 novembre, 2020			2		2
17 novembre, 2020			2		2
18 novembre, 2020				1	1
19 novembre, 2020		1	7	3	11
20 novembre, 2020		2	16	27	45
23 novembre, 2020	6	29	14	39	88
24 novembre, 2020		1	8	6	15
25 novembre, 2020		1	8	6	15
26 novembre, 2020	5	1	8	20	34
27 novembre, 2020	4	1	8	4	17
1 décembre, 2020			6	4	10
2 décembre, 2020		1	9	17	27
3 décembre, 2020		2	9	15	26
4 décembre, 2020	10	29	16	12	67
5 décembre, 2020	8	56	11	49	124
6 décembre, 2020		1	3		4
7 décembre, 2020			6	60	66
8 décembre, 2020		1	9	40	50
9 décembre, 2020		1	9	16	26
10 décembre, 2020	6	30	22	34	92
11 décembre, 2020		1	3	3	7
12 décembre, 2020		1	3		4
<b>Grand total</b>	<b>39</b>	<b>160</b>	<b>188</b>	<b>374</b>	<b>761</b>

Figure V-36: Tableau croisé des fréquences Jour/Système

### Transformation des données :

Cette étape consiste à créer une variable cible (target) afin de lancer un apprentissage supervisé. La fréquence des événements de type DCU est minimale en comparaison avec les autres types d'événements (Figure V-37). Ce constat nous amène à considérer que l'apparition d'un événement DCU correspond à une anomalie critique. Statistiquement, l'apparition d'un événement DCU va correspondre à une valeur booléenne « Vrai » qui signifie qu'il y a eu un problème au niveau du système accès voyageur (DCU).

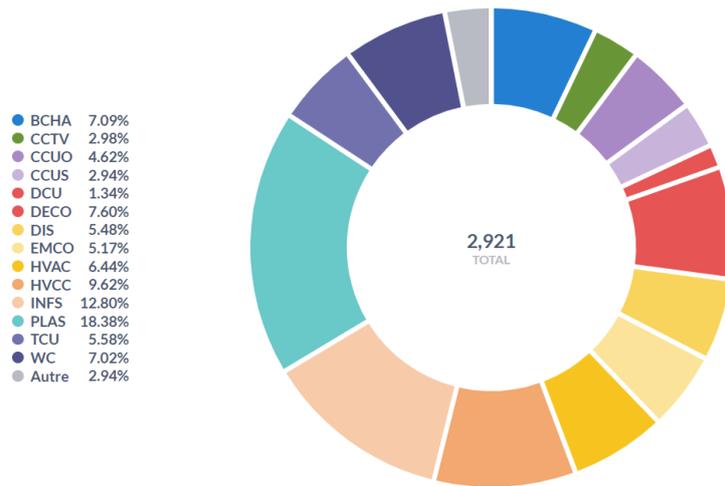


Figure V-37: Proportion des systèmes (DCU = 1,34%)

La vue finale du jeu de données pour l'apprentissage est présentée à la Figure V-38.

ID	HVAC	INFS	Is_DCU
	continuous	continuous	True False
1	0	0	False
2	9	17	False
3	0	0	False
4	0	1	False
5	2	0	False
6	2	0	False
7	0	1	False
8	7	3	False
9	16	27	False
10	14	39	True
11	8	6	False
12	8	6	False
13	8	20	True
14	8	4	True
15	6	4	False
16	9	17	False
17	9	15	False
18	16	12	True
19	11	49	True
20	3	0	False
21	6	60	False
22	9	40	False
23	9	16	False
24	22	34	True
25	3	3	False
26	3	0	False
27	0	0	False

Figure V-38: Jeu de données pour l'apprentissage

### II-2-6/ Développement du modèle

Vu que le faible nombre de lignes de données sélectionnées pour l'apprentissage (27 jours seulement) et en appliquant le guide de choix d'algorithme proposé par Microsoft (cf. Figure IV-6), l'algorithme des Arbres de Décision pour la classification est retenu pour développer l'assistance décisionnelle.

#### Test et validation :

Le manque de données pénalise la performance du modèle prédictif. Aussi, la validation des données sera à révéifier une fois que la base de données aura été enrichie avec un historique plus riche de pannes. Avec les données actuelles, nous avons obtenu un score de précision de 85,2% avec un score F1 de 84% (Figure V-39). L'algorithme des arbres décisionnel reste le meilleur en comparaison avec Naive Bayes, Random Forest, SVM et AdaBoost, comme explicité à la figure 43.

Model	AUC	CA	F1	Precision	Recall
Tree	0.778	0.852	0.840	0.843	0.852
Naive Bayes	0.794	0.778	0.788	0.807	0.778
Random Forest	0.802	0.778	0.761	0.754	0.778
SVM	0.246	0.741	0.662	0.598	0.741
AdaBoost	0.452	0.704	0.643	0.591	0.704

Figure V-39: Comparaison des critères d'évaluation du modèle prédictif

Le résultat des arbres décisionnels est associé à la matrice de confusion ci-dessus (Figure V-40).

		Predicted		$\Sigma$
		True	False	
Actual	True	75.0 %	13.0 %	6
	False	25.0 %	87.0 %	21
$\Sigma$		4	23	27

Figure V-40: La matrice de confusion liée au modèle prédictif

### II-3/ L'exploitation de l'assistance décisionnelle et la coopération Humain-Système-Cyber-Physique

Une autre source de donnée est susceptible de compléter l'analyse, il s'agit des données CBM (Condition-Based Maintenance). Ces données concernent la consommation énergétique (i.e. le courant et la tension consommés durant la phase d'ouverture/fermeture des portes) et aussi des informations sur la position de la porte et la présence des défauts.

Comme explicité dans la Figure V-41, en se référant au modèle AADA, la phase d'Acquisition de données est prise en charge par les deux entités artificielles « M<sub>1</sub> » et « M<sub>2</sub> ». L'entité artificielle « M<sub>3</sub> » et l'entité humaine « H<sub>1</sub> » coopèrent lors de la phase d'analyse. Et finalement l'entité humaine « H<sub>2</sub> » prend en charge la phase de Décision et la phase d'Action :

- L'acquisition des éléments informationnels dynamiques est assurée par le système qui recueille et stocke toutes données brutes issues du train. Le système CBM, quant à lui, capture et horodate la consommation énergétique et la position des portes.
- L'analyse des données est effectuée conjointement par l'assistance décisionnelle développée et l'expert du système cible DCU. La sortie de cette phase (i.e.  $out_i^n$ ) consiste en une classification des DCU (i.e. True : Tombera en panne dans 15 jours, False : Système normal), selon l'historique de leurs états, leurs états actuels et aussi selon les données CBM (Figure V-42).
- La décision, de type «knowledge-base», est prise par l'ingénieur en s'appuyant sur la connaissance générée lors de la phase d'analyse.
- L'action est confiée à l'ingénieur « fiabiliste » qui choisit de mener des inspections plus approfondies ou de faire confiance aux résultats et de procéder à un changement du DCU.

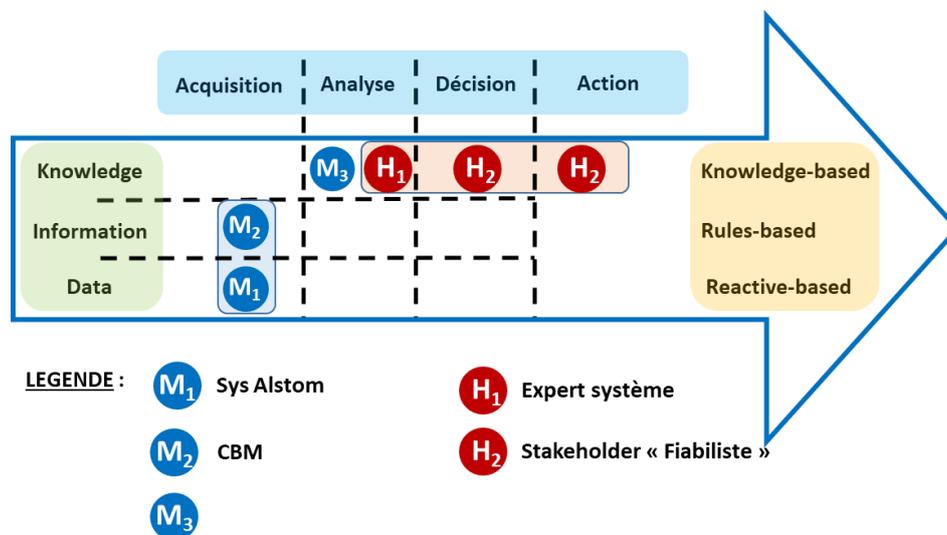


Figure V-41: Modèle HCP relatif au besoin d'Alstom

La figure suivante illustre un exemple d'interface graphique pouvant être mis à la disposition de l'ingénieur « fiabiliste » afin qu'il puisse naviguer au travers des données et des résultats d'analyse.

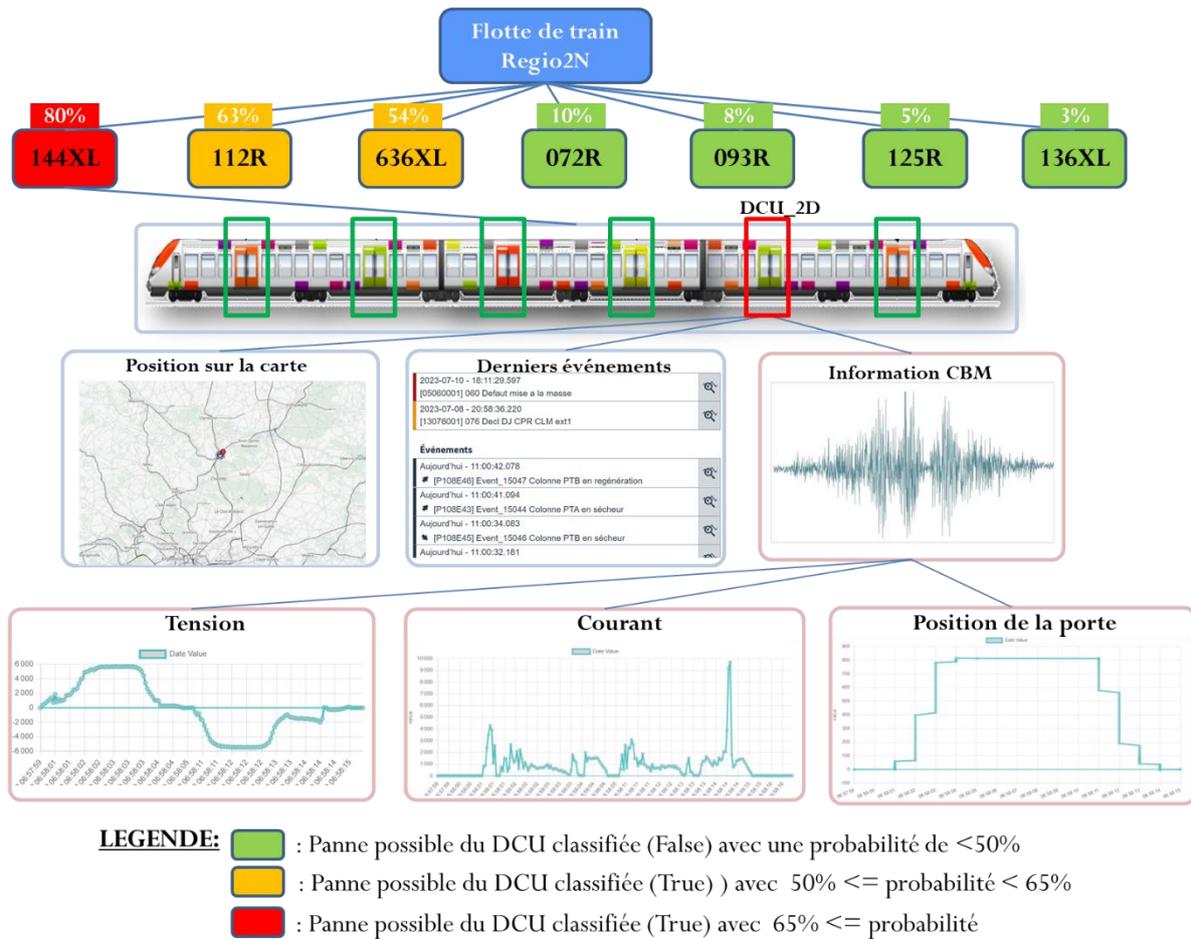


Figure V-42: Outil mise à la disposition du stakeholder pour l'interprétation des connaissances

### III/ Conclusion du chapitre

Dans ce chapitre, deux cas applicatifs relevant des domaines du transport routier et ferroviaire ont été étudiés en partenariat avec les sociétés STMF et Alstom. L'objectif de chaque étude était de valider l'assistance décisionnelle apportée aux boucles cybernétiques existantes entre le système "cible" et les différents stakeholders.

Pour chaque cas applicatif, une présentation a été réalisée, suivie d'une partie dédiée à la description de l'écosystème qui supporte les chaînes informationnelles et décisionnelles.

L'application du guide méthodologique, composé de huit étapes dans le chapitre III, a permis d'obtenir une compréhension approfondie des besoins des stakeholders. Ces étapes ont été mises en œuvre pour répondre aux phases de compréhension du métier et de compréhension des données de la méthodologie CPMAI présentée dans le chapitre IV. Pour le cas applicatif de STMF, deux stakeholders sont identifiés, et pour chacun un besoin est associé. Le premier concerne une activité décisionnelle de type Reactive-based et le deuxième de type Rule-based. Pour le cas applicatif d'Alstom, un stakeholder avec un unique besoin est identifié avec une activité décisionnelle de type Knowledge-based.

Les études de cas ont permis de valider l'efficacité de l'assistance décisionnelle apportée en mettant en évidence les bénéfices pour les stakeholders, tout en fournissant des informations détaillées sur les approches utilisées (i.e. DIK, SRK, AADA, AutoML...). Les résultats obtenus démontrent la pertinence et l'applicabilité des propositions faites dans le domaine de l'assistance décisionnelle.

## Conclusion générale

L'avancée technologique en système cyber physique et en IoT a permis d'automatiser certaines tâches répétitives et de rendre compréhensibles des situations autrefois abstraites. Cependant, cette progression technologique a également créé un défi pour l'humain, en particulier pour les décideurs « stakeholders », qui se retrouvent confrontés à une masse énorme de données de type Big Data. Ces données sont souvent difficiles à manipuler et à interpréter. La proposition de modèles et de guides méthodologiques s'avère alors indispensable pour aider les décideurs à naviguer dans cette masse de données. En développant ces méthodologies adaptées, les stakeholders seront assistés durant leurs processus de prise de décision.

Dans le premier chapitre, les systèmes cyber-physiques (SCP) et leur principe de fonctionnement ont été présentés. Les problématiques associées à la gestion du cycle de vie de ces systèmes cyber-physiques ont ensuite été mises en évidence. L'accent a notamment été mis sur la multiplicité des stakeholders amenés à intervenir sur le SCP tout au long de son cycle de vie. Par la suite, les approches IOT, Big Data, Data Analytics ou Machine Learning au niveau des boucles cybernétiques, permettant aux différents stakeholders de prendre des décisions au regard d'un SCP, sont positionnées. Les problématiques industrielle et scientifique ont ensuite été successivement présentées. La problématique scientifique s'intéressant à la conception et à la mise en œuvre d'une assistance décisionnelle pour les stakeholders a été détaillée et décomposée en un ensemble de questionnements à considérer dans le cadre d'une approche générique. Les travaux proposés dans cette thèse se sont plus particulièrement intéressés au domaine de la maintenance.

Le deuxième chapitre a proposé un état de l'art sur les différentes approches utilisées dans le domaine de l'Analytics et de l'IA, avec une focalisation sur leur application en maintenance. Dans un premier temps, ont été exposés les outils analytics classiques, suivis des approches de Machine Learning. Les techniques d'apprentissage supervisé, non supervisé et par renforcement ont été successivement détaillées. Les techniques du Deep Learning ont été abordées, en particulier les réseaux de neurones convolutifs et récurrents. Enfin, après avoir introduit un cadre d'analyse, une revue de la littérature concernant les applications des outils Analytics dans le domaine de la maintenance a été menée. Des limites dans les différentes solutions proposées pour la prise de décision ont été identifiées, notamment en raison de la difficulté à comprendre le contexte spécifique de chaque cas. De plus, la qualité et la quantité des données utilisées peuvent influencer les résultats et rendre les prévisions parfois difficiles à interpréter pour les stakeholders non-spécialistes du domaine Analytics. Les approches hybrides utilisées pour améliorer les données d'apprentissage deviennent souvent spécifiques à un cas et perdent ainsi en généralité. Enfin, si l'implication des décideurs dans la conception des stratégies de maintenance est essentielle, elle peut s'avérer complexe sans un cadre générique adéquat.

Le troisième chapitre, en tenant compte des limites soulevées dans le deuxième chapitre, a proposé une modélisation des boucles cybernétiques et des processus décisionnels associés à un système « cible » et a accordé une attention particulière au positionnement d'une assistance décisionnelle au sein des boucles cybernétiques. Les différentes entités (i.e. systèmes « cible », fonctions primaires, utilisateurs et contexte) en interaction dans un domaine d'intérêt ont été présentées. L'accent a été mis sur les fonctions secondaires (i.e. Surveillance, Amélioration, Evolution). L'étude a porté sur la proposition d'un modèle permettant de caractériser les boucles cybernétiques reliant le système « cible » et son contexte à un ou plusieurs stakeholders.

Une vision holonique, une caractérisation (DIK), une classification « Reactive-based », « Rules-based », « Knowledge-based » basés sur la typologie de Rasmussen et une caractérisation suivant le modèle AADA ont été respectivement adoptées pour permettre une décomposition d'un système « cible » en sous-systèmes, caractériser les flux informationnels au sein de la boucle cybernétique, caractériser la nature des traitements décisionnels et pour appréhender le partage des activités entre l'Humain et la Machine. Pour accompagner la proposition et la rendre pleinement opérationnelle, un guide méthodologique a finalement été proposé.

Le quatrième chapitre s'est attaché à proposer différentes approches pour concevoir l'assistance décisionnelle. Les différentes méthodologies associées aux cycles de développement de l'assistance, et la nouvelle approche Automated Machine Learning (AutoML), ont plus particulièrement été présentées. L'adoption de la méthode AutoML présente des avantages significatifs pour les entreprises qui ont besoin de créer rapidement des modèles de Machine Learning adaptés à des cas d'application spécifiques. Cette méthode en combinaison avec la méthodologie CPMAI offre une alternative efficace aux méthodes traditionnelles telles que CRISP-DM, SEMMA et KDD, qui peuvent prendre du temps et nécessiter des connaissances approfondies en data analytics.

Finalement le dernier chapitre a permis d'appliquer le guide méthodologique et de tester et d'évaluer les approches proposées. Deux cas applicatifs relevant du domaine du transport routier et ferroviaire ont été étudiés en partenariat avec les sociétés STMF et Alstom. Pour chaque cas applicatif, une présentation a été réalisée, suivie d'une partie dédiée à la description de l'écosystème qui supporte les chaînes informationnelles et décisionnelles. L'assistance décisionnelle apportée est validée par l'instanciation du guide méthodologique et l'application des approches proposées précédemment.

Dans la prolongation du travail de thèse, les perspectives envisagées à court terme concernent en particulier l'exploration d'autres cas applicatifs et l'amélioration de la présentation des résultats :

- Application des approches proposées pour des cas applicatifs générant des données de type Big Data où l'utilisation des algorithmes Deep Learning est privilégiée.
- Développement d'un outil de visualisation simplifiant l'interprétation par les stakeholders des résultats obtenus via l'assistance décisionnelle.

Les perspectives à long terme concernent le développement d'outils logiciels supportant les approches proposées et axés sur l'assistance décisionnelle :

- Développement d'un système informatique intégrant les approches proposées dans le présent mémoire et permettant de supporter les étapes successives proposées dans le guide méthodologique.
- Développement d'outil de type jumeau numérique, en complément du précédent système informatique, capable de simuler les scénarios proposés par l'assistance décisionnelle. Le but est de déterminer des indicateurs de performance selon différents scénarios décisionnels avant la prise de décision définitive par le stakeholder concerné.

## Références

- Abdi, Hervé, and Lynne J. Williams. 2010. "Principal Component Analysis." *Wiley Interdisciplinary Reviews: Computational Statistics* 2 (4): 433–59. <https://doi.org/10.1002/WICS.101>.
- Aboukadri, Sara, Aafaf Ouaddah, and Abdellatif Mezrioui. 2023. "Major Role of Artificial Intelligence, Machine Learning, and Deep Learning in Identity and Access Management Field: Challenges and State of the Art." *Lecture Notes on Data Engineering and Communications Technologies* 152: 50–64. [https://doi.org/10.1007/978-3-031-20601-6\\_5/COVER](https://doi.org/10.1007/978-3-031-20601-6_5/COVER).
- Adoum, Ahmat Fadil. 2019. "Proposition d'une Architecture de Surveillance Holonique Pour l'aide à La Maintenance Proactive d'une Flotte de Systèmes Mobiles : Application Au Domaine Ferroviaire," January. <https://theses.hal.science/tel-02056495>.
- Ahmed, Mohiuddin. 2018. "Collective Anomaly Detection Techniques for Network Traffic Analysis." *Annals of Data Science* 5 (4): 497–512. <https://doi.org/10.1007/S40745-018-0149-0/METRICS>.
- Ali, Rahman, Sungyoung Lee, and Tae Choong Chung. 2017. "Accurate Multi-Criteria Decision Making Methodology for Recommending Machine Learning Algorithm." *Expert Systems with Applications* 71 (April): 257–78. <https://doi.org/10.1016/J.ESWA.2016.11.034>.
- "AllegroGraph." 2023. 2023. <https://allegrograph.com/>.
- Alloghani, Mohamed, Dhiya Al-Jumeily, Jamila Mustafina, Abir Hussain, and Ahmed J. Aljaaf. 2020. "A Systematic Review on Supervised and Unsupervised Machine Learning Algorithms for Data Science." *Supervised and Unsupervised Learning for Data Science*, 3–21. [https://doi.org/10.1007/978-3-030-22475-2\\_1](https://doi.org/10.1007/978-3-030-22475-2_1).
- Alshamaa, Daniel, Farah Mourad Chehade, and Paul Honeine. 2018. "A Hierarchical Classification Method Using Belief Functions." *Signal Processing* 148 (July): 68–77. <https://doi.org/10.1016/J.SIGPRO.2018.02.021>.
- Atziori, Luigi, Antonio Iera, and Giacomo Morabito. 2010. "The Internet of Things: A Survey." *Computer Networks*.
- Azevedo, Ana, and Manuel Filipe Santos. 2008. "KDD, Semma and CRISP-DM: A Parallel Overview." In *MCCSIS'08 - IADIS Multi Conference on Computer Science and Information Systems; Proceedings of Informatics 2008 and Data Mining 2008*, 182–85. <https://recipp.ipp.pt/handle/10400.22/136>.
- Bahri, Maroua, Flavia Salutari, Andrian Putina, and Mauro Sozio. 2022. "AutoML: State of the Art with a Focus on Anomaly Detection, Challenges, and Research Directions." *International Journal of Data Science and Analytics* 14 (2): 113–26. <https://doi.org/10.1007/S41060-022-00309-0/METRICS>.
- Baier, Lucas, Fabian Jöhren, and Stefan Seebacher. 2020. "Challenges in the Deployment and Operation of Machine Learning in Practice." In *27th European Conference on Information Systems - Information Systems for a Sharing Society, ECIS 2019*. [https://aisel.aisnet.org/ecis2019\\_rp/163](https://aisel.aisnet.org/ecis2019_rp/163).
- Bampoula, Xanthi, Georgios Siaterlis, Nikolaos Nikolakis, and Kosmas Alexopoulos. 2021. "A

- Deep Learning Model for Predictive Maintenance in Cyber-Physical Production Systems Using LSTM Autoencoders.” *Sensors* 2021, Vol. 21, Page 972 21 (3): 972. <https://doi.org/10.3390/S21030972>.
- Bandyopadhyay, Debasis, and Jaydip Sen. 2011. “Internet of Things: Applications and Challenges in Technology and Standardization.” *Wireless Personal Communications* 58 (1): 49–69.
- Barbosa, José, Paulo Leitão, Damien Trentesaux, Armando W Colombo, and Stamatis Karnouskos. 2016. “Cross Benefits from Cyber-Physical Systems and Intelligent Products for Future Smart Industries.” In *2016 IEEE 14th International Conference on Industrial Informatics (INDIN)*, 504–9.
- Barutcuoglu, Zafer, and Christopher DeCoro. 2006. “Hierarchical Shape Classification Using Bayesian Aggregation.” *Proceedings - IEEE International Conference on Shape Modeling and Applications 2006, SMI 2006* 2006: 44. <https://doi.org/10.1109/SMI.2006.15>.
- Basselot, Vivien. 2019. “Contribution à La Modélisation Des Chaînes Informationnelles et Des Processus Décisionnels Associés à Un Produit ‘Intelligent,’” October. <https://uphf.hal.science/tel-03368976>.
- Basselot, Vivien, Thierry Berger, and Yves Sallez. 2019a. “Information Chain Modeling from Product to Stakeholder in the Use Phase – Application to Diagnoses in Railway Transportation.” *Manufacturing Letters* 20: 22–26. <https://doi.org/10.1016/j.mfglet.2019.03.001>.
- . 2019b. “Proposition of a Holonic Approach to Model the Information Chain from Product to Stakeholder.” In *6th International Conference on Control, Decision and Information Technologies, CoDIT 2019*, 109–14. <https://doi.org/10.1109/CoDIT.2019.8820462>.
- Becker, Till, and Hendrik Stern. 2016. “Future Trends in Human Work Area Design for Cyber-Physical Production Systems.” *Procedia Cirp* 57: 404–9.
- Bell, Jason. 2022. “What Is Machine Learning?” *Machine Learning and the City: Applications in Architecture and Urban Design*, 209–16. [https://doi.org/10.1007/978-3-319-18305-3\\_1](https://doi.org/10.1007/978-3-319-18305-3_1).
- Berger, Thierry, Yves Sallez, Antoine Dequidt, and Damien Trentesaux. 2020. “A Generic Architecture to Design Cyber-Physical and Human Systems.” *IFAC-PapersOnLine* 53 (5): 344–49. <https://doi.org/10.1016/J.IFACOL.2021.04.111>.
- Bergstra, James, James Bergstra@umontreal Ca, and Yoshua Bengio@umontreal Ca. 2012. “Random Search for Hyper-Parameter Optimization Yoshua Bengio.” *Journal of Machine Learning Research* 13: 281–305. <http://scikit-learn.sourceforge.net>.
- Berisha, Blend, Endrit Mëziu, and Isak Shabani. 2022. “Big Data Analytics in Cloud Computing: An Overview.” *Journal of Cloud Computing* 11 (1): 1–10. <https://doi.org/10.1186/S13677-022-00301-W/FIGURES/11>.
- Berman, Daniel S., Anna L. Buczak, Jeffrey S. Chavis, and Cherita L. Corbett. 2019. “A Survey of Deep Learning Methods for Cyber Security.” *Information (Switzerland)*. Multidisciplinary Digital Publishing Institute. <https://doi.org/10.3390/info10040122>.
- Bester, Craig J., Steven D. James, and George D. Konidaris. 2019. “Multi-Pass Q-Networks for Deep Reinforcement Learning with Parameterised Action Spaces.” *Preprint*, May.

<https://arxiv.org/abs/1905.04388v1>.

- Bishara, Anthony J., and James B. Hittner. 2012. "Testing the Significance of a Correlation with Nonnormal Data: Comparison of Pearson, Spearman, Transformation, and Resampling Approaches." *Psychological Methods* 17 (3): 399–417. <https://doi.org/10.1037/A0028087>.
- Botvinick, Matthew, Sam Ritter, Jane X. Wang, Zeb Kurth-Nelson, Charles Blundell, and Demis Hassabis. 2019. "Reinforcement Learning, Fast and Slow." *Trends in Cognitive Sciences* 23 (5): 408–22. <https://doi.org/10.1016/J.TICS.2019.02.006>.
- Bouvard, K., S. Artus, C. Bérenguer, and V. Cocquempot. 2011. "Condition-Based Dynamic Maintenance Operations Planning & Grouping. Application to Commercial Heavy Vehicles." *Reliability Engineering & System Safety* 96 (6): 601–10. <https://doi.org/10.1016/J.RESS.2010.11.009>.
- Breiman, Leo, Jerome H. Friedman, Richard A. Olshen, and Charles J. Stone. 2017. "Classification and Regression Trees." *Routledge*, January, 1–358. <https://doi.org/10.1201/9781315139470>.
- Burkart, Nadia, and Marco F. Huber. 2021. "A Survey on the Explainability of Supervised Machine Learning." *Journal of Artificial Intelligence Research* 70 (January): 245–317. <https://doi.org/10.1613/JAIR.1.12228>.
- Caigny, Arno De, Kristof Coussement, and Koen W. De Bock. 2018. "A New Hybrid Classification Algorithm for Customer Churn Prediction Based on Logistic Regression and Decision Trees." *European Journal of Operational Research* 269 (2): 760–72. <https://doi.org/10.1016/j.ejor.2018.02.009>.
- Cardin, Olivier, William Derigent, and Damien Trentesaux. 2022. "Digitalization and Control of Industrial Cyber-Physical Systems: Concepts, Technologies and Applications." *Digitalization and Control of Industrial Cyber-Physical Systems: Concepts, Technologies and Applications*, May, 1–323. <https://doi.org/10.1002/9781119987420>.
- Cassady, C. Richard, Joel A. Nachlas, W. Paul Murdock, and Edward A. Pohl. 1998. "Comprehensive Fleet Maintenance Management." *Proceedings of the IEEE International Conference on Systems, Man and Cybernetics* 5: 4665–69. <https://doi.org/10.1109/ICSMC.1998.727588>.
- Cassina, Jacopo, Alessandro Cannata, and Marco Taisch. 2009. "Development of an Extended Product Lifecycle Management through Service Oriented Architecture." In *Proceedings of the 1st CIRP Industrial Product-Service Systems (IPS2) Conference*.
- Cassina, Jacopo, Maurizio Tomasella, Micheal Marquard, Altug Metin, Andrea Matta, and Marco Taisch. 2006. "Development of the Semantic Object Model for a PDKM System." In *2006 IEEE International Technology Management Conference (ICE)*, 1–8.
- Cervantes, Jair, Farid Garcia-Lamont, Lisbeth Rodríguez-Mazahua, and Asdrubal Lopez. 2020. "A Comprehensive Survey on Support Vector Machine Classification: Applications, Challenges and Trends." *Neurocomputing* 408 (September): 189–215. <https://doi.org/10.1016/J.NEUCOM.2019.10.118>.
- Chassagnon, Guillaume, Maria Vakalopoulou, Nikos Paragios, and Marie Pierre Revel. 2020. "Deep Learning: Definition and Perspectives for Thoracic Imaging." *European Radiology* 30 (4): 2021–30. <https://doi.org/10.1007/S00330-019-06564-3/METRICS>.

- Chen, Shanzhi, Hui Xu, Dake Liu, Bo Hu, and Hucheng Wang. 2014. "A Vision of IoT: Applications, Challenges, and Opportunities with China Perspective." *IEEE Internet of Things Journal* 1 (4): 349–59.
- Chen, Yiran, Yuan Xie, Linghao Song, Fan Chen, and Tianqi Tang. 2020. "A Survey of Accelerator Architectures for Deep Neural Networks." *Engineering* 6 (3): 264–74. <https://doi.org/10.1016/J.ENG.2020.01.007>.
- Cheng, Ching-An, Tengyang Xie, Nan Jiang, and Alekh Agarwal. 2022. "Adversarially Trained Actor Critic for Offline Reinforcement Learning." *Adversarially Trained Actor Critic for Offline Reinforcement Learning, ArXiv*, February, arXiv:2202.02446. <https://doi.org/10.48550/ARXIV.2202.02446>.
- Christensen, James. 1994. "Holonc Manufacturing Systems: Initial Architecture and Standards Directions." In *1st Euro. Conf. on Holonic Manufacturing Systems, Hannover, Germany*, no. March: 1–20.
- Cortes, Corinna, and Vladimir Vapnik. 1995. "Support-Vector Networks." *Machine Learning* 20 (3): 273–97. <https://doi.org/10.1007/bf00994018>.
- Courage, Catherine, and Kathy Baxter. 2004. *Understanding Your Users: A Practical Guide to User Requirements Methods, Tools, and Techniques*. Understanding Your Users: A Practical Guide to User Requirements Methods, Tools, and Techniques. Gulf Professional Publishing. <https://doi.org/10.1016/B978-1-55860-935-8.X5029-5>.
- D'Agostini, G. 1994. "On the Use of the Covariance Matrix to Fit Correlated Data." *Nuclear Instruments and Methods in Physics Research Section A: Accelerators, Spectrometers, Detectors and Associated Equipment* 346 (1–2): 306–11. [https://doi.org/10.1016/0168-9002\(94\)90719-6](https://doi.org/10.1016/0168-9002(94)90719-6).
- Dalzochio, Jovani, Rafael Kunst, Jorge Luis Victória Barbosa, Pedro Clarindo da Silva Neto, Edison Pignaton, Carla Schwengber ten Caten, and Alex de Lima Teodoro da Penha. 2023. "Predictive Maintenance in the Military Domain: A Systematic Review of the Literature." *ACM Computing Surveys*, July. <https://doi.org/10.1145/3586100>.
- Das, Subrata Kumar. 2008. *High-Level Data Fusion*. Artech House.
- Daskalakis, Constantinos, Dylan J. Foster, and Noah Golowich. 2020. "Independent Policy Gradient Methods for Competitive Reinforcement Learning." *Advances in Neural Information Processing Systems* 33: 5527–40.
- Dassisti, Michele, Hervé Panetto, and Angela Tursi. 2006. "Product-Driven Enterprise Interoperability for Manufacturing Systems Integration." In *International Conference on Business Process Management*, 249–60.
- Deka, Lipika, Sakib M. Khan, Mashrur Chowdhury, and Nick Ayres. 2018. "Transportation Cyber-Physical System and Its Importance for Future Mobility." *Transportation Cyber-Physical Systems*, January, 1–20. <https://doi.org/10.1016/B978-0-12-814295-0.00001-0>.
- Delen, Dursun, and Sudha Ram. 2018. "Research Challenges and Opportunities in Business Analytics." *Journal of Business Analytics* 1 (1): 2–12. <https://doi.org/10.1080/2573234X.2018.1507324>.
- Denkena, Berend, Marc-André Dittrich, Marius Lindauer, Julia Mainka, and Lukas Stürenburg. 2020. "Using AutoML to Optimize Shape Error Prediction in Milling Processes." *SSRN Electronic Journal*, November. <https://doi.org/10.2139/SSRN.3724234>.

- Dhillon, B. S. (Balbir S.). 1999. *Engineering Maintainability : How to Design for Reliability and Easy Maintenance*. Gulf Pub. Co. <http://www.sciencedirect.com:5070/book/97808884152576/engineering-maintainability>.
- Diez-Olivan, Alberto, Jose A. Pagan, Ricardo Sanz, and Basilio Sierra. 2017. “Data-Driven Prognostics Using a Combination of Constrained K-Means Clustering, Fuzzy Modeling and LOF-Based Score.” *Neurocomputing* 241: 97–107. <https://doi.org/10.1016/J.NEUCOM.2017.02.024>.
- Dubé, Eric. 2007. “Orbita – Predictive Asset Management.” In *AusRAIL PLUS*, 1–18.
- Engelen, Jesper E. van, and Holger H. Hoos. 2020. “A Survey on Semi-Supervised Learning.” *Machine Learning* 109 (2): 373–440. <https://doi.org/10.1007/S10994-019-05855-6/FIGURES/5>.
- Essien, Aniekan, and Cinzia Giannetti. 2020. “A Deep Learning Model for Smart Manufacturing Using Convolutional LSTM Neural Network Autoencoders.” *IEEE Transactions on Industrial Informatics* 16 (9): 6069–78. <https://doi.org/10.1109/TII.2020.2967556>.
- Ezugwu, Absalom E, Abiodun M Ikotun, Olaide O Oyelade, Laith Abualigah, Jeffery O. Agushaka, Christopher I. Eke, and Andronicus A. Akinyelu. 2022. “A Comprehensive Survey of Clustering Algorithms: State-of-the-Art Machine Learning Applications, Taxonomy, Challenges, and Future Research Prospects.” *Engineering Applications of Artificial Intelligence*. Elsevier Ltd. <https://doi.org/10.1016/j.engappai.2022.104743>.
- Fadil, Adoum, Damien Trentesaux, and Guillaume Branger. 2019. “Event Management Architecture for the Monitoring and Diagnosis of a Fleet of Trains: A Case Study.” *Journal of Modern Transportation* 27 (3): 169–87. <https://doi.org/10.1007/S40534-019-0187-0>.
- Fayyad, Usama, Gregory Piatetsky-Shapiro, and Padhraic Smyth. 1996. “The KDD Process for Extracting Useful Knowledge from Volumes of Data.” *Communications of the ACM* 39 (11): 27–35. [link.gale.com/apps/doc/A18993841/AONE](http://link.gale.com/apps/doc/A18993841/AONE).
- Fayyad, Usama, and Paul Stolorz. 1997. “Data Mining and KDD: Promise and Challenges.” *Future Generation Computer Systems* 13 (2–3): 99–115. [https://doi.org/10.1016/S0167-739X\(97\)00015-0](https://doi.org/10.1016/S0167-739X(97)00015-0).
- Feurer, Matthias, Katharina Eggensperger, Stefan Falkner, Marius Lindauer, and Frank Hutter. 2022. “Auto-Sklearn 2.0: Hands-Free AutoML via Meta-Learning.” *Journal of Machine Learning Research* 23 (October): 0–18. <http://arxiv.org/abs/2007.04074>.
- Florea, Adrian-Catalin, and Razvan Andonie. 2020. “Weighted Random Search for Hyperparameter Optimization.” *International Journal of Computers, Communications and Control* 14 (2): 154–69. <https://doi.org/10.15837/ijccc.2019.2.3514>.
- Frye, M., J. Krauß, and R. H. Schmitt. 2021. “Expert System for the Machine Learning Pipeline in Manufacturing.” *IFAC-PapersOnLine* 54 (1): 128–33. <https://doi.org/10.1016/J.IFACOL.2021.08.014>.
- Gandomi, Amir, and Murtaza Haider. 2015. “Beyond the Hype: Big Data Concepts, Methods, and Analytics.” *International Journal of Information Management* 35 (2): 137–44. <https://doi.org/10.1016/J.IJINFOMGT.2014.10.007>.
- Garouani, Moncef, Adeel Ahmad, Mourad Bouneffa, Mohamed Hamlich, Gregory Bourguin, and Arnaud Lewandowski. 2022. “Towards Big Industrial Data Mining through

- Explainable Automated Machine Learning.” *International Journal of Advanced Manufacturing Technology* 120 (1–2): 1169–88. <https://doi.org/10.1007/S00170-022-08761-9/FIGURES/12>.
- Gewers, Felipe L., Gustavo R. Ferreira, Henrique F. De Arruda, Filipi N. Silva, Cesar H. Comin, Diego R. Amancio, and Luciano Da F. Costa. 2021. “Principal Component Analysis.” *ACM Computing Surveys (CSUR)* 54 (4). <https://doi.org/10.1145/3447755>.
- Gholami, Raouf, and Nikoo Fakhari. 2017. “Support Vector Machine: Principles, Parameters, and Applications.” *Handbook of Neural Computation*, January, 515–35. <https://doi.org/10.1016/B978-0-12-811318-9.00027-2>.
- Gigerenzer, Gerd, and Reinhard Selten. 2002. *Bounded Rationality: The Adaptive Toolbox*. Vol. 1. The MIT Press. <https://econpapers.repec.org/RePEc:mtp:titles:0262571641>.
- Goeij, Moniek C.M. De, Merel Van Diepen, Kitty J. Jager, Giovanni Tripepi, Carmine Zoccali, and Friedo W. Dekker. 2013. “Multiple Imputation: Dealing with Missing Data.” *Nephrology Dialysis Transplantation* 28 (10): 2415–20. <https://doi.org/10.1093/NDT/GFT221>.
- Gordon, A. D. 1987. “A Review of Hierarchical Classification.” *Journal of the Royal Statistical Society: Series A (General)* 150 (2): 119–37. <https://doi.org/10.2307/2981629>.
- Grabot, Bernard. 2020. “Rule Mining in Maintenance: Analysing Large Knowledge Bases.” *Computers & Industrial Engineering* 139 (January): 105501. <https://doi.org/10.1016/J.CIE.2018.11.011>.
- “Grafana Labs.” 2023. Accessed 20-08-2023. 2023. <https://grafana.com/>.
- Gruber, Thomas R. 1993. “A Translation Approach to Portable Ontology Specifications.” *Knowledge Acquisition* 5 (2): 199–220.
- “Gruff.” 2023. Accessed 20-08-2023. 2023. <https://allegrograph.com/products/gruff/>.
- Haddad, G., P. A. Sandborn, and M. G. Pecht. 2014. “Using Maintenance Options to Maximize the Benefits of Prognostics for Wind Farms.” *Wind Energy* 17 (5): 775–91. <https://doi.org/10.1002/WE.1610>.
- Haixiang, Wang, and Smys S. 2021. “Big Data Analysis and Perturbation Using Data Mining Algorithm.” *Journal of Soft Computing Paradigm* 3 (1): 19–28. <https://doi.org/10.36548/JSCP.2021.1.003>.
- He, Xin, Kaiyong Zhao, and Xiaowen Chu. 2021. “AutoML: A Survey of the State-of-the-Art.” *Knowledge-Based Systems* 212: 106622. <https://doi.org/10.1016/j.knosys.2020.106622>.
- Hitzler, Pascal, and Bijan Parsia. 2009. “Ontologies and Rules.” *Handbook on Ontologies*, 111–32. [https://doi.org/10.1007/978-3-540-92673-3\\_5](https://doi.org/10.1007/978-3-540-92673-3_5).
- Ho, Tin Kam. 1995. “Random Decision Forests.” *Proceedings of the International Conference on Document Analysis and Recognition, ICDAR* 1: 278–82. <https://doi.org/10.1109/ICDAR.1995.598994>.
- Hu, Y H, S C Yu, X Qi, W J Zheng, Q Q Wang, and H Y Yao. 2019. “An Overview of Multiple Linear Regression Model and Its Application.” *Chinese Journal of Preventive Medicine* 53 (6): 653–56. <https://doi.org/10.3760/CMA.J.ISSN.0253-9624.2019.06.021>.
- Hutter, Frank, Lars Kotthoff, and Joaquin Vanschoren. 2019. *Automated Machine Learning:*

- Methods, Systems, Challenges*. The Springer Series on Challenges in Machine Learning. Springer Nature. <https://doi.org/10.1007/978-3-030-05318-5>.
- “InfluxData.” 2023. Accessed 20-08-2023. 2023. <https://www.influxdata.com/influxdb/>.
- Ishwarappa, and J. Anuradha. 2015. “A Brief Introduction on Big Data 5Vs Characteristics and Hadoop Technology.” *Procedia Computer Science* 48 (C): 319–24. <https://doi.org/10.1016/J.PROCS.2015.04.188>.
- Islam, Umar, Rami Qays Malik, Amnah S. Al-Johani, Muhammad Riaz Khan, Yousef Ibrahim Daradkeh, Ijaz Ahmad, Khalid A. Alissa, Zulkiflee Abdul-Samad, and Elsayed M. Tag-Eldin. 2022. “A Novel Anomaly Detection System on the Internet of Railways Using Extended Neural Networks.” *Electronics (Switzerland)* 11 (18): 2813. <https://doi.org/10.3390/electronics11182813>.
- ISO/IEC. 2018. “Information Technology – Internet of Things Reference Architecture (IoT RA).” *Iso/Iec Cd 30141* 20160910: 1–77. <https://www.iso.org/standard/65695.html>.
- Jackson, Ilya, and Josue C. Velazquez-Martinez. 2021. “Automl Approach to Classification of Candidate Solutions for Simulation Models of Logistic Systems.” *Proceedings - Winter Simulation Conference* 2021-December. <https://doi.org/10.1109/WSC52266.2021.9715416>.
- Jain, A. K., M. N. Murty, and P. J. Flynn. 1999. “Data Clustering: A Review.” *ACM Computing Surveys* 31 (3): 264–323. <https://doi.org/10.1145/331499.331504>.
- Jardine, Andrew K.S., and Albert H.C. Tsang. 2013. “Maintenance, Replacement, and Reliability: Theory and Applications, Second Edition.” *Maintenance, Replacement, and Reliability: Theory and Applications, Second Edition*, January, 1–332. <https://doi.org/10.1201/B14937/MAINTENANCE-REPLACEMENT-RELIABILITY-ANDREW-JARDINE-ALBERT-TSANG>.
- Javed, Abdul Rehman, Muhammad Usman, Saif Ur Rehman, Mohib Ullah Khan, and Mohammad Sayad Haghghi. 2021. “Anomaly Detection in Automated Vehicles Using Multistage Attention-Based Convolutional Neural Network.” *IEEE Transactions on Intelligent Transportation Systems* 22 (7): 4291–4300. <https://doi.org/10.1109/TITS.2020.3025875>.
- Jiao, Yasen, and Pufeng Du. 2016. “Performance Measures in Evaluating Machine Learning Based Bioinformatics Predictors for Classifications.” *Quantitative Biology* 4:4 4 (4): 320–30. <https://doi.org/10.1007/S40484-016-0081-2>.
- Jin, Haifeng, Qingquan Song, and Xia Hu. 2019. “Auto-Keras: An Efficient Neural Architecture Search System.” *Proceedings of the ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, no. March: 1946–56. <https://doi.org/10.1145/3292500.3330648>.
- Joudaki, Hossein, Arash Rashidian, Behrouz Minaei-Bidgoli, Mahmood Mahmoodi, Bijan Geraili, Mahdi Nasiri, and Mohammad Arab. 2015. “Using Data Mining to Detect Health Care Fraud and Abuse: A Review of Literature.” *Global Journal of Health Science* 7 (1): 194. <https://doi.org/10.5539/GJHS.V7N1P194>.
- Judd, Charles M., Gary H. McClelland, and Carey S. Ryan. 2011. “Data Analysis : A Model Comparison Approach, Second Edition,” March. <https://doi.org/10.4324/9780203892053>.
- Jun, Hong-Bae, Dimitris Kiritsis, and Paul Xirouchakis. 2007. “Research Issues on Closed-

- Loop PLM.” *Computers in Industry* 58 (8–9): 855–68.
- K., Vikranth, and Krishna Prasad K. 2020. “The Sustained Improvements in E-Commerce Business through Big Data and Data Analytics of Wal-Mart Company.” *International Journal of Case Studies in Business, IT, and Education*, August, 28–39. <https://doi.org/10.47992/ijcsbe.2581.6942.0077>.
- Kantasa-ard, Anirut, Abdelghani Bekrar, Abdessamad Aitelcadi, and Yves Saliez. 2019. “Artificial Intelligence for Forecasting in Supply Chain Management: A Case Study of White Sugar Consumption Rate in Thailand.” *IFAC-PapersOnLine* 52 (13): 725–30. <https://doi.org/10.1016/J.IFACOL.2019.11.201>.
- Kantasa-ard, Anirut, Maroua Nouri, Abdelghani Bekrar, Abdessamad Ait el cadi, and Yves Saliez. 2020. “Machine Learning for Demand Forecasting in the Physical Internet: A Case Study of Agricultural Products in Thailand.” *International Journal of Production Research* 0 (0): 1–25. <https://doi.org/10.1080/00207543.2020.1844332>.
- Karamizadeh, Sasan, Shahidan M Abdullah, Azizah A Manaf, Mazdak Zamani, and Alireza Hooman. 2013. “An Overview of Principal Component Analysis.” *Journal of Signal and Information Processing* 4: 173–75. <https://doi.org/10.4236/jsip.2013.43B031>.
- Kemp, Sarah E., May Ng, Tracey Hollowood, and Joanne Hort. 2017. “Introduction to Descriptive Analysis.” *Descriptive Analysis in Sensory Evaluation*, December, 1–39. <https://doi.org/10.1002/9781118991657.CH1>.
- Khan, Asifullah, Anabia Sohail, Umme Zahoor, and Aqsa Saeed Qureshi. 2020. “A Survey of the Recent Architectures of Deep Convolutional Neural Networks.” *Artificial Intelligence Review* 2020 53:8 53 (8): 5455–5516. <https://doi.org/10.1007/S10462-020-09825-6>.
- Kiritsis, Dimitris. 2011. “Closed-Loop PLM for Intelligent Products in the Era of the Internet of Things.” *CAD Computer Aided Design* 43 (5): 479–501. <https://doi.org/10.1016/j.cad.2010.03.002>.
- Kiritsis, Dimitris, Ahmed Bufardi, and Paul Xirouchakis. 2003. “Research Issues on Product Lifecycle Management and Information Tracking Using Smart Embedded Systems.” *Advanced Engineering Informatics* 17 (3–4): 189–202.
- Kocbek, Simon, and Bogdan Gabrys. 2019. “Automated Machine Learning Techniques in Prognostics of Railway Track Defects.” *IEEE International Conference on Data Mining Workshops, ICDMW 2019-November* (November): 777–84. <https://doi.org/10.1109/ICDMW.2019.00115>.
- Koestler, Arthur. 1970. “Beyond Atomism and Holism—the Concept of the Holon.” *Perspectives in Biology and Medicine* 13 (2): 131–54. <https://doi.org/10.1353/PBM.1970.0023>.
- Komer, Brent, James Bergstra, and Chris Eliasmith. 2014. “Hyperopt-Sklearn: Automatic Hyperparameter Configuration for Scikit-Learn.” *Proceedings of the 13th Python in Science Conference*, no. Scipy: 32–37. <https://doi.org/10.25080/majora-14bd3278-006>.
- Krauß, Jonathan, Bruno Machado Pacheco, Hanno Maximilian Zang, and Robert Heinrich Schmitt. 2020. “Automated Machine Learning for Predictive Quality in Production.” *Procedia CIRP* 93 (January): 443–48. <https://doi.org/10.1016/J.PROCIR.2020.04.039>.
- Ku, Jin Hee. 2018. “A Study on Prediction Model of Equipment Failure Through Analysis of Big Data Based on RHadoop.” *Wireless Personal Communications* 98 (4): 3163–76.

<https://doi.org/10.1007/s11277-017-4151-1>.

- Kumar, Aviral, Aurick Zhou, George Tucker, and Sergey Levine. 2020. "Conservative Q-Learning for Offline Reinforcement Learning." *Advances in Neural Information Processing Systems* 33: 1179–91.
- Kumbhare Santosh V Chobe, Trupti A. 2014. "An Overview of Association Rule Mining Algorithms." *International Journal of Computer Science and Information Technologies*. [www.ijcsit.com](http://www.ijcsit.com).
- Lämmer, Lutz, and Mirko Theiss. 2015. "Product Lifecycle Management." In *Concurrent Engineering in the 21st Century: Foundations, Developments and Challenges*, 455–90. Springer. [https://doi.org/10.1007/978-3-319-13776-6\\_16](https://doi.org/10.1007/978-3-319-13776-6_16).
- Lau, Raymond Y.K., J. Leon Zhao, Guoqing Chen, and Xunhua Guo. 2016. "Big Data Commerce." *Information and Management* 53 (8): 929–33. <https://doi.org/10.1016/J.IM.2016.07.008>.
- Lawless, Harry T., and Hildegard Heymann. 2010. "Descriptive Analysis." In *Sensory Evaluation of Food*, 227–57. Springer, New York, NY. [https://doi.org/10.1007/978-1-4419-6488-5\\_10](https://doi.org/10.1007/978-1-4419-6488-5_10).
- Lee, Edward A. 2006. "Cyber-Physical Systems-Are Computing Foundations Adequate." In *Position Paper for NSF Workshop on Cyber-Physical Systems: Research Motivation, Techniques and Roadmap*, 2:1–9.
- Lee, Jay, Behrad Bagheri, and Hung An Kao. 2015. "A Cyber-Physical Systems Architecture for Industry 4.0-Based Manufacturing Systems." *Manufacturing Letters* 3 (January): 18–23. <https://doi.org/10.1016/J.MFGLET.2014.12.001>.
- Li, Changjiu, Yong Zhang, Xichao Su, and Xinwei Wang. 2022. "An Improved Optimization Algorithm for Aeronautical Maintenance and Repair Task Scheduling Problem." *Mathematics* 2022, Vol. 10, Page 3777 10 (20): 3777. <https://doi.org/10.3390/MATH10203777>.
- Li, Dan, Dacheng Chen, Baihong Jin, Lei Shi, Jonathan Goh, and See Kiong Ng. 2019. "MAD-GAN: Multivariate Anomaly Detection for Time Series Data with Generative Adversarial Networks." *Lecture Notes in Computer Science (Including Subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)* 11730 LNCS: 703–16. [https://doi.org/10.1007/978-3-030-30490-4\\_56/COVER](https://doi.org/10.1007/978-3-030-30490-4_56/COVER).
- Li, Zewen, Fan Liu, Wenjie Yang, Shouheng Peng, and Jun Zhou. 2022. "A Survey of Convolutional Neural Networks: Analysis, Applications, and Prospects." *IEEE Transactions on Neural Networks and Learning Systems* 33 (12): 6999–7019. <https://doi.org/10.1109/TNNLS.2021.3084827>.
- Liu, Ruiming, Erqi Liu, Jie Yang, Ming Li, and Fanglin Wang. 2006. "Optimizing the Hyper-Parameters for SVM by Combining Evolution Strategies with a Grid Search." *Intelligent Control and Automation*, October, 712–21. [https://doi.org/10.1007/978-3-540-37256-1\\_87](https://doi.org/10.1007/978-3-540-37256-1_87).
- Liu, Shixia, Jiannan Xiao, Junlin Liu, Xiting Wang, Jing Wu, and Jun Zhu. 2018. "Visual Diagnosis of Tree Boosting Methods." *IEEE Transactions on Visualization and Computer Graphics* 24 (1): 163–73. <https://doi.org/10.1109/TVCG.2017.2744378>.
- Lopes Gerum, Pedro Cesar, Ayca Altay, and Melike Baykal-Gürsoy. 2019. "Data-Driven

- Predictive Maintenance Scheduling Policies for Railways.” *Transportation Research Part C: Emerging Technologies* 107 (October): 137–54. <https://doi.org/10.1016/J.TRC.2019.07.020>.
- Lwakatare, Lucy Ellen, Aiswarya Raj, Jan Bosch, Helena Holmström Olsson, and Ivica Crnkovic. 2019. “A Taxonomy of Software Engineering Challenges for Machine Learning Systems: An Empirical Investigation.” *Lecture Notes in Business Information Processing* 355: 227–43. [https://doi.org/10.1007/978-3-030-19034-7\\_14](https://doi.org/10.1007/978-3-030-19034-7_14).
- Mallouk, Issam, Badr Abou El Majd, and Yves Sallez. 2018. “Optimization of the Maintenance Planning of a Multi-Component System.” *MATEC Web of Conferences* 200: 1–6. <https://doi.org/10.1051/mateconf/201820000011>.
- Manyika, James, Michael Chui, Brad Brown, Jacques Bughin, Richard Dobbs, Charles Roxburgh, and Angela Hung Byers. 2011. “Big Data: The next Frontier for Innovation, Competition, and Productivity.” *McKinsey Global Institute*, no. June: 156. <https://cir.nii.ac.jp/crid/1570291224336057344>.
- Martin Salvador, Manuel, Marcin Budka, and Bogdan Gabrys. 2016. “Adapting Multicomponent Predictive Systems Using Hybrid Adaptation Strategies with AutoWEKA in Process Industry.” In *AutoML at ICML 2016*, 64:48–57.
- Matignon, Randall. 2007. “Data Mining Using SAS® Enterprise Miner™.” *Data Mining Using SAS® Enterprise Miner™*, 1–564. <https://doi.org/10.1002/9780470171431>.
- Maulik, Ujjwal, and Debasis Chakraborty. 2017. “Remote Sensing Image Classification: A Survey of Support-Vector-Machine-Based Advanced Techniques.” *IEEE Geoscience and Remote Sensing Magazine* 5 (1): 33–52. <https://doi.org/10.1109/MGRS.2016.2641240>.
- Mauro, Andrea De, Marco Greco, Michele Grimaldi, and Paavo Ritala. 2018. “Human Resources for Big Data Professions: A Systematic Classification of Job Roles and Required Skill Sets.” *Information Processing & Management* 54 (5): 807–17. <https://doi.org/10.1016/J.IPM.2017.05.004>.
- Mbuli, John, Damien Trentesaux, Joffrey Clarhaut, and Guillaume Branger. 2018. “Decision Support in Condition-Based Maintenance of a Fleet of Cyber-Physical Systems: A Fuzzy Logic Approach.” In *Intelligent Systems Conference, IntelliSys 2017*, 2018-Janua:82–89. Institute of Electrical and Electronics Engineers Inc. <https://doi.org/10.1109/IntelliSys.2017.8324362>.
- Mbuli, John William. 2019. “A Multi-Agent System for the Reactive Fleet Maintenance Support Planning of a Fleet of Mobile Cyber-Physical Systems : Application to Rail Transport Industry.” Université Polytechnique Hauts-de-France. <https://hal.science/tel-02468233>.
- Memoona, Khanum, Imtiaz Warda, Abdul Ghafoor Humaraia, and Sehar Rabeea. 2015. “A Survey on Unsupervised Machine Learning Algorithms for Automation, Classification and Maintenance.” *International Journal of Computer Applications* 119 (13): 975–8887. [www.campsearch.com](http://www.campsearch.com).
- Mohammadi, Mehdi, Ala Al-Fuqaha, Sameh Sorour, and Mohsen Guizani. 2018. “Deep Learning for IoT Big Data and Streaming Analytics: A Survey.” *IEEE Communications Surveys and Tutorials* 20 (4): 2923–60. <https://doi.org/10.1109/COMST.2018.2844341>.
- Mohammed, Basna, Salih Hasan, and Adnan Mohsin Abdulazeez. 2021. “A Review of

- Principal Component Analysis Algorithm for Dimensionality Reduction.” *Journal of Soft Computing and Data Mining* 2 (1): 20–30. <https://doi.org/10.30880/jscdm.2021.02.01.003>.
- Monostori, László. 2014. “Cyber-Physical Production Systems: Roots, Expectations and R&D Challenges.” *Procedia Cirp* 17: 9–13.
- Montgomery, Douglas C. 2014. “Big Data and the Quality Profession.” *Quality and Reliability Engineering International* 30 (4): 447. <https://doi.org/10.1002/QRE.1669>.
- Morariu, Cristina, Octavian Morariu, Silviu Răileanu, and Theodor Borangiu. 2020. “Machine Learning for Predictive Scheduling and Resource Allocation in Large Scale Manufacturing Systems.” *Computers in Industry* 120. <https://doi.org/10.1016/j.compind.2020.103244>.
- Mortellec, Antoine Le. 2013. “Proposition d’une Architecture de Surveillance ‘Active’ à Base d’agents Intelligents Pour l’aide à La Maintenance de Systèmes Mobiles Application Au Domaine Ferroviaire.”
- Mortellec, Antoine Le. 2014. “Proposition d’une Architecture de Surveillance ‘Active’ à Base d’agents Intelligents Pour l’aide à La Maintenance de Systèmes Mobiles - Application Au Domaine Ferroviaire.” Université de Valenciennes et du Hainaut-Cambresis. <https://theses.hal.science/tel-00947981>.
- Mortellec, Antoine Le, Joffrey Clarhaut, Yves Sallez, Thierry Berger, and Damien Trentesaux. 2013. “Embedded Holonic Fault Diagnosis of Complex Transportation Systems.” *Engineering Applications of Artificial Intelligence* 26 (1): 227–40. <https://doi.org/10.1016/j.engappai.2012.09.008>.
- Muan Sang, Go. 2021. “Predictive Maintenance for Industry 4.0 A Holistic Approach to Performing Predictive Maintenance as a Service.” Bournemouth University. <http://eprints.bournemouth.ac.uk/36855/>.
- Murdoch, W. James, Chandan Singh, Karl Kumbier, Reza Abbasi-Asl, and Bin Yu. 2019. “Definitions, Methods, and Applications in Interpretable Machine Learning.” *Proceedings of the National Academy of Sciences of the United States of America* 116 (44): 22071–80. <https://doi.org/10.1073/pnas.1900654116>.
- Murtagh, F., and M. Hernández-Pajares. 1995. “The Kohonen Self-Organizing Map Method: An Assessment.” *Journal of Classification* 12 (2): 165–90. <https://doi.org/10.1007/BF03040854>.
- Nabati, Elaheh Gholamzadeh, Klaus-Dieter Thoben, and Morice Daudi. 2017. “Stakeholders in the Middle of Life of Complex Products: Understanding the Role and Information Needs.” *International Journal of Product Lifecycle Management* 10 (3): 231–57.
- Nguyen, Khanh T.P., and Kamal Medjaher. 2019. “A New Dynamic Predictive Maintenance Framework Using Deep Learning for Failure Prognostics.” *Reliability Engineering & System Safety* 188 (August): 251–62. <https://doi.org/10.1016/J.RESS.2019.03.018>.
- Noy, Natalya F, and Deborah L McGuinness. 2001. “Ontology Development 101: A Guide to Creating Your First Ontology.” *Stanford Knowledge Systems Laboratory*. Stanford knowledge systems laboratory technical report KSL-01-05 and~.... <https://doi.org/10.1016/j.artmed.2004.01.014>.
- Olson, Randal S, Olsonran@upenn Edu, and Jason H Moore. 2016. “AutoML Workshop Tpot.”

- Parasuraman, Raja, Thomas B. Sheridan, and Christopher D. Wickens. 2000. “A Model for Types and Levels of Human Interaction with Automation.” *IEEE Transactions on Systems, Man, and Cybernetics Part A: Systems and Humans*. 30 (3): 286–97. <https://doi.org/10.1109/3468.844354>.
- Paul, Angshuman, Dipti Prasad Mukherjee, Prasun Das, Abhinandan Gangopadhyay, Appa Rao Chinthu, and Saurabh Kundu. 2018. “Improved Random Forest for Classification.” *IEEE Transactions on Image Processing* 27 (8): 4012–24. <https://doi.org/10.1109/TIP.2018.2834830>.
- Philpotts, Mike. 1996. “An Introduction to the Concepts, Benefits and Terminology of Product Data Management.” *Industrial Management & Data Systems* 96 (4): 11–17.
- Plantin, Jean-Christophe, Carl Lagoze, Paul N. Edwards, and Christian Sandvig. 2017. “Big Data Is Not about Size: When Data Transform Scholarship.” In *Ouvrir, Partager, Réutiliser*. Editions de la Maison des Sciences de l’Homme. <https://doi.org/10.4000/books.editionsmsmh.9103>.
- Qiu, Junfei, Qihui Wu, Guoru Ding, Yuhua Xu, and Shuo Feng. 2016. “A Survey of Machine Learning for Big Data Processing.” *Eurasip Journal on Advances in Signal Processing* 2016 (1): 1–16. <https://doi.org/10.1186/S13634-016-0355-X/FIGURES/5>.
- Qu, Xiaofei, Lin Yang, Kai Guo, Linru Ma, Meng Sun, Mingxing Ke, and Mu Li. 2021. “A Survey on the Development of Self-Organizing Maps for Unsupervised Intrusion Detection.” *Mobile Networks and Applications* 26 (2): 808–29. <https://doi.org/10.1007/S11036-019-01353-0/METRICS>.
- Quinlan, J R. 1986. “Induction of Decision Trees.” *Machine Learning* 1: 81–106.
- Rahimi, M ;, H ; Liu, I D ; Cardenas, A ; Starr, A ; Hall, R Anderson, Masoumeh Rahimi, et al. 2022. “A Review on Technologies for Localisation and Navigation in Autonomous Railway Maintenance Systems.” *Sensors* 2022, Vol. 22, Page 4185 22 (11): 4185. <https://doi.org/10.3390/S22114185>.
- Rajkumar, Ragunathan, Insup Lee, Lui Sha, and John Stankovic. 2010. “Cyber-Physical Systems: The next Computing Revolution.” In *Design Automation Conference*, 731–36.
- Rasmussen, Jens. 1983. “Skills, Rules, and Knowledge; Signals, Signs, and Symbols, and Other Distinctions in Human Performance Models.” *IEEE Transactions on Systems, Man and Cybernetics* SMC-13 (3): 257–66. <https://doi.org/10.1109/TSMC.1983.6313160>.
- Ren, Shan, Yingfeng Zhang, Tomohiko Sakao, Yang Liu, and Ruilong Cai. 2022. “An Advanced Operation Mode with Product-Service System Using Lifecycle Big Data and Deep Learning.” *International Journal of Precision Engineering and Manufacturing - Green Technology* 9 (1): 287–303. <https://doi.org/10.1007/S40684-021-00354-3/TABLES/6>.
- Ridwan, Muhammad, and Andi Purnomo. 2022. “Incorporating Deep Learning Data Analytics Techniques in the Optimisation of Capacitated Planned Maintenance.” *Jurnal Sistem Dan Manajemen Industri* 6 (2): 167–75. <https://doi.org/10.30656/JSMI.V6I2.5076>.
- Rosenblatt, F. 1958. “The Perceptron: A Probabilistic Model for Information Storage and Organization in the Brain.” *Psychological Review* 65 (6): 386–408. <https://doi.org/10.1037/H0042519>.

- Ross, Amanda, and Victor L. Willson. 2017. "Linear Regression." *Basic and Advanced Statistical Tests*, 39–47. [https://doi.org/10.1007/978-94-6351-086-8\\_8](https://doi.org/10.1007/978-94-6351-086-8_8).
- Runkler, Thomas A. 2020. "Data Analytics: Models and Algorithms for Intelligent Data Analysis, Third Edition." *Data Analytics: Models and Algorithms for Intelligent Data Analysis*, January, 1–161. <https://doi.org/10.1007/978-3-658-29779-4/COVER>.
- Russom, Philip, and Tdwi Org. 2011. "Introduction to Big Data Analytics."
- Sallez, Yves. 2012. "Produit " Actif " Tout Au Long de Son Cycle de Vie." Université de Valenciennes et du Hainaut-Cambresis. <http://tel.archives-ouvertes.fr/tel-00768771/>.
- Sallez, Yves, Thierry Berger, Dominique Deneux, and Damien Trentesaux. 2010. "The Lifecycle of Active and Intelligent Products: The Augmentation Concept." *International Journal of Computer Integrated Manufacturing* 23 (10): 905–24. <https://doi.org/10.1080/0951192X.2010.490275>.
- Samsuden, Mohd Azmin, Norizan Mat Diah, and Nurazzah Abdul Rahman. 2019. "A Review Paper on Implementing Reinforcement Learning Technique in Optimising Games Performance." *2019 IEEE 9th International Conference on System Engineering and Technology, ICSET 2019 - Proceeding*, October, 258–63. <https://doi.org/10.1109/ICSENGT.2019.8906400>.
- Sarangpure, Nikhilesh, Vipul Dhamde, Ankita Roge, Janhawi Doye, Shivam Patle, and Sukhad Tamboli. 2023. "Automating the Machine Learning Process Using PyCaret and Streamlit." *2023 2nd International Conference for Innovation in Technology, INOCON 2023*, March, 1–5. <https://doi.org/10.1109/INOCON57975.2023.10101357>.
- Schmidt, Amand F., and Chris Finan. 2018. "Linear Regression and the Normality Assumption." *Journal of Clinical Epidemiology* 98 (June): 146–51. <https://doi.org/10.1016/J.JCLINEPI.2017.12.006>.
- Schneider, Walter, and Jason M. Chein. 2003. "Controlled & Automatic Processing: Behavior, Theory, and Biological Mechanisms." *Cognitive Science* 27 (3): 525–59. [https://doi.org/10.1207/S15516709COG2703\\_8](https://doi.org/10.1207/S15516709COG2703_8).
- Schröer, Christoph, Felix Kruse, and Jorge Marx Gómez. 2021. "A Systematic Literature Review on Applying CRISP-DM Process Model." *Procedia Computer Science* 181 (January): 526–34. <https://doi.org/10.1016/J.PROCS.2021.01.199>.
- Scott, Cheryl. 2011. "Product Life-Cycle Management." In *BioProcess International*, 9:16–23. Springer. <https://doi.org/10.1201/9781439828328.ch4>.
- Sewak, Mohit, Sanjay K. Sahay, and Hemant Rathore. 2020. "An Overview of Deep Learning Architecture of Deep Neural Networks and Autoencoders." *Journal of Computational and Theoretical Nanoscience* 17 (1): 182–88. <https://doi.org/10.1166/JCTN.2020.8648>.
- Shekar, B. H., and Guesh Dagneu. 2019. "Grid Search-Based Hyperparameter Tuning and Classification of Microarray Cancer Data." *2019 2nd International Conference on Advanced Computational and Communication Paradigms, ICACCP 2019*, February. <https://doi.org/10.1109/ICACCP.2019.8882943>.
- Sherstinsky, Alex. 2020. "Fundamentals of Recurrent Neural Network (RNN) and Long Short-Term Memory (LSTM) Network." *Physica D: Nonlinear Phenomena* 404 (March): 132306. <https://doi.org/10.1016/J.PHYSD.2019.132306>.

- Shi, Xiupeng, Yiik Diew Wong, Chen Chai, and Michael Zhi Feng Li. 2021. “An Automated Machine Learning (AutoML) Method of Risk Prediction for Decision-Making of Autonomous Vehicles.” *IEEE Transactions on Intelligent Transportation Systems* 22 (11): 7145–54. <https://doi.org/10.1109/TITS.2020.3002419>.
- Shi, Yong. 2022. “Advances in Big Data Analytics.” *Advances in Big Data Analytics*. <https://doi.org/10.1007/978-981-16-3607-3>.
- Shrestha, Ajay, and Ausif Mahmood. 2019. “Review of Deep Learning Algorithms and Architectures.” *IEEE Access* 7: 53040–65. <https://doi.org/10.1109/ACCESS.2019.2912200>.
- Silla, Carlos N., and Alex A. Freitas. 2011. “A Survey of Hierarchical Classification across Different Application Domains.” *Data Mining and Knowledge Discovery* 22 (1–2): 31–72. <https://doi.org/10.1007/S10618-010-0175-9/METRICS>.
- Smagulova, Kamilya, and Alex Pappachen James. 2019. “A Survey on LSTM Memristive Neural Network Architectures and Applications.” *The European Physical Journal Special Topics* 228:10 228 (10): 2313–24. <https://doi.org/10.1140/EPJST/E2019-900046-X>.
- Stiglic, Gregor, Simon Kocbek, Igor Pernek, and Peter Kokol. 2012. “Comprehensive Decision Tree Models in Bioinformatics.” *PLOS ONE* 7 (3): e33812. <https://doi.org/10.1371/JOURNAL.PONE.0033812>.
- Strauch, Barry. 2018. “Ironies of Automation: Still Unresolved after All These Years.” *IEEE Transactions on Human-Machine Systems* 48 (5): 419–33. <https://doi.org/10.1109/THMS.2017.2732506>.
- Sutcliffe, Alistair. 2012. *User-Centred Requirements Engineering*. Springer Science & Business Medi.
- Targowski, Andrew. 2005. “From Data to Wisdom.” *Dialogue and Universalism* 15 (5): 55–71. <https://doi.org/10.5840/du2005155/629>.
- Terzi, Sergio, Abdelaziz Bouras, Debashi Dutta, Marco Garetti, Dimitris Kiritsis, and others. 2010. “Product Lifecycle Management—from Its History to Its New Role.” *International Journal of Product Lifecycle Management* 4 (4): 360–89.
- Thornton, Chris, Frank Hutter, Holger H. Hoos, and Kevin Leyton-Brown. 2013. “Auto-WEKA: Combined Selection and Hyperparameter Optimization of Classification Algorithms.” *Proceedings of the ACM SIGKDD International Conference on Knowledge Discovery and Data Mining Part F1288*: 847–55. <https://doi.org/10.1145/2487575.2487629>.
- Tieppo, Eduardo, Roger Robson dos Santos, Jean Paul Barddal, and Júlio Cesar Nievola. 2022. “Hierarchical Classification of Data Streams: A Systematic Literature Review.” *Artificial Intelligence Review* 55 (4): 3243–82. <https://doi.org/10.1007/S10462-021-10087-Z/TABLES/10>.
- Tondini, Stefano, Claudio Castellan, Manuel Alessandro Medina, and Lorenzo Pavesi. 2019. “Automatic Initialization Methods for Photonic Components on a Silicon-Based Optical Switch.” *Applied Sciences (Switzerland)* 9 (9): 1843. <https://doi.org/10.3390/app9091843>.
- Trentesaux, D., T. Knothe, G. Branger, and K. Fischer. 2015. “Planning and Control of Maintenance, Repair and Overhaul Operations of a Fleet of Complex Transportation Systems: A Cyber-Physical System Approach.” *Studies in Computational Intelligence* 594

- (February): 175–86. [https://doi.org/10.1007/978-3-319-15159-5\\_17](https://doi.org/10.1007/978-3-319-15159-5_17).
- Trentesaux, Damien, and Patrick Millot. 2016. “A Human-Centred Design to Break the Myth of the ‘Magic Human’ in Intelligent Manufacturing Systems.” *Studies in Computational Intelligence* 640: 103–13. [https://doi.org/10.1007/978-3-319-30337-6\\_10/COVER](https://doi.org/10.1007/978-3-319-30337-6_10/COVER).
- Truong, Anh, Austin Walters, Jeremy Goodsitt, Keegan Hines, C. Bayan Bruss, and Reza Farivar. 2019. “Towards Automated Machine Learning: Evaluation and Comparison of AutoML Approaches and Tools.” *Proceedings - International Conference on Tools with Artificial Intelligence, ICTAI 2019-Novem* (November): 1471–79. <https://doi.org/10.1109/ICTAI.2019.00209>.
- Vabalas, Andrius, Emma Gowen, Ellen Poliakoff, and Alexander J. Casson. 2019. “Machine Learning Algorithm Validation with a Limited Sample Size.” *PLOS ONE* 14 (11): e0224365. <https://doi.org/10.1371/JOURNAL.PONE.0224365>.
- Vanfretti, Luigi, and V. S.Narasimham Arava. 2020. “Decision Tree-Based Classification of Multiple Operating Conditions for Power System Voltage Stability Assessment.” *International Journal of Electrical Power & Energy Systems* 123 (December): 106251. <https://doi.org/10.1016/J.IJEPES.2020.106251>.
- Wang, Chi, Qingyun Wu, Markus Weimer, and Erkang Zhu. 2019. “FLAML: A Fast and Lightweight AutoML Library.” *Proceedings of Machine Learning and Systems*, November. <https://doi.org/10.48550/arxiv.1911.04706>.
- Wang, Fei-Yue. 2010. “The Emergence of Intelligent Enterprises: From CPS to CPSS.” *IEEE Intelligent Systems* 25 (4): 85–88.
- Wang, Wei, Yan Huang, Yizhou Wang, and Liang Wang. 2014. “Generalized Autoencoder: A Neural Network Framework for Dimensionality Reduction.” *IEEE Computer Society Conference on Computer Vision and Pattern Recognition Workshops*, September, 496–503. <https://doi.org/10.1109/CVPRW.2014.79>.
- Waterson, Patrick, Jean Christophe Le Coze, and Henning Boje Andersen. 2017. “Recurring Themes in the Legacy of Jens Rasmussen.” *Applied Ergonomics*. {\copyright} Elsevier. <https://doi.org/10.1016/j.apergo.2016.10.002>.
- Weerakody, Philip B., Kok Wai Wong, Guanjin Wang, and Wendell Ela. 2021. “A Review of Irregular Time Series Data Handling with Gated Recurrent Neural Networks.” *Neurocomputing* 441 (June): 161–78. <https://doi.org/10.1016/J.NEUCOM.2021.02.046>.
- Wu, Hao, Qi Liu, and Xiaodong Liu. 2019. “A Review on Deep Learning Approaches to Image Classification and Object Segmentation.” *Computers, Materials & Continua* 60 (2): 575–97. <https://doi.org/10.32604/CMC.2019.03595>.
- Wu, Junjie. 2012. *Advances in K-Means Clustering: A Data Mining Thinking*. Springer Theses. Berlin, Heidelberg: Springer Berlin Heidelberg. <https://doi.org/10.1007/978-3-642-29807-3>.
- Xie, Jianwen, Jianhua Wu, and Qingquan Qian. 2009. “Feature Selection Algorithm Based on Association Rules Mining Method.” *Proceedings of the 2009 8th IEEE/ACIS International Conference on Computer and Information Science, ICIS 2009*, 357–62. <https://doi.org/10.1109/ICIS.2009.103>.
- Yang, Wenxian, Radoslaw Zimroz, Mayorkinos Papaelias, Ji-Hyun Yoo, Young-Kook Park, and Seung-Soo Han. 2022. “Predictive Maintenance System for Wafer Transport Robot

- Using K-Means Algorithm and Neural Network Model.” *Electronics* 2022, Vol. 11, Page 1324 11 (9): 1324. <https://doi.org/10.3390/ELECTRONICS11091324>.
- Yap, B. W., and C. H. Sim. 2011. “Comparisons of Various Types of Normality Tests.” *Journal of Statistical Computation and Simulation* 81 (12): 2141–55. <https://doi.org/10.1080/00949655.2010.520163>.
- Yi, Fengji, Wenlong Fu, and Huan Liang. 2023. “Model-Based Reinforcement Learning: A Survey.” *Foundations and Trends® in Machine Learning* 16 (1): 1–118. <https://doi.org/10.1561/22000000086>.
- Yoo, Youngjin. 2015. “It Is Not about Size: A Further Thought on Big Data.” *Journal of Information Technology* 30 (1): 63–65. [https://doi.org/10.1057/JIT.2014.30/ASSET/JIT.2014.30.FP.PNG\\_V03](https://doi.org/10.1057/JIT.2014.30/ASSET/JIT.2014.30.FP.PNG_V03).
- Yu, Yong, Xiaosheng Si, Changhua Hu, and Jianxun Zhang. 2019. “A Review of Recurrent Neural Networks: LSTM Cells and Network Architectures.” *Neural Computation* 31 (7): 1235–70. [https://doi.org/10.1162/NECO\\_A\\_01199](https://doi.org/10.1162/NECO_A_01199).
- Zaadnoordijk, Lorijn, Tarek R. Besold, and Rhodri Cusack. 2022. “Lessons from Infant Learning for Unsupervised Machine Learning.” *Nature Machine Intelligence* 2022 4:6 4 (6): 510–20. <https://doi.org/10.1038/s42256-022-00488-2>.
- Zaharah Allah, Bukhsh, Aaqib Saeed, Irina Stipanovic, and Andre G. Doree. 2019. “Predictive Maintenance Using Tree-Based Classification Techniques: A Case of Railway Switches.” *Transportation Research Part C: Emerging Technologies* 101 (April): 35–54. <https://doi.org/10.1016/J.TRC.2019.02.001>.
- Zaki, Mohammed J., and Wagner Meira, Jr. 2014. “Data Mining and Analysis: Fundamental Concepts and Algorithms.” *Data Mining and Analysis*, May. <https://doi.org/10.1017/CBO9780511810114>.
- Zendehboudi, Alireza, M. A. Baseer, and R. Saidur. 2018. “Application of Support Vector Machine Models for Forecasting Solar and Wind Energy Resources: A Review.” *Journal of Cleaner Production* 199 (October): 272–85. <https://doi.org/10.1016/J.JCLEPRO.2018.07.164>.
- Zhang, Qianli, Weifei Hu, Zhenyu Liu, and Jianrong Tan. 2020. “TBM Performance Prediction with Bayesian Optimization and Automated Machine Learning.” *Tunnelling and Underground Space Technology* 103 (September): 103493. <https://doi.org/10.1016/J.TUST.2020.103493>.
- ZhengRuiqi, QuLiang, CuiBin, ShiYuhui, and YinHongzhi. 2023. “AutoML for Deep Recommender Systems: A Survey.” *ACM Transactions on Information Systems*, March. <https://doi.org/10.1145/3579355>.
- Zhuang, Xiaowei, Zhengshi Yang, and Dietmar Cordes. 2020. “A Technical Review of Canonical Correlation Analysis for Neuroscience Applications.” *Human Brain Mapping* 41 (13): 3807–33. <https://doi.org/10.1002/HBM.25090>.