



**HAL**  
open science

# Intelligence des données au service de la gestion optimisée des urgences hospitalières

Khouloud Fakhfakh

► **To cite this version:**

Khouloud Fakhfakh. Intelligence des données au service de la gestion optimisée des urgences hospitalières. Intelligence artificielle [cs.AI]. Centrale Lille, 2022. Français. NNT: . tel-04470834

**HAL Id: tel-04470834**

**<https://hal.science/tel-04470834v1>**

Submitted on 21 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.

## Centrale Lille

École doctorale SPI-MADIS

Unité de recherche CRISTAL UMR 9189

Thèse présentée par Khouloud Fakhfakh-Maala

Soutenue le 18 novembre 2022

En vue de l'obtention du grade de docteur de l'école centrale de Lille

Discipline Automatique, Génie Informatique, Traitement du signal et des images

# Intelligence des données au service de la gestion optimisée des urgences hospitalières

Thèse dirigée par Slim Hammadi directeur  
Hayfa Zgaya-Biau co-directeur

### Composition du jury

<i>Rapporteurs</i>	Alassane B.Ndiaye Jean-Charles Billaut	professeur à l'Université Libre de Bruxelles professeur à l'Université de Tours (EPU)
<i>Examineurs</i>	Aziz Moukrim Christophe Bortolaso Jean-Marie Renard Laetitia Jourdan	professeur à l'Université de Technologie de Compiègne responsable R&D à Berger-Levrault MCF PH au CHU de Lille professeur à l'université de Lille
<i>Directeurs de thèse</i>	Slim Hammadi Hayfa Zgaya-Biau	professeur au Centrale Lille Institut professeur à l'Université de Lille

# Remerciement

Je tiens à exprimer ma profonde gratitude à mon directeur de thèse Monsieur Slim Hammadi, Professeur à l'École Centrale de Lille, et ma codirectrice Madame Hayfa Zgaya-Biau, Professeur à l'ILIS de l'Université de Lille 2, de m'avoir soutenue, encouragée et encadrée tout au long de cette thèse et des efforts qu'ils ont consentis, les précieux conseils qu'ils ont prodigués qui ont permis l'aboutissement de ce travail ainsi que pour m'avoir fait bénéficier amplement de leur rigueur scientifique et de leurs critiques objectives.

Mes plus sincères remerciements s'adressent à Monsieur Jean Charles Billaut, Professeur à l'Université de Tours et Monsieur Alassane B.Ndiaye, Professeur à l'École Polytechnique de l'Université libre de Bruxelles pour l'honneur qu'ils m'ont fait d'accepter de rapporter mes travaux de thèse et d'y avoir porté tant d'intérêt. Je les remercie énormément pour le temps consacré à cet effet malgré toutes leurs responsabilités.

Je remercie également les autres membres du jury pour avoir accepté d'être les examinateurs de cette thèse, j'adresse donc des remerciements particuliers à Monsieur Christophe Bortolaso Responsable R&D au sein de l'entreprise Berger Levrault et Monsieur Aziz Moukrim Professeur à l'Université de Technologie de Compiègne-Centrale de recherche Royallieu. Je remercie vivement Monsieur Jean-Marie Renard, Praticien Hospitalier et Maître de Conférences à l'Université de Lille et Madame Laetitia Jourdan, Professeure à l'université de Lille.

Je tiens également à exprimer ma profonde gratitude aux membres du CHRU de Lille, plus particulièrement Messieurs Jean-Marie Renard et Grégoire de m'avoir accueillie au sein de cet établissement et de m'avoir fourni des données utiles et des explications précieuses qui m'ont aidée à travailler sur un sujet passionnant.

Je remercie également Monsieur Alain Tixier fondateur et CEO de l'entreprise Fingertips d'avoir accepté mon invitation à cette thèse, ainsi pour sa confiance et son soutien.

Enfin, j'exprime toute ma gratitude envers tous ceux qui n'ont pas hésité à m'aider, particulièrement aux membres de mon équipe OSL Madame Sarah Ben Othman et Madame Faiza Ajmi, ainsi que le personnel de l'administration du CRISTAL et l'école centrale de Lille pour leur disponibilité et serviabilité.

## **Dédicace**

*A mon cher papa, je te dédie particulièrement cette thèse avec tous mes vœux de bonheur et de bonne santé. Tes sacrifices, ton soutien moral et matériel, ton profond attachement m'ont permis de réussir mes études. Sans ton aide, tes précieux conseils et tes encouragements ce travail n'aurait vu le jour.*

*A mon cher époux pour son amour, sa présence et ses encouragements sans faille,*

*A ma douce maman et mon frère pour tout leur amour, leur affection sans limites et leur soutien,*

*A la mémoire de ma belle-mère et mon beau-père,  
A mes beaux-frères et mes belles-sœurs,  
A toute ma famille,  
A tous ceux et celles qui me sont chers,*

*Je vous rends hommage par ce modeste travail en guise de ma reconnaissance éternelle et de mon incommensurable amour.*



## COLOPHON

Mémoire de thèse intitulé « Intelligence des données au service de la gestion optimisée des urgences hospitalières », écrit par Khoulood FAKHFAKH-MAALA, achevé le 9 novembre 2022, composé au moyen du système de préparation de document `LATEX` et de la classe `yathesis` dédiée aux thèses préparées en France.

# Table des matières

<b>Table des matières</b>	iii
<b>Liste des tableaux</b>	xi
<b>Table des figures</b>	xiii
<b>Introduction générale</b>	1
<b>I L'impact de l'IA dans le domaine de la santé</b>	3
<b>1.1 Introduction</b>	3
<b>1.2 Généralités sur l'IA</b>	4
<b>1.2.1 Définitions et l'historique de l'IA</b>	4
<b>1.2.2 Les types des approches d'IA</b>	6
<b>1.2.2.1 Les approches d'IA symbolique</b>	6
<b>1.2.2.2 Les approches d'IA subsymbolique</b>	6
<b>1.2.3 Les domaines d'application de l'IA en santé</b>	7
<b>1.2.3.1 L'IA pour la prédiction et le diagnostic des maladies</b>	7
<b>1.2.3.2 L'IA pour le développement des produits pharmaceutiques</b>	9
<b>1.2.3.3 L'IA pour la surveillance de l'état de santé des patients</b>	10
<b>1.2.3.4 L'IA pour l'anticipation des pandémies</b>	11
<b>1.2.3.5 L'IA pour l'aide à la chirurgie</b>	12
<b>1.2.3.6 L'IA pour les opérations hospitalières</b>	12
<b>1.3 L'IA : Solution pour anticiper les tensions aux SUs</b>	13
<b>1.3.1 Le service des urgences</b>	14
<b>1.3.1.1 Description et fonctionnement du SU</b>	14
<b>1.3.1.2 Les limites des services d'Urgences</b>	16
<b>1.3.2 Le système de triage au SU</b>	17

1.3.3	Qu'est-ce que la tension aux urgences?	18
1.3.3.1	Définition de la tension	18
1.3.3.2	Les causes des situations de tension aux urgences	20
1.3.3.3	Conséquences des situations de tension au SU	22
1.3.3.4	Les indicateurs de tension dans les services des urgences	23
1.3.3.5	La gestion des situations de tension	24
1.3.4	L'impact de l'IA sur le fonctionnement du SU	25
1.4	L'imperfection des connaissances médicales dans les SU : Vers l'IA symbolique	25
1.5	Problématique de la thèse	27
1.6	Conclusion	29
<b>2</b>	<b>Intelligence des données médicales : Des données vers les connaissances</b>	<b>31</b>
2.1	Introduction	31
2.2	L'ingénierie des connaissances	31
2.2.1	Recueil des connaissances	32
2.2.2	Modélisation des connaissances	32
2.2.3	Représentation des connaissances	33
2.3	Les ontologies	33
2.3.1	Définitions d'une ontologie	34
2.3.2	Les composants d'une ontologie	34
2.3.3	L'application des ontologies	35
2.3.4	Les méthodes de développement des ontologies.	36
2.3.4.1	La méthode de Gruninger et Fox (TOVE)	36
2.3.4.2	La méthodologie de Uschold et King	36
2.3.4.3	La méthode de Bernaras	37
2.3.4.4	La méthode Terminae	37
2.3.4.5	La méthodologie Methontology	37
2.3.5	Les types d'ontologies	38
2.3.5.1	Les ontologies de haut niveau	39
2.3.5.2	Les ontologies de domaine	39
2.3.5.3	Les ontologies de tâches	40
2.3.5.4	Les ontologies d'application	41
2.3.6	Le Langage OWL (Ontology Web Language)	42
2.3.7	L'évaluation des ontologies	43
2.3.8	Le raisonnement sémantique classique	43

2.3.8.1	Les raisonneurs sémantiques	43
2.3.8.2	Les règles SWRL (Semantic Web Rule Language)	44
2.3.9	Les formalismes de représentation des connaissances	45
2.3.9.1	Les logiques de descriptions	45
2.3.9.2	Les limites des logiques de description	46
2.4	Les ontologies floues	46
2.4.1	Les logiques de descriptions floues	47
2.4.2	Définition des ontologies Floues	47
2.4.3	Les composants des ontologies floues	47
2.4.3.1	Les concepts flous	47
2.4.3.2	Les relations floues	48
2.4.3.3	Les axiomes	48
2.4.3.4	Les instances	49
2.5	Les ontologies médicales	49
2.5.1	Les ontologies de standardisation médicales	49
2.5.1.1	La classification ICD	49
2.5.1.2	SNOMED CT	50
2.5.1.3	Le thésaurus MeSH	50
2.5.1.4	L'ontologie FMA	50
2.5.1.5	L'ontologie DOLCE	51
2.5.1.6	Le projet CISMef	51
2.5.2	Les ontologies en santé	51
2.5.2.1	Systèmes d'information en santé (SIS)	51
2.5.2.2	Les dossiers de santé électroniques (DES)	52
2.5.2.3	Systèmes d'aide à la décision clinique (SADC)	52
2.6	La gestion des connaissances imparfaites	53
2.6.1	Causes des connaissances imparfaites	53
2.6.2	Typologie de l'imperfections des données	53
2.6.2.1	Les incertitudes sur les données	53
2.6.2.2	Les imprécisions des données	54
2.6.2.3	L'incomplétude des données	54
2.6.3	Choix d'une méthode de traitement des données	54
2.6.4	Les approches de gestion des connaissances imparfaites	55
2.6.4.1	La logique floue	55
2.6.4.2	La théorie des possibilités	58

2.6.4.3	La théorie de Dempster Shafer(D-S)	59
2.6.4.3.1	L'exemple de la théorie D-S	60
2.7	Synthèse : Vers un modèle intelligent	61
2.8	Conclusion	63
<b>3</b>	<b>L'apprentissage Artificiel en santé : Outils et approches</b>	<b>65</b>
3.1	Introduction	65
3.2	Le prétraitement des données	65
3.2.1	Nettoyage des données	67
3.2.2	Intégration des données	67
3.2.3	Transformation des données	68
3.2.4	Réduction des données	68
3.3	L'apprentissage automatique	69
3.3.1	Les catégories d'apprentissage automatique	69
3.3.1.1	Apprentissage supervisé	70
3.3.1.2	Apprentissage non supervisé	71
3.3.1.3	Apprentissage semi-supervisé	71
3.3.1.4	Apprentissage par renforcement	71
3.3.1.5	Apprentissage auto-supervisé (SSL)	72
3.3.2	Les techniques d'apprentissage automatique	72
3.3.2.1	Les réseaux de neurones (Artificiel Neural Networks ou ANN)	72
3.3.2.2	Les arbres de décision (Decision Tree ou DT)	74
3.3.2.3	Machine à vecteurs de support (Support vector machine ou SVM)	76
3.3.2.4	Régression logistique et multinomiale	76
3.3.2.5	Les K plus proches voisins (K-Nearest Neighbours ou KNN)	77
3.3.3	Evaluation et validation des modèles d'apprentissages	78
3.3.3.1	Mesures de performances	78
3.3.3.2	Généralisation et surajustement (overfitting)	80
3.4	Techniques de l'apprentissage par renforcement	81
3.4.1	Généralité sur l'apprentissage par renforcement	81
3.4.2	Processus de décision de Markov (MDP) et algorithme d'itération des valeurs	82
3.4.3	L'algorithme Q-Learning	82
3.5	L'apprentissage automatique et le domaine de santé	83
3.5.1	Le diagnostic médical	84
3.5.2	Découverte de médicaments	84

3.5.3	Les urgences hospitalières	85
3.6	Synthèses et Positionnement	86
3.7	Conclusion	88
<b>4</b>	<b>Proposition d'une approche hybride d'extraction des connaissances et de structuration des données : Vers une conception des ontologies de domaines et des ontologies rationnelles des urgences</b>	<b>89</b>
4.1	Introduction	89
4.2	Architecture globale du système proposé	90
4.3	Les données médicales et ses structurations	92
4.4	Les ontologies proposées du domaine de SUA	92
4.4.1	L'ontologie OntoTriS proposée	94
4.4.1.1	Développement de l'ontologie OntoTriS	94
4.4.1.2	La structure de l'ontologie OntoTriS	95
4.4.1.2.1	Niveau générique de OntoTris	96
4.4.1.2.2	Niveau de domaine de OntoTriS	96
4.4.1.2.3	Niveau des cas de OntoTriS	98
4.4.1.3	Le fonctionnement de l'ontologie OntoTris	99
4.4.1.4	Le score F-ESI 1.0 proposé	101
4.4.2	L'ontologie FOTS proposée	105
4.4.2.1	La méthode FOntoM proposée pour le développement des ontologies Floues	105
4.4.2.2	Ontologie proposée FOTS « Fuzzy Ontology for Triage System »	106
4.4.2.2.1	La structure de l'ontologie FOTS	107
4.4.2.2.2	Le score F-ESI 2.0 de l'ontologie FOTS	110
4.4.3	L'ontologie EDOMO proposée	114
4.4.3.1	Méthodologie de développement de l'ontologie	114
4.4.3.2	Les modèles de l'ontologie EDOMO	115
4.4.3.2.1	Modèle de domaine	115
4.4.3.2.2	Modèle de cas	117
4.4.3.2.3	Modèle de raisonnement	117
4.4.3.3	Identification des IPC pertinents basée sur EDOMO	118
4.4.3.4	La gestion de la tension basée sur EDOMO	120
4.4.3.4.1	Le score OES proposé	120
4.4.3.4.2	Actions de gestion de la tension	121
4.5	L'extraction des connaissances et Le pré-traitement des données médicales	122

4.6	Conclusion	124
<b>5</b>	<b>Approches et algorithmes d'apprentissage automatique appliqués aux urgences</b>	<b>125</b>
5.1	Introduction	125
5.2	Analyses statistiques des données cliniques	126
5.2.1	Les flux d'arrivées au SUA	126
5.2.2	Le temps d'attente au SUA	128
5.2.3	Classification CCMU	128
5.2.4	L'admission post urgences	129
5.3	Modèle de prédiction de l'admission hospitalière du patient dès son arrivée	132
5.3.1	L'algorithme Perceptron Multicouche (MLP)	132
5.3.1.1	La Backpropagation par Descente de Gradient	133
5.3.2	L'algorithme DDMLP (Dynamic Dempster Multi Layers Perceptron)	135
5.3.2.1	Poids de croyances pondérées (WBA)	136
5.3.2.1.1	WBA de la couche d'entrée	136
5.3.2.1.2	WBA de la couche cachée	137
5.3.2.2	La description de l'algorithme DDMLP	137
5.4	Modèle de prévision du nombre d'arrivées aux urgences	140
5.4.1	Modèle LTSM (Long Short-Term Memory)	140
5.4.2	Modèle d'apprentissage par renforcement proposé	142
5.4.2.1	Formulation du modèle ED-deepMDPRL	143
5.4.2.2	Algorithme Deep Q-Learning pour la prévision des arrivées au SUA	144
5.5	Modèle de prédiction et d'orientation post-triage (Circuit court/ Circuit long/ Déchocage)	147
5.5.1	Les arbres de décision et les critères de division	147
5.5.2	L'algorithme C4.5	148
5.5.2.1	Répartitions du C4.5	148
5.5.2.2	Attributs de valeur inconnue	149
5.5.2.3	Valeur des attributs sur un intervalle continu	149
5.5.2.4	Élagage	149
5.5.2.5	C4.5 pour orienter les patients	149
5.5.3	L'algorithme D-C4.5 proposé	150
5.5.3.1	Rapport de gain d'information sur l'incertitude UIGR	150
5.5.3.2	Inducteur d'arbre D-C4.5	151
5.5.3.2.1	Critères de fractionnement	152

5.5.3.2.2	Critère d'arrêt	152
5.5.3.2.3	Traitement des attributs numériques	152
5.5.3.2.4	Traitement des attributs manquants	152
5.5.3.2.5	Processus de post-élimination	152
5.5.3.3	Description de l'algorithme D-C4.5	153
5.6	Conclusion	154
<b>6</b>	<b>Expérimentations et Résultats</b>	<b>155</b>
6.1	Introduction	155
6.2	Expérimentations et résultats du modèle de prédiction proposé pour l'hospitalisation du patient dès son arrivée aux urgences	155
6.2.1	Expérimentations : phase 1	156
6.2.2	Expérimentations : phase 2	157
6.2.2.1	1ère partie : Comparaison DDMLP vs DMLP et MLP	157
6.2.2.2	2ème partie : Comparaison DDMLP vs CART, RF, KNN et LR	158
6.2.3	Discussions	160
6.3	Expérimentations et résultats du modèle de prévision de l'affluence des patients	160
6.4	Expérimentations et résultats liés au modèle proposé d'aide au triage	163
6.4.1	Etude expérimentale	163
6.4.2	Discussions	165
6.5	Expérimentations et résultats du modèle de prédiction de l'orientation post-triage	167
6.5.1	C4.5 vs D-C4.5	168
6.5.2	D-C4.5 vs techniques usuelles de ML	171
6.6	Implémentation et simulation du SATGT proposé	173
6.7	Conclusion	178
	<b>Conclusion générale</b>	<b>179</b>
	<b>Bibliographie</b>	<b>181</b>





# Liste des tableaux

2.1 Les masses de fonctions de sources 1 et 2	60
2.2 Les masses de fonctions de source 1 et 4	61
2.3 La combinaison des deux possibilités de sources	61
3.1 Avantages et inconvénients des arbres de décision	76
3.2 Matrice de confusion pour la classification binaire	79
3.3 Résumé des références clés discutées	87
4.1 Structure de la base de données du CHU	93
4.2 Déclaration des classes principales de l'ontologie OntoTriS	97
4.3 Aperçu des propriétés d'objets définis dans OntoTriS	98
4.4 Aperçu des propriétés des données définies dans OntoTriS	98
4.5 Aperçu des axiomes et concepts définis dans OntoTriS	101
4.6 Identification d' $ESI_A^i$	103
4.7 Identification d' $ESI_{cc}^i$	103
4.8 Le calcul du score F-ESI 1.0	104
4.9 Une description détaillée des classes génériques (ontologie FOTS)	108
4.10 Aperçu des propriétés d'objets définis dans FOTS	108
4.11 Aperçu des axiomes et concepts définis dans OntoTriS	109
4.12 Exemple d'une propriété floue dans FOTS	110
4.13 le SD calculé pour le F-ESI 2.0	111
4.14 Le calcul du $SD_{age}$ (ontologie FOTS)	111
4.15 la classification des symptômes et leurs degrés de sévérité	112
4.16 Le calcul de $SD_{MH}$	112
4.17 Le calcul de $SD_{MO}$ (ontologie FOTS)	113
4.18 Le calcul du score F-ESI 2.0	114
4.19 Les concepts principaux d'EDOMO	115

4.20 Aperçu des propriétés définies dans EDOMO	116
4.21 Les valeurs seuils de chaque IPC	121
4.22 L'identification du score OES	121
5.1 Description des variables utilisées dans l'algorithme DDMLP	139
5.2 Les variables descriptives de l'état système	143
5.3 Description des variables utilisées dans l'algorithme ED-Deep MDPRL	146
6.1 Les BBA des données médicales du patient $P_1$	156
6.2 Le calcul des WBA pour la couche entrante	156
6.3 Le calcul des neurones entrants de la couche cachée	157
6.4 Les poids de la couche cachée	157
6.5 Le calcul de la couche sortante	157
6.6 Les résultats de la comparaison entre l'approche proposée, le MLP usuel et les données réelles	158
6.7 Les résultats d'expérimentations après 20 époques	158
6.8 Résultats de comparaison entre les méthodes CART, LR, RF, KNN et DDMLP	158
6.9 Les hyper paramètres de l'algorithme ED-Deep MDPRL	161
6.10 Les résultats de comparaison	161
6.11 Résultats de classifieurs	164
6.12 Comparaison du système proposé avec les autres techniques de ML	164
6.13 Comparaison entre l'algorithme C4.5 et D-C4.5 sans élagage	168
6.14 Comparaison entre l'algorithme C4.5 et D-C4.5 avec élagage	168
6.15 Résultats de comparaison entre le D-C4.5 et les techniques usuelles de ML	172
6.16 Comparaison entre les données réelles du SUA et les résultats du système proposé SATGT	174
6.17 Résultat de SATGT pour prédire l'affluence des patients et la tension	177

# Table des figures

1.1 La place d'IA dans la science informatique . . . . .	4
1.2 Aperçu de l'histoire de l'IA . . . . .	5
1.3 Les 10 principaux types de maladies considérés dans la littérature sur l'IA . . . . .	7
1.4 Applications d'IA au développement des médicaments . . . . .	9
1.5 Une vue d'ensemble des techniques d'IA les plus répandues, ainsi que des principaux besoins, défis et sous-domaines de l'IA utilisés dans la planification préopératoire, le guidage peropératoire et la robotique chirurgicale . . . . .	13
1.6 Structure générale des SU en France . . . . .	15
1.7 La chaîne des urgences . . . . .	16
1.8 Le principe du score CCMU . . . . .	18
1.9 Nombre de passages annuel aux SUs . . . . .	20
1.10 Evolution du nombre de lits d'hospitalisation depuis 2003 . . . . .	21
2.1 Méthode « MethOntology », (FERNÁNDEZ-LÓPEZ, GÓMEZ-PÉREZ et JURISTO [1997]) . . . . .	38
2.2 Typologie d'ontologies , (GHAZOUANI [2018]) . . . . .	38
2.3 Ontologie de haut niveau , (FAKHFAKH, MAALEL et FARHAT [2019]) . . . . .	39
2.4 Exemple d'une ontologie de domaine, (FAKHFAKH, MAALEL et FARHAT [2019]) . . . . .	40
2.5 Aperçu d'un exemple d'ontologie de tâches, (PANISSON et al. [2015]) . . . . .	41
2.6 Exemple d'une ontologie d'application, (NAUBOURG, SAVONNET et YÉTONGNON [2011]) . . . . .	42
2.7 Relation enfant de parents mariés (règle SWRL R1), (NAUBOURG, SAVONNET et YÉTONGNON [2011]) . . . . .	44
2.8 Aperçu des règles syntaxiques de la logique de descriptions , (WARREN et al. [2015]) . . . . .	45
2.9 Fonction d'appartenance de taux de glycémie normal , (HOUILI s. d.) . . . . .	48
2.10 Les méthodes de gestion des imperfections de connaissances , (BOUCHON-MEUNIER [2000]) . . . . .	55
2.11 La fonction d'appartenance A , (BOUCHON-MEUNIER [2000]) . . . . .	56
2.12 La fonction d'appartenance B , (BOUCHON-MEUNIER [2000]) . . . . .	57

2.13 Les étapes de la logique floue , (BOUCHON-MEUNIER 2000)	57
3.1 les étapes de prétraitement des données	66
3.2 La classification des techniques de ML	70
3.3 Structure de réseaux de neurones (YACIM et BOSHOF 2018)	73
3.4 Structure de réseaux de neurones (GARCÍA-GONZALO et al. 2016)	77
3.5 La fonction logistique est une fonction sigmoïde, qui met en correspondance des valeurs continues du domaine des nombres réels avec l'intervalle $[0, 1]$ , (GHAMRI 2016)	78
3.6 Le cycle d'apprentissage par renforcement. (RÜCKSTIESS 2016)	81
4.1 Architecture globale de la solution proposée : Système d'Aide au Triage et de Gestion de la Tension (SATGT)	91
4.2 Observation médicale pour un patient dans la base de données	92
4.3 Le diagramme de classe de l'ontologie OntoTriS	95
4.4 La structure de l'ontologie OntoTriS	96
4.5 Les classes génériques de l'ontologie OntoTriS	97
4.6 Niveau de cas d'OntoTriS	99
4.7 Le schéma global d'OntoTriS	100
4.8 Processus de génération du score F-ESI 1.0	102
4.9 Fuzzification de F-ESI 1.0 ( <i>l'axe des abscisses est <math>ESI_g</math></i> )	104
4.10 La méthode FOntoM proposée pour le développement d'ontologies floues (FAKHFAKH et al. 2021a)	106
4.11 Le diagramme de classe de l'ontologie FOTS	107
4.12 La structure de l'ontologie FOTS	109
4.13 Exemple d'un type de donnée flou	110
4.14 Le modèle flou de F-ESI 2.0	113
4.15 Les classes de l'ontologie proposée EDOMO	116
4.16 Schéma global de l'ontologie EDOMO	117
4.17 Un aperçu du modèle de cas et son lien avec le modèle de domaine	118
4.18 Les actions de gestion de la tension définies par EDOMO	122
4.19 Framework d'extraction des connaissances et d'informations cliniques basé sur OntoED	123
5.1 Aperçu de la base de données réelles (2016-2020) de CHU de Lille	126
5.2 l'affluence des patients par heure	127
5.3 l'affluence des patients par jour	127

5.4	L'affluence des patients par mois	127
5.5	La moyenne du temps d'attente par localisation	128
5.6	Temps d'attente selon l'heure d'admission	129
5.7	score CCMU par nombre de patients	130
5.8	La durée de séjour selon CCMU	130
5.9	Orientation post urgence par patient	131
5.10	Structure d'un MLP,(GHANI, DIHMANE, MANSOURI et al. [2017])	133
5.11	L'algorithme de la rétro-propagation de gradient,(GHANI, DIHMANE, MANSOURI et al. [2017])	134
5.12	Schéma global de l'approche proposée :phase de forward du DDMLP	136
5.13	Illustration de l'approche DDMLP	139
5.14	La structure du modèle LSTM	141
5.15	La structure du modèle Deep RL, (SARKER [2021])	145
6.1	Courbe de la phase BP pour les algorithmes MLP, DMLP, DDMLP	159
6.2	Courbe de la phase BP pour les algorithmes MLP, DMLP, DDMLP	159
6.3	Comparaison entre la méthode proposée et les données observées	162
6.4	les courbes ROC des modèles (a) KNN (b) LR (c) ANN (d)	165
6.5	Comparaison entre la méthode proposée et les données observées	166
6.6	Structure de l'arbre C4.5	169
6.7	Structure de l'arbre D-C4.5	170
6.8	Courbe ROC de C4.5 et D-C4.5	170
6.9	Comparaison entre la méthode proposée et les données observées	172
6.10	Comparaison entre le CCMU du système ResUrgence, le F-ESI 1.0 et le F-ESI 2.0	174
6.11	Comparaison entre l'orientation post triage du système ResUrgence et de modèle D-C4.5	175
6.12	Comparaison entre les résultats de prédiction du DDMLP et les données réelles	175
6.13	Les interfaces implémentées du SATGT	176
6.14	Comparaison entre les résultats de prédiction du DDMLP et les données réelles	177



# Introduction générale

Au cours de ces dernières années, les progrès liés aux technologies d'intelligence artificielle (IA) ont entraîné une croissance rapide de la recherche sur l'apprentissage automatique (ML) dans le domaine de la santé. Plus précisément, le développement d'applications intégrant l'apprentissage automatique a montré un grand potentiel au profit de la médecine d'urgence. Ces applications permettent de relever les défis actuels des services des urgences, tels que le triage et la prise en charge, la détection précoce des conditions et des résultats de tension, la gestion des opérations des services des urgences et l'intervention thérapeutique. Avec l'augmentation de la disponibilité des données cliniques, il est extrêmement avantageux pour les cliniciens de la médecine d'urgence de se baser sur des techniques de calcul automatique comme le ML, qui sont capables de traiter de manière significative de grandes quantités de données complexes. En revanche, ces techniques sont incapables aujourd'hui d'exploiter correctement les données non structurées textuelle. Dans le cadre de cette thèse, nous proposons une solution efficace à cette limite qui se base sur la combinaison de deux types d'approches d'IA : les approches symboliques (e.g les ontologies) et les approches subsymboliques (e.g ML). Les trois principales différences entre ces deux domaines sont les suivantes : (1) les approches symboliques produisent des conclusions logiques, alors que les approches sub-symboliques fournissent des résultats associatifs; (2) L'intervention humaine est courante dans les méthodes symboliques, alors que les approches subsymboliques apprennent et s'adaptent aux données; (3) Les méthodes symboliques sont plus performantes lorsqu'elles traitent des données relativement petites et précises, tandis que les méthodes subsymboliques sont capables de traiter des ensembles larges et bruyants de données. La combinaison de deux types d'approches peut être une solution potentielle pour résoudre le problème des données et créer un système d'aide à la décision efficace pour le service des urgences (SU). L'encombrement de ce service se produit lorsque la demande dépasse la capacité à fournir des soins dans un délai raisonnable (HENDERSON et BOYLE 2014). Ce problème est d'envergure internationale et touche les gouvernements, les hôpitaux, les prestataires de services et les utilisateurs de services (ASPLIN et al. 2003). Cela se traduit souvent par des risques pour la sécurité des patients et une diminution de leur satisfaction (CARTER, POUCH et LARSON 2014). En complément, le processus de triage est aussi très important pour assurer le bon déroulement de la prise en charge des patients aux urgences. La moindre erreur peut engendrer des conséquences graves sur l'état de santé des patients et augmenter ainsi le risque des situations de tension. Dans le cadre de cette thèse, nous proposons donc un modèle d'aide au triage qui est basé sur une ontologie de domaine. Cette dernière assure le bon fonctionnement du processus en intégrant un nouveau score qui calcule d'une manière précise le degré de l'état de sévérité du patient. L'ontologie, avec ses raisonnements sémantiques et les règles logiques intégrées, représente la partie symbolique. Elle a trois rôles principaux qui sont : (1) extraire les connaissances pertinentes à travers les données non structurées textuelles et les intégrer dans nos modèles de ML (subsymbologiques),(2) transformer les données brutes en des connaissances



en créant une base de cas patient ontologique et (3) raisonner sémantiquement en se basant sur des règles logiques pour le triage et la gestion de tension. Les approches subsymboliques sont présentées par des algorithmes d'apprentissages qui sont définis pour prédire l'hospitalisation des patients dès l'arrivée, l'orientation post-triage et l'affluence des patients. Pour améliorer la qualité des données, nous gérons l'incertitude en intégrant la théorie de Dempster-Shafer dans nos algorithmes. Cette thèse propose donc un système d'aide au triage et à la gestion de tension (SATGT) qui est basé sur une architecture hybride d'IA (symbolique et sub-symbolique). Ce manuscrit est organisé comme suit :

- Le chapitre 1 est dédié à la définition générale de l'IA et en particulier à l'étude de l'impact de l'IA sur le domaine de la santé. Dans ce chapitre, nous détaillons les différentes causes et solutions proposées de tension des urgences. Ensuite, nous spécifions la problématique et le terrain d'expérimentation de cette thèse.
- Le chapitre 2 présente un état de l'art sur les outils et approches de représentation des connaissances en particulier les ontologies, ciblant ainsi les ontologies médicales et les outils de gestion des connaissances imparfaites et incertaines.
- Le chapitre 3 commence par l'étude des méthodologies de traitement des données. Les techniques d'apprentissages sont ensuite définies et leurs impacts sur le domaine de la santé sont exposés. Dans la dernière partie de ce chapitre, nous précisons notre positionnement thématique.
- Le chapitre 4 commence par définir l'architecture hybride de notre système. Puis, nous décrivons les ontologies proposées et la technique d'extraction des connaissances associée.
- Le chapitre 5 présente dans un premier lieu une analyse statistique qui a permis de transcrire la réalité de notre terrain d'expérimentation (SUA) à l'aide des données cliniques historiques. Ensuite, nous définissons nos algorithmes de prédiction basés sur l'apprentissage qui permettent de prédire l'admission au moment de l'arrivée, l'orientation et l'affluence des patients.
- Le chapitre 6 est consacré aux résultats de différentes expérimentations effectuées sur les approches proposées tout au long de ce manuscrit. Nous commençons par présenter l'efficacité de nos approches d'apprentissage. Ensuite, nous simulons notre système proposé, le SATGT, en exposant les résultats réels obtenus.

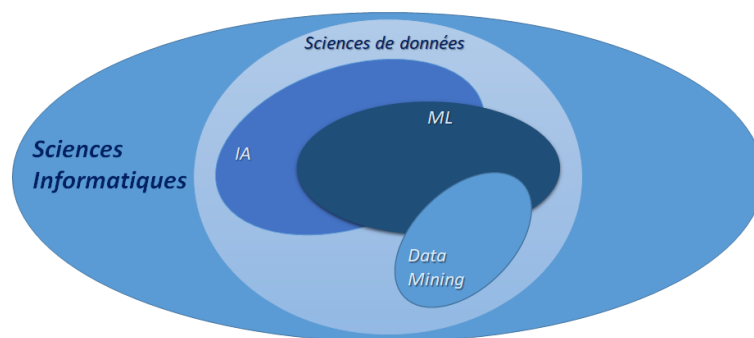
Enfin, une conclusion générale, des perspectives ainsi qu'une liste de références bibliographiques et des annexes termineront ce manuscrit de thèse.

# L'impact de l'IA dans le domaine de la santé

## 1.1 Introduction

Aujourd'hui, l'intelligence artificielle (IA) vise à imiter les fonctions cognitives humaines. Elle entraîne un changement de paradigme dans l'analyse de données et l'aide à la décision appliqués à la santé, grâce notamment à la disponibilité croissante des données cliniques et les progrès rapides des techniques d'analyse. L'IA peut être adoptée pour exploiter différents types de données médicales (structurées et non structurées). Récemment, les techniques d'IA ont provoqué de vastes vagues dans le domaine médical, alimentant même une discussion active sur la question de savoir si l'IA finira par remplacer les médecins dans l'avenir. Nous pensons que les médecins ne seront pas remplacés par des machines dans un avenir prévisible, mais l'IA peut certainement aider les médecins à prendre de meilleures décisions cliniques ou même remplacer le jugement subjonctif humain dans certains domaines fonctionnels de santé comme la radiologie et le triage. Grâce à la nouvelle réglementation T2A, la disponibilité des données cliniques est croissante et plus importante (MOISDON et PEPIN 2010). Par conséquent, le développement rapide des méthodes d'analyse des données massives « Big Data » ont rendu possibles les récents déploiements réussis de l'IA dans le domaine de la santé. Guidées par des questions pertinentes de santé publique, de puissantes techniques d'IA peuvent identifier des informations cliniques pertinentes cachées dans les quantités massives de données, qui peuvent à leur tour aider à une prise de décision clinique plus éclairée. Les techniques d'IA les plus connues comprennent les méthodes d'apprentissage automatique pour les données structurées, telles que les réseaux de neurones et les machines à vecteurs de support, l'apprentissage profond, ainsi que le traitement du langage naturel pour les données non structurées (WANG et PREININGER 2019).

Dans ce chapitre, nous définissons l'IA d'une manière générale. Ensuite, nous faisons le point sur l'importance des applications de l'IA dans le domaine de la santé et son avenir. Puis, nous présentons les solutions d'IA pour anticiper les situations de tension et améliorer la qualité de prise en charge aux urgences.



Source : (PANESAR 2019)


FIGURE 1.1 – La place d'IA dans la science informatique

## 1.2 Généralités sur l'IA

L'intelligence artificielle (IA) désigne un ensemble de technologies qui permettent aux machines et aux ordinateurs de simuler l'intelligence humaine. Les technologies utilisées sont basées sur du raisonnement logique, mathématique ou sémantique en définissant des approches d'IA symbolique et d'IA subsymbolique. Dans cette section, nous définissons l'IA en présentant brièvement son histoire. Ensuite, nous décrivons chaque type d'IA en se focalisant sur l'application de l'IA à la santé.

### 1.2.1 Définitions et l'historique de l'IA

L'IA est un sous-ensemble des sciences informatiques qui trouve essentiellement ses origines dans les mathématiques, la logique, la philosophie, la psychologie, les sciences cognitives et la biologie (Figure 1.1) (PANESAR 2019). Alan Turing (1950) est l'un des fondateurs des ordinateurs modernes et de l'IA. Le "test de Turing" est basé sur le fait que le comportement intelligent d'un ordinateur est la capacité d'atteindre des performances cognitives de l'être humain (MINTZ et BRODIE 2019). Six ans plus tard, John McCarthy décrit le terme "intelligence artificielle" (IA) comme "la science et l'ingénierie de la fabrication de machines intelligentes" (GREENHILL et EDMUNDS 2020; MALIK, PATHANIA, RATHAUR et al. 2019). L'IA a commencé par une simple série de règles "si, alors, sinon" et a progressé au cours de plusieurs décennies pour inclure des algorithmes plus complexes dont les performants miment le fonctionnement du cerveau humain. Il existe de nombreux domaines et sous-domaines de l'IA, le plus connu est le Machine Learning (ML) incluant l'apprentissage profond « Deep Learning » (DL) (KAUL, ENSLIN et GROSS 2020). Le ML consiste à utiliser des caractéristiques spécifiques pour identifier des modèles pouvant être exploités pour analyser une situation particulière. La machine peut ensuite "apprendre" à partir de ces informations et les utiliser au profit de scénarios futurs similaires. Il s'agit donc d'un outil précieux de prédiction très utile dans le domaine de la santé pour une aide à décision temps réel permettant ainsi d'individualiser les soins aux patients plutôt que de suivre un algorithme statique (KAUL, ENSLIN et GROSS 2020). Les années 1980 et 1990 ont vu un regain d'intérêt pour l'IA (MALIK, PATHANIA, RATHAUR et al. 2019). La figure 1.2 récapitule l'histoire de l'IA. Tout d'abord, cette dernière n'était que de la science-fiction dans les années 1920. Ensuite, dans les années 1950, un petit pas a été franchi, faisant passer l'IA de la fiction à la réalité. Alan



Source : [IA Hybride](#)

FIGURE 1.2 – Aperçu de l'histoire de l'IA

Turing a publié un article intitulé "Computing Machinery and Intelligence" et a introduit le jeu d'imitation (test de Turing) pour déterminer si une machine est intelligente ou non. Le test est très intuitif : si un juge humain, lorsqu'il est engagé dans une interaction avec un ordinateur, ne peut pas distinguer de manière fiable la machine de l'homme, alors la machine passe le test. Le terme "intelligence artificielle", en tant que terme scientifique respectable, a été inventé lors de la conférence de "Dartmouth" en 1956, organisée par Marvin Minsky, John McCarthy, et Shannon et Nathan Rochester. Un an plus tard, après l'introduction du perceptron, l'informaticien américain Arthur Samuel a inventé le terme "apprentissage automatique" (KAUL, ENSLIN et GROSS [2020]). L'apprentissage profond a été introduit par le mathématicien ukrainien Alexey Grigorevich en 1965 (ERGEN et al. [2019]), en empilant plusieurs perceptrons les uns sur les autres, ce qui ressemble aux architectures d'apprentissage profond actuelles inspirées des réseaux neuronaux (RN) du cerveau humain. Il y a eu quelques succès notables avant que l'IA n'entre en hibernation dans les années 1970, ce qui a duré une décennie. Dans les années 1980, Geoffrey Hinton et ses collaborateurs ont introduit la rétro propagation, un mécanisme permettant d'auto-optimiser les réseaux neuronaux artificiels sans une intervention humaine. Il s'agit d'un succès qui consiste à ajuster les poids des nœuds du RN sur plusieurs couches (HINTON et al. [1986]). En 1989, Yann LeCun a introduit le réseau neuronal convolutif (CNN) pour la reconnaissance d'images (LE CUN et al. [1989]). En 1991, Sepp Hochreiter a présenté un réseau neuronal récurrent (RNN), utile pour les tâches de séquençage (HOCHREITER et SCHMIDHUBER [1997]). En 1992, Bernhard E. Boser, Isabelle M. Guyon et Vladimir N. Vapnik ont introduit les Machines à Vecteurs de Support (SVM) afin de faciliter la classification des sentiments et la compréhension de la parole humaine qui est devenue plus efficace avec le traitement du langage naturel (BOSER, GUYON et VAPNIK [1992]). En 1997, Hochreiter et Jurgen Schmidhuber ont introduit la mémoire à long terme (LSTM) pour la traduction avancée de la parole en texte (HOCHREITER et SCHMIDHUBER [1997]).

Des techniques d'intelligence artificielle telles que les systèmes experts flous, les réseaux bayésiens, les réseaux neuronaux artificiels et les systèmes intelligents hybrides ont été utilisées dans différents contextes cliniques dans le domaine de la santé. En 2016, la plus grande partie des investissements dans la recherche sur l'IA concernait les applications de santé par rapport aux autres secteurs (RESEARCH [2017]). L'IA en médecine peut être dichotomisée en deux sous-types : Virtuelle et physique (HAMET et TREMBLAY [2017]). La partie virtuelle définit par des applications telles que les systèmes de dossiers médicaux électroniques aux conseils basés sur les réseaux neuronaux dans les décisions de traitement. La partie physique concerne les robots d'assistance aux opérations chirurgicales, les prothèses intelligentes pour les personnes handicapées et les soins aux personnes âgées.

## 1.2.2 Les types des approches d'IA


Dans la littérature, Il existe deux types approches principales de l'IA : l'approche subsymbolique et l'approche symbolique (MINSKY [1991]).

### 1.2.2.1 Les approches d'IA symbolique

Les techniques symboliques sont définies par des méthodes symboliques explicites, telles que les méthodes formelles et les langages de programmation, et sont généralement utilisées pour la connaissance déductive (HOGAN et al. [2021]). Elles consistent en des règles de logique du premier ordre, tandis que d'autres méthodes comprennent des règles, des ontologies, des arbres de décision, la planification et le raisonnement. Selon Benderskaya, l'IA symbolique est généralement associée aux bases de connaissances et aux systèmes experts, et elle est une continuation des machines de von Neumann et de Turing (BENDERSKAYA et ZHUKOVA [2013]). Une caractéristique clé des méthodes symboliques est leur capacité à expliquer et à raisonner sur la conclusion atteinte. En outre, même leurs étapes intermédiaires sont souvent explicables. Les systèmes symboliques fournissent un flux de calcul compréhensible par l'homme, ce qui les rend plus faciles à déboguer, à expliquer et à contrôler. En particulier, les systèmes à base de règles ont l'avantage de la modularité des règles, car ces derniers sont des unités de connaissance discrètes et autonomes qui peuvent facilement être insérées ou retirées d'une base de connaissance (HATZILYGEROUDIS et PRENTZAS [2004]). En outre, ils assurent l'interopérabilité des connaissances, ce qui signifie que le transfert de connaissances est possible dans des applications étroitement liées. Enfin, elles sont plus adaptées aux problèmes abstraits car elles ne dépendent pas fortement des données d'entrée. D'autre part, les méthodes symboliques ne sont généralement pas adaptées aux cas où les ensembles de données présentent des problèmes de qualité et peuvent être sujets au bruit (ILKOU et KOUTRAKI [2020]).

### 1.2.2.2 Les approches d'IA subsymbolique

Contrairement aux méthodes symboliques, où l'apprentissage se fait par la supervision et l'intervention humaine, les méthodes subsymboliques établissent des corrélations entre les variables d'entrée et de sortie. Ces relations sont très complexes et sont souvent formalisées par des fonctions qui relient les données entrantes aux données sortantes ou aux variables cibles (ILKOU et KOUTRAKI [2020]). Les méthodes subsymboliques représentent le mouvement connexionniste qui tente d'imiter le cerveau humain et son réseau complexe de neurones interconnectés avec les réseaux neuronaux artificiels (RNA). L'IA subsymbolique comprend des méthodes d'apprentissage statistique, telles que l'apprentissage bayésien, l'apprentissage profond, la rétropropagation et les algorithmes génétiques. Les méthodes subsymboliques sont plus robustes face aux données bruitées et manquantes, et elles ont généralement des performances de calcul élevées. Elles sont plus faciles à mettre à l'échelle et conviennent donc bien aux grands ensembles de données et aux grands graphes de connaissances. En outre, elles sont plus adaptées aux problèmes de perception et nécessitent moins de connaissances préalables. Cependant, les méthodes connexionnistes présentent certains inconvénients. Le plus important est le manque d'interprétabilité de ces méthodes. Cela constitue un obstacle majeur à leur applicabilité dans des domaines où les explications et les interprétations sont des points clés. À première vue, cela ne semble pas être un problème, mais il en résulte une incapacité à extrapoler les résultats à des instances non vues ou à des données qui ne suivent pas une distribution similaire à celle des données d'apprentissage.



Source : (JIANG et al. 2017)

FIGURE 1.3 – Les 10 principaux types de maladies considérés dans la littérature sur l'IA

En outre, en raison de la quantité généralement importante de paramètres à estimer dans les modèles subsymboliques, ceux-ci nécessitent une puissance de calcul et des quantités de données considérables. Un autre problème qui se pose est la disponibilité de données de haute qualité pour l'entraînement des algorithmes, qui sont souvent difficiles à trouver. Les données doivent être correctement structurées et avoir des représentants décents de la normale pour ne pas conduire à des résultats biaisés (NTOUTSI et al. 2020).

### 1.2.3 Les domaines d'application de l'IA en santé

Dans la littérature, il existe de nombreux exemples de déploiement de l'IA au profit des processus de soins. L'IA peut économiser le temps consacré à ces processus, fournir un diagnostic précis, tirer des conclusions à partir d'images et de rapports médicaux, surveiller l'état de santé et prédire l'apparition ou l'évolution de maladies, améliorer la qualité des soins, réduire les complications lors d'opérations chirurgicales, contrôler l'observance médicale et le mauvais usage des médicaments, fournir une aide à la prise de décision clinique et aider à gérer les crises comme les pandémies. Nous détaillons quelques exemples d'applications dans les sous-sections suivantes.

#### 1.2.3.1 L'IA pour la prédiction et le diagnostic des maladies

Le diagnostic des maladies affiche le besoin le plus urgent en termes d'IA dans le domaine de la biomédecine. Un certain nombre de percées intéressantes ont été réalisées dans ce domaine. L'IA permet aux professionnels de la santé de poser des diagnostics plus précoces et plus précis pour de nombreux types de maladies (GRABER, FRANKLIN et GORDON 2005). Malgré une littérature de plus en plus riche en termes d'IA dans le domaine de la santé, la recherche se concentre principalement sur quelques types de maladies : le cancer, les maladies du système nerveux et les maladies cardiovasculaires (Cf. figure 1.3) (JIANG et al. 2017). En effet, l'une des principales catégories de diagnostics repose sur les diagnostics in vitro à l'aide de biocapteurs ou de biopuces.

Par exemple, l'expression génétique, qui est un outil de diagnostic très important, peut être analysée par des algorithmes de ML, dans lequel l'IA interprète les données des biopuces pour classer et détecter les anomalies (MOLLA et al. 2004). Une application récente consiste à classer les données des biopuces pour le diagnostic du cancer (W SHI et al. 2017). Grâce à l'IA intégrée, les biocapteurs et les systèmes connexes de test au point de service (POCT) peuvent diagnostiquer les maladies cardiovasculaires à un stade précoce (VASHISTHA et al. 2018). En plus du diagnostic, l'IA peut aider à prédire les taux de survie des patients atteints de cancer, notamment du côlon (AHMED 2005).

En Italie, des chercheurs ont développé un système assisté par ordinateur pour le diagnostic des maladies cardiaques, utilisant l'intelligence artificielle. Le système est destiné à aider les médecins généralistes et les infirmiers qui ne sont pas spécialisés en cardiologie dans la prise de décision clinique. Le système reçoit des données anamnestiques (pré-informations) et instrumentales (liées aux instruments) et établit un diagnostic et un pronostic relatifs à l'état de santé actuel du patient. Le système tient également compte des antécédents cliniques du patient lorsqu'il établit un diagnostic.

Les chercheurs ont également identifié certaines limites du Machine Learning (ML) dans le diagnostic biomédical et ont suggéré des mesures pour minimiser les effets de ces inconvénients (FOSTER, KOPROWSKI et SKUFCA 2014). Une autre catégorie importante de solution pour le diagnostic des maladies est basée sur l'imagerie médicale (bidimensionnelle) et le traitement du signal (unidimensionnel). Ces techniques ont été utilisées pour le diagnostic, la gestion et la prédiction des maladies. Pour le traitement des signaux unidimensionnels, l'IA a été utilisée pour l'extraction de caractéristiques de signaux biomédicaux (KRISHNAN et ATHAVALE 2018), tels que l'électroencéphalographie (EEG) (HAMADA, ZAIDAN et ZAIDAN 2018), l'électromyographie (EMG) (KEHRI et al. 2016) et l'électrocardiographie (ECG) (RAI et CHATTERJEE 2018). Une application importante de l'EEG est la prédiction des crises d'épilepsie. Il est très important de prévoir les crises afin de minimiser leur impact sur le patient (COOK et al. 2013).

Ces dernières années, l'IA a été reconnue comme l'un des éléments clés d'un système de prédiction précis et fiable (ASSI et al. 2017). Il est désormais possible de prédire en se basant sur l'apprentissage profond (STACEY 2018), et la plateforme de prédiction peut être déployée dans un système mobile (KIRAL-KORNEK et al. 2018). L'IA peut également jouer un rôle important dans le diagnostic basé sur le traitement des images biomédicales (STORTSIS et al. 2006). Elle a été utilisée dans la segmentation des images (FASIHI et MIKHAEL 2016), l'imagerie multidimensionnelle (Jo et al. 2018) et l'imagerie thermique (GHAFARPOUR et al. 2016) pour améliorer la qualité des images et l'efficacité de l'analyse. L'IA peut également être déployée dans des appareils à ultrasons portables, afin que des personnes non formées puissent utiliser les ultrasons comme un outil puissant pour diagnostiquer de nombreux types de maladies dans les régions non développées (RONG et al. 2020).

Outre les applications ci-dessus, l'IA peut permettre aux systèmes standards d'aide à la décision (SAD) (FU et al. 2022) d'améliorer la précision des diagnostics et de faciliter la gestion des maladies, réduisant ainsi la charge de travail du personnel. Par exemple, l'IA a été utilisée dans la gestion intégrée du cancer (FIELD et al. 2022), pour soutenir le diagnostic et la gestion des maladies tropicales (RAHMAN et al. 2022) et des maladies cardiovasculaires (KHIABANI, BATANI et KHANMOHAMMADI 2022) pour améliorer le processus décisionnel des diagnostics (ELKIN et al.




FIGURE 1.4 – Applications d'IA au développement des médicaments

2018]). Ces applications montrent que l'IA peut être un outil puissant pour un diagnostic précoce et précis et même pour la prédiction des maladies et de l'évolution de l'état de santé des patients (RONG et al. 2020).

### 1.2.3.2 L'IA pour le développement des produits pharmaceutiques

L'IA joue un rôle très important dans la logistique pharmaceutique ainsi que dans le développement des produits pharmaceutiques. Elle peut aider à la conception rationnelle de médicaments (DUCH, SWAMINATHAN et MELLER 2007), à la prise de décision, à la détermination de la bonne thérapie pour un patient y compris les médicaments personnalisés, ainsi qu'à la gestion des données cliniques et leur utilisation pour le développement futur de médicaments (BLASIAK, KHONG et KEE 2020). E-VAI est une plateforme d'IA analytique et décisionnelle développée par Eularis, qui se base sur des algorithmes ML et une interface utilisateur facile à exploiter pour créer des feuilles de route analytiques (BARONZIO, PARMAR et BARONZIO 2015). Le but est de prédire les principaux moteurs de vente des produits pharmaceutiques, aidant ainsi les responsables marketing à allouer des ressources pour gagner un maximum de parts de marché, et inverser les mauvaises ventes. Les différentes applications de l'IA dans la découverte et le développement de médicaments sont résumées dans la figure 1.4 ci-dessous (PAUL et al. 2021). Avec la complexité croissante des processus de fabrication et l'exigence accrue en termes de qualité des produits, les systèmes de fabrication modernes tentent de conférer des connaissances humaines aux machines, modifiant continuellement les pratiques de fabrication (MEZIANE et al. 2000).

L'incorporation de l'IA dans la fabrication peut s'avérer être un coup de pouce pour l'industrie pharmaceutique. Des outils, tels que la CFD<sup>1</sup>, utilisent la technologie des solveurs NavierStokes à moyenne de Reynolds pour étudier l'impact de l'agitation et des niveaux de stress en exploitant l'automatisation de nombreuses opérations pharmaceutiques. Des systèmes similaires, tels que les simulations numériques directes et les simulations de grands remous, impliquent des approches avancées pour résoudre des problèmes d'écoulement compliqués dans la fabrication (RANTANEN et KHINAST 2015).

La nouvelle plate-forme Chemputer permet l'automatisation numérique de la synthèse et de la fabrication de molécules, en incorporant divers codes chimiques et en utilisant un langage

1. Computational Fluid Dynamics



de script connu sous le nom d'assemblage chimique (CHAN et al. 2019). Elle a été utilisée avec succès pour la synthèse et la fabrication du sildénafil, du chlorhydrate de diphénhydramine et du Rufin amide, avec un rendement et une pureté sensiblement similaires à ceux de la synthèse manuelle (STEINER et al. 2019). La DEM<sup>2</sup> a été largement utilisée dans l'industrie pharmaceutique, notamment pour étudier la ségrégation des poudres dans un mélange binaire, les effets de la variation de la vitesse et de la forme des pales, la prédiction de la trajectoire possible des comprimés dans le processus d'enrobage, ainsi que l'analyse du temps passé par les comprimés sous la zone de pulvérisation (RANTANEN et KHINAST 2015).

Les RNN, ainsi que les modèles flous, ont étudié la corrélation entre les réglages de la machine et le problème du bouchage afin de réduire le bouchage des comprimés sur la ligne de fabrication (DAS et CHAKRABORTY 2016). Le méta-classificateur et le classificateur de comprimés sont des outils d'IA qui aident à améliorer la qualité du produit final, en indiquant une erreur possible dans la fabrication du comprimé (GAMS et al. 2014). Un brevet a été déposé, démontrant un système capable de déterminer la combinaison de médicaments et de dosage la plus adaptée à chaque patient à l'aide d'un processeur recevant les informations du patient, et conçoit le timbre transdermique souhaité en conséquence (KRAFT 2019).

### 1.2.3.3 L'IA pour la surveillance de l'état de santé des patients

Facilitée par les technologies de capteurs avancées et l'augmentation de la puissance de calcul, l'acquisition et l'analyse continues de données physiologiques de patients à grande échelle ne sont plus à l'imagination. Curtis a présenté un système intégré sans fil pour surveiller les patients aux urgences (CURTIS et al. 2008). Dans cette étude, un prototype de système évolutif de technologie de réponse aux alertes médicales (SMART) a été piloté et un déploiement à petite échelle a été effectué. Dans une étude récente de Clifton, un système intégré de surveillance des patients a été développé et validé à grande échelle dans les urgences (CLIFTON et al. 2012). Ce système intégré est relié à un réseau d'égal à égal de moniteurs au chevet des patients et de PDA<sup>3</sup> mobile. Les auteurs ont comparé deux systèmes d'alerte précoce (EWS<sup>4</sup>) développés sur le système intégré et le système manuel traditionnel. Le vaste essai clinique rapporté a également évalué des méthodes automatiques d'évaluation des patients basées sur des dossiers médicaux électroniques complétés par des techniques d'IA.

En général, les systèmes intégrés de surveillance des patients sont associés à des composants d'IA pour la prise de décision assistée. D'autres études de recherche ont porté sur l'utilisation d'outils d'IA pour traiter des données physiologiques telles que l'électrocardiographie dans le contexte de l'urgence (TAKCI 2022). Des algorithmes RNN et ML ont également été utilisés pour prédire la mortalité à l'hôpital chez des patients subissant une réparation d'anévrisme aortique abdominal. Les chercheurs ont utilisé des variables cliniques telles que les antécédents du patient, les médicaments, la pression artérielle et la durée du séjour pour alimenter les algorithmes RNN (KARTHI, ARVINHLAKSHMAN, ASHWANTH et al. 2021). Le système de prédiction a généré des prédictions de la mortalité hospitalière avec une sensibilité de 87%, une spécificité de 96,10% et une précision de 95,40% (NAEMI et al. 2021). La société finlandaise Kaiku health a développé une plateforme d'intervention sanitaire pour la surveillance et la gestion des symptômes afin

---

2. Discrete Element Modeling  
3. personal digital assistant  
4. early warning systems

d'améliorer la qualité de vie et le taux de survie des patients atteints de cancer (LIVANAINEN et al. 2019). Une étude, menée auprès de 766 patients atteints de cancer métastatique et dont l'objectif est d'évaluer l'efficacité du suivi des symptômes avec Kaiku, montre que le suivi numérique des symptômes pendant la chimiothérapie prolonge la durée de vie globale des patients de 5,2 mois, améliore leur qualité de vie dans 31% des cas et réduit les hospitalisations de 4% et les visites aux urgences de 7% (SANZ-GARCIA et al. 2022).

#### 1.2.3.4 L'IA pour l'anticipation des pandémies

Des chercheurs de plusieurs domaines font la course pour soutenir la réaction à la COVID-19 dans un effort exceptionnel de collaboration scientifique. Pour produire un effet à l'échelle mondiale grâce aux outils d'IA, il faudrait des stratégies évolutives de partage des données, des modèles et des codes, ainsi qu'une adaptation des applications aux contextes locaux et une collaboration transfrontalière (LUENGO-OROZ et al. 2020). Il existe actuellement des dizaines d'efforts de partage de données centrés sur la COVID-19, aux niveaux mondial, national et local. Les séquences génétiques, les analyses génomiques, les structures protéiques, les informations cliniques sur les patients, l'imagerie médicale, les données sur les événements, les informations épidémiologiques, les données sur les mouvements, les commentaires sur les médias sociaux, les articles de presse et la littérature scientifique ne sont que quelques-unes des ressources disponibles.

L'hyper-fragmentation des activités de partage de données est un problème car elle pourrait conduire à des avancées limitées à des projets et des communautés spécifiques. La création et la diffusion de nouvelles applications pourraient être accélérées par l'établissement de techniques évolutives de partage des données, des modèles et des codes. Des activités de partage de données mondiales, ouvertes, complètes, comparables et vérifiables seront utiles à ce stade pour connecter et promouvoir la coopération entre diverses communautés et géographies (BERMEJO-PELÁEZ et al. 2022; BIKDELI et al. 2020). La science ouverte, aidée par des collaborations multipartites en matière d'IA qui fonctionnent au-delà des frontières internationales, peut accélérer la distribution des informations et le renforcement des capacités dans les systèmes hospitaliers nationaux (BATIHA et al. 2021).

Le réseau «EIOS<sup>5</sup>», par exemple, utilise des données provenant d'une source ouverte pour permettre la détection précoce, la vérification et l'évaluation des risques et des menaces pour la santé publique (SUCHARITHA et CHARY 2021). Le déploiement de l'IA dans le domaine de la santé implique des gouvernements, des organisations internationales et des instituts de recherche qui collaborent pour évaluer et partager des informations concernant les occurrences d'épidémies en temps réel selon le principe de la collaboration plutôt que de la concurrence pour la détection précoce. Selon les épidémiologistes, les normes mondiales et l'interopérabilité des bases de données peuvent faciliter une réaction et une prise de décision unifiées aux niveaux mondial, national et local. Pour comprendre les caractéristiques épidémiologiques et les facteurs de risque de divers groupes démographiques à mesure que la pandémie progresse, il faudra tenir compte de la capacité des ressources du système de santé, des mesures de santé publique, des facteurs environnementaux et des conséquences sociétales de la COVID-19 (SUCHARITHA et CHARY 2021).

---

5. Epidemic Intelligence from Open Sources

Le partage de modèles d'IA pré-entraînés et approuvés pourrait aider les solutions à s'adapter plus rapidement à différentes situations. Les modèles utilisés pour diagnostiquer des maladies à partir d'images, prévoir les résultats des patients, filtrer les désinformations et les fausses informations en fonction des modèles de propagation à travers les médias sociaux, et distiller des graphes de connaissances à partir de collections massives d'articles savants sont des exemples d'algorithmes qui pourraient être largement utiles (LUENGO-OROZ et al. [2020]; SHAHEEN [2021]; HARRER et al. [2019]).

#### 1.2.3.5 L'IA pour l'aide à la chirurgie

L'IA a été introduite en chirurgie plus récemment, avec un fort ancrage dans l'imagerie et la navigation et des techniques précoces axées sur la détection des caractéristiques et l'intervention assistée par ordinateur, tant pour la planification que pour le guidage préopératoires (ZHOU et al. [2020]). Au fil des années, des algorithmes supervisés, tels que des modèles de formes actives, des méthodes basées sur des atlas et des classificateurs statistiques ont été développés (vitiello2012emergin). Les récents succès des réseaux de neurones convolutifs profonds (DCNN<sup>6</sup>, tels qu'AlexNet (KRIZHEVSKY et al. [2012]), ont permis d'utiliser des descripteurs guidés par les données et appris automatiquement pour la compréhension des images, qui ont montré une meilleure robustesse et généralisation par rapport aux caractéristiques ad hoc créées à la main.

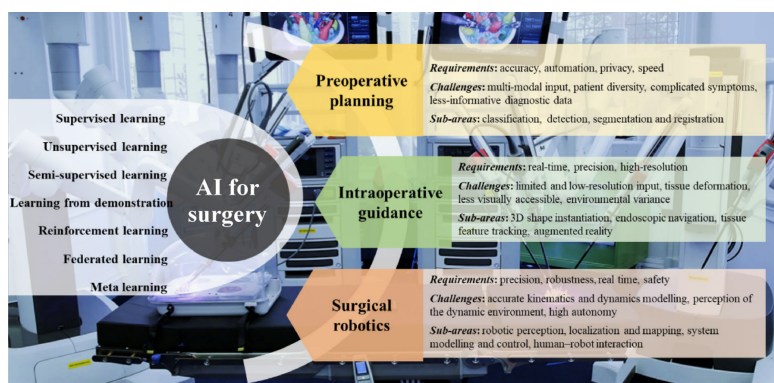
La robotique étant de plus en plus utilisée en chirurgie (ZHOU et al. [2020]). Différents niveaux d'autonomie peuvent permettre au chirurgien et au système robotique de naviguer ensemble dans des environnements en constante évolution et spécifiques au patient, une situation qui peut réduire la capacité de l'un ou l'autre à accomplir efficacement une tâche chirurgicale. De plus, en tirant parti des progrès médicaux parallèles en matière de détection précoce et de thérapie ciblée, l'IA peut garantir l'exécution de l'intervention appropriée. Les futurs robots chirurgicaux devraient être capables de percevoir et de comprendre un environnement complexe (ALIP et al. [2022]), de prendre des décisions en temps réel et d'exécuter les tâches souhaitées avec une précision, une sécurité et une efficacité accrues. Les techniques d'IA les plus répandues, ainsi qu'un aperçu de leurs exigences, de leurs défis et de leurs sous-domaines en chirurgie sont résumées dans la figure 1.5 (ZHOU et al. [2020]).

#### 1.2.3.6 L'IA pour les opérations hospitalières

La planification des ressources et la gestion de la foule sont des tâches importantes dans les urgences. Dans (SUN et al. [2009]), les auteurs ont utilisé une technique d'analyse de séries chronologiques appelée moyenne mobile intégrée autorégressive (ARIMA) pour élaborer des modèles de prévision de la charge de travail aux urgences. Leur recherche a montré l'évidence de l'utilisation des modèles de prévision pour la mise en place de la liste du personnel et la planification des ressources. Dans l'étude de (JONES et EVANS [2008]), les auteurs se sont concentrés sur le problème de tension dans les urgences en évaluant l'impact de la configuration du personnel médical grâce à un outil de simulation développé à base d'agents. La faisabilité de cet outil a été également évaluée.

---

6. Deep Convolutional Neural Network



Source : (ZHOU et al. [2020](#))

FIGURE 1.5 – Une vue d’ensemble des techniques d’IA les plus répandues, ainsi que des principaux besoins, défis et sous-domaines de l’IA utilisés dans la planification préopératoire, le guidage peropératoire et la robotique chirurgicale

Les outils de décision diagnostique sont essentiels aux urgences pour le dépistage et la stratification des patients. Haug a proposé un système de modélisation diagnostique qui pourrait potentiellement automatiser la création d’applications d’aide à la décision diagnostique (HAUG et al. [2013](#)). Le système a été validé dans l’urgence et a démontré la possibilité de l’étendre à d’autres départements. De même, Grigull et Lechner ont utilisé des techniques d’exploration de données pour soutenir les décisions diagnostiques dans un service d’urgence pédiatrique (GRIGULL et LECHNER [2012](#)). Les outils d’IA et d’apprentissage automatique ont également été largement adoptés à diverses fins opérationnelles dans les urgences (SÁNCHEZ-SALMERÓN et al. [2022](#)). Par exemple, Zmiri a mis en œuvre plusieurs méthodes d’exploration de données, notamment les algorithmes Naïve Bayes et C4.5, pour trier les patients des urgences en mesurant leur degré de gravité (ZMIRI, SHAHAR et TAIEB-MAIMON [2012](#)). De même, Goto a utilisé plusieurs approches d’apprentissage automatique pour prédire les dispositions des services d’urgence afin de faciliter le triage des patients souffrant d’asthme et de bronchopneumopathie chronique obstructive (BPCO) (GOTO et al. [2018](#)). Yadav (YADAV et al. [2016](#)) a proposé une classification automatisée des résultats des rapports de tomodensitométrie (CT) des urgences pour les patients adultes et pédiatriques, où des systèmes hybrides de traitement du langage naturel (NLP) et d’apprentissage automatique ont été construits. Le NLP a joué un rôle important dans une autre étude (LIU et al. [2018](#)) dans laquelle les auteurs ont proposé un cadre automatisé d’évaluation subjective, objective et plan (SOAP<sup>7</sup>) pour les rapports des services d’urgence. Dans ce contexte, nous développons l’idée de l’utilisation de l’IA et son impact pour les SU dans la section suivante.

### 1.3 L’IA : Solution pour anticiper les tensions aux SUs

Quelle que soit l’urgence, vitale ou non, le rôle des services d’urgence est d’accueillir tous types de patients, sans sélection. Pour cela, le risque de la tension est très élevé au sein de ce service. Pour résoudre ce problème, différentes solutions basées sur l’IA sont proposées dans la littérature. Par exemple, la prédiction de l’encombrement des urgences (CALDAS et SOARES [2022](#)),

7. Subjective, Objective, Assessment, Plan

la prévision de l'affluence des patients (ZHAO et al. [2022]), la prédiction du temps d'attentes (SULEIMAN et al. [2022]), l'aide au triage (GAO et al. [2022]), la prédiction de l'admission (BRINK et al. [2022]) et l'optimisation de parcours patient (EDELMAAN et al. [2022]). Nous définissons dans ce qui suit les services d'urgence et le besoin d'utiliser l'IA pour améliorer la qualité des soins et anticiper les tensions.

### 1.3.1 Le service des urgences

La prise en charge aux urgences forme une discipline à part entière, répondant à un besoin spécifique de Santé Publique en prenant en compte l'importance de la santé humaine. En France, le service des urgences (SU) est accessible à toutes les personnes qui ont besoin des soins spécifiques (urgentes ou non urgentes). Le personnel soignant au SU doit prendre en charge médicalement tout patient se présentant, même s'il ne relève pas de l'urgence. Dans ce qui suit nous commençons par la définition du service des urgences avant de détailler les problèmes rencontrés.

#### 1.3.1.1 Description et fonctionnement du SU

Selon (BAILEY, MURPHY et POROCK [2011]), le service des urgences est la principale porte d'entrée de l'hôpital. Il constitue donc un passage évident pour les patients avant leur admission dans la plupart des services hospitaliers. Cette situation rend le soin dans les SU valable 24h/24h sans rendez-vous et 365 jours par an, y compris les jours fériés. Les patients arrivent soit avec leur propre moyen, soit par un moyen de secours qui sont le SAMU (service d'aide médicale urgente), le SMUR (service mobile d'urgence et de réanimation), les pompiers, la police, les militaires, les marins pompiers et les secouristes bénévoles, soit orienté par un médecin. En France l'urgence médicale présente un établissement de service public qui effectue l'accueil et le traitement des patients tout en garantissant l'égalité, l'accessibilité, la permanence et la continuité des soins. Selon la Société française de médecine d'urgence (SFMU), l'urgence est une toute circonstance qui, par sa survenue ou sa découverte, introduit ou laisse supposer un risque fonctionnel ou vital si une action médicale n'est pas entreprise immédiatement.

Dans la littérature, il y'a plusieurs propositions concernant la définition d'un SU (GAYRARD [S. d.]). Il existe parfois une ambiguïté dans cette définition et un écart significatif entre la définition médicale de l'urgence par un personnel soignant et le patient. Les flux entrants et les flux sortants d'un SU et les acteurs qui le composent permettent de le décrire comme un système complexe. En outre, l'activité au sein d'un SU se caractérise par l'irrégularité de la quantité et de la nature du travail demandé (KADRI [2014]). Cette complexité est due aux flux d'entrées au SU qui ne cessent d'augmenter. Plus de 19 millions de patients consultent les SU chaque année, entraînant des difficultés de gestion sur toute la chaîne logistique hospitalière du SU. En France, il existe environ 709 structures d'urgence situées dans les hôpitaux publics et les cliniques. Selon le département de la recherche statistique, environ 15% des patients qui se présentent aux SU sont arrivés via un système de secours et plus de la moitié des blessés et malades arrivent par leurs propres moyens. En effet, la prise en charge des patients s'effectue selon différents modes, c'est-à-dire en fonction du type de soins nécessaires (Figure [1.6]) :

- Soins programmés;
- Soins non programmés urgents : répondent aux besoins des patients souffrant d'un problème de santé qui peut relever de l'urgence vitale et la prise en charge doit être immédiate;

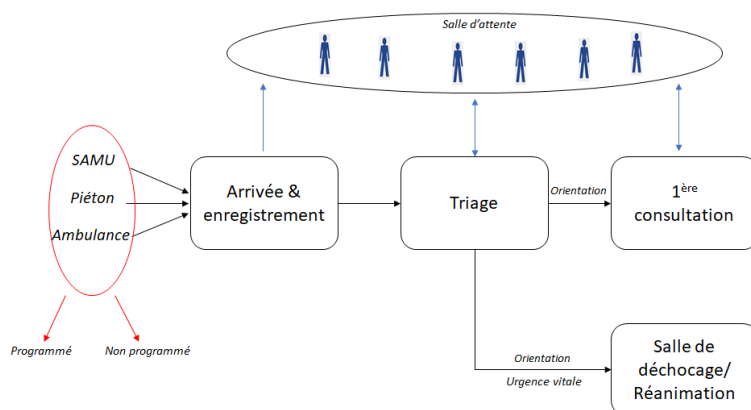



FIGURE 1.6 – Structure générale des SU en France

- Soins non programmés non urgents : répondent aux besoins des patients souffrant d'un problème de santé qui ne relève pas de l'urgence vitale mais dont la prise en charge ne peut être ni anticipée ni retardée.

Dans la majorité des SUs, le volume d'admission varie peu d'un jour à l'autre, d'un jour de semaine à un week-end ou d'une saison à l'autre. En 2018, 21.8 millions de passages ont été enregistrés dans les 709 structures des urgences françaises, soit 2% de plus qu'en 2017 (BERGONZONI et al. [2020]). Ces chiffres concernent la France métropolitaine, hors service de santé des armées (SSA). Cette progression est constante depuis vingt ans (3,4% par an en moyenne). Chaque SU reçoit en moyenne 30 800 patients par an. Ce nombre est moins important dans les services des urgences pédiatriques (27 300 passages en moyenne et par an) que dans les services des urgences adultes (31 300 passages en moyenne et par an). De plus, il existe 101 SAMUs et 387 SMURs en France métropolitaine qui assurent l'orientation, le transfert des patients et la prise en charge pré-hospitalière si nécessaire avec l'aide d'un médecin spécialiste. La chaîne logistique hospitalière des urgences cherche une démarche d'amélioration continue de la qualité des soins.

Néanmoins, vu l'augmentation de 3,4% du nombre de passages moyen et les cas urgents non programmés qui arrivent aux urgences. Les SUs sont confrontés à des demandes contrastées mais ils ont du mal à les gérer ce qui engendre des situations fréquentes d'engorgement. Lorsque la demande est supérieure à l'offre, il s'ensuit généralement une situation de tension qui est connue comme un problème mondial (HOYLE [2013]), (PASCASIE et MTSHALI [2014]). En effet, la tension dans les SUs est due à un nombre très élevé de patients dans les zones de traitement, qui dépasse la capacité réelle des urgences et réclame ainsi des prises en charge dans les couloirs des SUs et dans d'autres zones d'examen improvisées (HUSSEIN et al. [2017]). En outre, la tension aux urgences est la conséquence de l'engorgement et la saturation des hôpitaux. Par conséquent, l'optimisation et l'amélioration de la partie amont, intra et aval de la chaîne logistique hospitalière des urgences peuvent être une solution potentielle pour résoudre ce problème. En effet, l'amont des urgences représente toute la partie qui précède l'entrée réelle du patient dans le service. L'intra définit les tâches de soins établis aux urgences et illustre le parcours patient à partir du début de sa prise en charge. L'aval décrit le processus de sortie et l'orientation des patients après la fin de la prise en charge aux urgences (Figure [1.7]) (AJMI [2021]). Dans la section suivante, nous détaillons les défaillances des SUs dans chaque partie de la chaîne logistique.





Source : (AJMI 2021)

FIGURE 1.7 – La chaîne des urgences

### 1.3.1.2 Les limites des services d'Urgences

Les défaillances du SU sont très diverses. La résolution de ces problèmes dépend fortement de leurs origines. En se basant sur les travaux existants (KADRI 2014; CHANDOUK 2015) et en collaboration avec des personnels de santé, nous trouvons que les problèmes les plus connus dans les SUs sont :

- Les pics d'activité : la planification des activités médicales dans un SU est très difficile dans sa nature. Généralement, parmi les caractéristiques de l'activité, il y a la présence des pics qui sont composés de deux types :
  - Les pics d'activité intrinsèques au service : ce phénomène dépend globalement des modifications de l'état clinique des patients. L'état physiologique de ces derniers (qui est toujours instable) nécessite une adaptation dynamique de l'organisation des soins, ce qui caractérise précisément les services des urgences et de réanimation. Pendant la journée, certaines tâches deviennent inutiles, d'autres extrêmement urgentes, déjà prévues ou non urgentes mais présentent une probabilité de devenir urgente, ce qui explique une partie de l'imprévisibilité de l'activité,
  - Les pics d'activité extrinsèques correspondent à l'arrivée et donc l'admission de nouveaux patients dans ces services qui ne sont pas programmés. Le flux des patients est donc irrégulier. Cette irrégularité ne donne pas la possibilité d'établir une planification à l'avance et pose des problèmes d'organisation aux personnels de santé.
- Les interférences entre les activités hospitalières : Ce problème résulte des interférences permanentes entre l'activité programmée et l'activité non programmée. Ce qui présente l'une des problématiques majeures à laquelle sont confrontées les urgences hospitalières de manière continue. A notre connaissance, il n'y en a encore aucune solution satisfaisante pour ce problème. Particulièrement, l'activité non programmée urgente présente le grand débat dans ce sujet. En outre, le terme d'urgence, regroupe deux phénomènes distincts :
  - des flux récurrents qui peuvent présenter des variations saisonnières mais dont les tendances moyennes à court terme (heure, journée), moyen terme (semaine, mois) ou long terme (trimestre, année) sont connues. L'implémentation d'une structure ou d'une organisation et d'un pilotage à court terme présente un défi majeur pour atteindre un niveau d'efficacité satisfaisant pour chaque système de soins dans le monde,

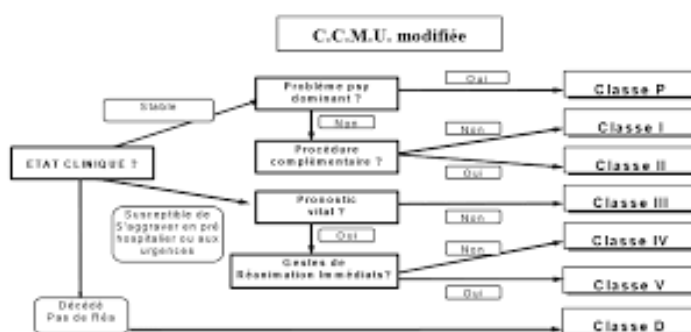
- des flux consécutifs à des crises sanitaires, imprévus et inconnus.
- Les événements exceptionnels : menaces sanitaires liées à des épidémies, canicules, vagues de froid, etc. Il s'agit d'événements qui nécessitent de mettre en place des mesures de recevoir des flux plus importants de patients pour des traitements médicaux et/ou chirurgicaux.
- Les problèmes liés aux flux des processus : dans la gestion des SU, la maîtrise des flux (i.e., nombre d'arrivées, informations, produits, équipements) sont des enjeux majeurs. La prise de conscience de cet enjeu est de plus en plus forte (KADRI 2014). Ainsi, la majorité des difficultés observées actuellement dans les SUs sont dues à la gestion de ces flux.
- Les problèmes liés au système de triage actuel qui présentent une décision subjective de la part des infirmiers de triage ou cette décision dépend :
  - des connaissances pratiques acquises par l'expérience et la formation ;
  - de l'identification appropriée des signes et symptômes ;
  - de l'usage de guides et de protocoles.

Aussi, le triage est une opération sensible qui expose au risque de passer à côté des pathologies graves et ne permet pas de réduire les consultations non urgentes. Donc, il faut évaluer régulièrement la pertinence du tri. Bien qu'il soit recommandé que des tris soient achevés en 2 à 5 minutes, Travers a démontré que cet objectif n'a été respecté que dans 22% des cas (TRAVERS 1999). Les enfants et les personnes âgées nécessitent plus de temps que les autres patients. Néanmoins, l'attente est la principale cause de violence. En Suisse (YERSIN 2006), en 2005, plus de 600 patients ont quitté le centre des urgences avant l'examen médical, soumis à des délais d'attente pouvant aller jusqu'à plusieurs heures (parfois plus de six heures). L'utilité réelle du triage dans un SU dépend ainsi des capacités des équipes à intégrer la priorité dans l'organisation des filières de soins et à mettre en place des procédures d'évaluation (ROY et LANNEHOA 2002). En outre, l'absence d'une définition consensuelle de ce qui constitue une urgence, d'outils fiables pour la reconnaître et d'un consensus sur le rôle exact des urgences explique l'impossibilité d'identifier le patient «non urgent», et donc de légitimer le refus de soins en urgence (HUGLI et al. 2006).

### 1.3.2 Le système de triage au SU

Le Guide de gestion de l'urgence du ministère de la Santé et des Services sociaux (MONTREUIL s. d.) définit le triage comme l'activité consistant à déterminer le degré de priorité des patients à la suite de l'évaluation effectuée par l'infirmier(ère), et à déterminer le délai souhaitable entre l'arrivée du patient et l'évaluation médicale. Les délais prescrits constituent des buts à atteindre. En effet, le triage consiste à évaluer la condition du patient et à déterminer le niveau de priorité des soins selon une classification prédéterminée par le système de santé. Le triage peut impliquer aussi une réévaluation périodique et systématique des patients qui attendent d'être pris en charge sur le plan médical. Mais ce procès dépend du système sanitaire du Pays. Le but premier du triage est le repérage rapide des patients requérant une intervention urgente. Il est donc primordial que l'infirmier(ère) au triage soit en mesure de prendre contact avec le patient dans un délai maximal de dix minutes suivant son arrivée (BEVERIDGE et al. 1998). En ce sens, la principale cible de l'évaluation infirmier(ère) au triage est l'attribution d'un niveau de priorité en fonction des motifs de venue des patients aux urgences, plutôt que l'amorce d'un diagnostic clinique ou d'un traitement. Les échelles de triage hospitalier comprennent cinq niveaux de gravité, ils sont fondées principalement sur le motif (symptôme) de consultation du patient (et non pas sur le diagnostic). En France, le personnel de santé utilisent le score CCMU





Source : DREES

FIGURE 1.8 – Le principe du score CCMU

(Classification clinique des malades aux urgences) ou la « french emergency nurses classification in hospitals » (grille FRENCH cf. annexe A) qui permettent d'identifier le niveau de l'état de sévérité d'un patient (score de 1 à 5) (Figure 1.8). Il est important de noter que la classification du CCMU est basé sur le score ESI mais le score 1 de CCMU est égal le score 5 de ESI.

### 1.3.3 Qu'est-ce que la tension aux urgences ?

La tension aux urgences est un problème mondial préoccupant qui a été identifié comme une crise nationale dans certains pays (SALWAY et al. 2017). L'engorgement des urgences est défini comme "la situation dans laquelle le fonctionnement des urgences est entravé principalement en raison du nombre excessif de patients qui attendent d'être examinés, évalués et traités, ou qui attendent leur départ, par rapport au nombre des personnels soignant (BAHADORI et al. 2017)". La sécurité et la confidentialité des patients (CALLEJA et FORREST 2011), la rapidité des services (HEDON 2003) et la frustration du personnel des urgences (GARCÍA-FERNÁNDEZ et al. 2022) doivent être prises en compte dans les études sur le surpeuplement des urgences. Pour cela, nous développons dans cette partie ce problème, ses causes principales et ses conséquences.

#### 1.3.3.1 Définition de la tension

Une situation de tension dans un service d'urgence peut ainsi être définie comme un déséquilibre entre (KADRI 2014) :

- le flux de la charge en soins : le nombre de patients entrant, le nombre de patients sortant, le nombre de fugues et le nombre de patients abandonnant les urgences sans être traités,
- la capacité de soins (moyens humains et matériels) : le nombre de médecins, d'infirmier(e)s, d'auxiliaires de soins, le nombre de box, de lits et le matériel médical.

En effet, la gestion de la tension présente un défi mondial (SALWAY et al. 2017) qui est l'origine principal de plusieurs difficultés dans le système sanitaire telles qu'un nombre de patients très élevé dans les zones de traitements, un temps d'attente très long qui prolonge la durée de séjours des patients, des soins médicaux dans les couloirs du SU et une mauvaise prise en charge. Par conséquent, la tension réduit la qualité des soins, diminue la satisfaction des patients et rend le nombre de personnel insuffisant pour gérer le flux d'arriver.

L'encombrement des urgences complique la tâche des médecins urgentistes de remplir les obligations morales envers les patients et surtout de faire face aux prises en charge non urgents, les arrivées en SAMU et les réanimations non programmées (Moskop et al. 2019). Ce qui provoque des conséquences graves sur la qualité des soins au SU comme l'augmentation de la probabilité des erreurs médicales (PINES et al. 2011; BERNSTEIN et al. 2009), l'insatisfaction des patients (PINES et al. 2011) et les détournements des ambulances (PAUL, REDDY et DEFLITCH 2010). Aussi, l'un des principaux défis à relever dans des urgences en situation de tension, est de trouver un équilibre entre le respect de la vie privée et de l'autonomie des patients et les efforts pour trouver un espace disponible pour les traitements urgents (Stoklosa et al. 2018). Étant donné que les retards dans la prestation des soins d'urgence entraînent une morbidité et une mortalité accrues, la meilleure décision est souvent d'évaluer et de traiter les patients aussi rapidement que possible malgré les risques pour leur vie privée et leur dignité. Les médecins urgentistes ont peu de contrôle sur les entrées et les sorties au SU, mais ils peuvent essayer de rendre les processus de soins plus efficaces et efficaces. En améliorant l'efficacité des urgences, les médecins urgentistes peuvent réduire les dommages causés par les soins tardifs.


Bien qu'il n'existe pas de définition précise de la tension aux urgences, plusieurs études ont fourni diverses descriptions à ce phénomène. Dans (SALWAY et al. 2017), les auteurs ont défini une situation de tension, « lorsque il n'y a plus de place pour répondre aux besoins d'un prochain patient qui nécessite des soins aux urgences ». Dans (HUSSEIN et al. 2017), les auteurs ont indiqué que le SU est en situation de tension s'il y a « un excès extrême de patients dans les zones de traitement, dépassant la capacité du SU et nécessitant fréquemment des soins médicaux dans les couloirs du SU et dans d'autres zones d'examen ». Ce qui nous pousse à penser que les attentes au SU sont le résultat d'une mauvaise gestion des urgences et à un dysfonctionnement dans une partie de la chaîne logistique hospitalière. Cependant, la maîtrise de ce phénomène demande une réflexion plus générale.

D'ailleurs, plusieurs études (SALWAY et al. 2017) ont déduit que la tension aux urgences dépend en grande partie de leur fonctionnement interne ainsi qu'à une surcharge à l'échelle de l'hôpital. Dans ce contexte, les partenaires du projet ANR HOST (2012-2015)<sup>8</sup> ont ajouté l'aspect temporel en définissant un état de tension aux urgences comme : « un déséquilibre entre le flux de charge des soins et la capacité de prise en charge sur une durée suffisante pouvant entraîner des conséquences néfastes au bon fonctionnement » (CHANDOUX 2015). Ce projet avait pour but de modéliser, de développer, d'optimiser et de mettre en œuvre un système d'aide à la décision (SAD) pour anticiper les situations de tension aux urgences pédiatriques du centre hospitalier universitaire (CHU) de Lille. Nous trouvons aussi la FEDORU<sup>9</sup> française qui a défini la tension aux SU comme « une inadéquation entre la demande (flux entrant de patients et besoins d'hospitalisation), les moyens disponibles au niveau des urgences (personnel, plateau technique et structure des urgences) et de l'aval des urgences (lits d'hospitalisation disponibles et fluidité du transfert en lits d'aval) ». Alors, chaque définition dans la littérature définit l'encombrement avec des horizons bien précis et met le point sur l'importance de proposer des solutions afin de la gérer en améliorant toute la chaîne des urgences : l'amont, l'intra et l'aval.

---

8. HOST : Hôpital Optimisation, Simulation et évitement des Tensions

9. FEDORU : Fédération des Observatoires Régionaux des Urgences



Source : [DREES 2021](#)

FIGURE 1.9 – Nombre de passages annuel aux SU


### 1.3.3.2 Les causes des situations de tension aux urgences

L'augmentation massive de l'afflux des patients présente le facteur principal de la tension aux SU (Figure 1.9). Cette augmentation est due à la nature de la population qui est plus ou moins vieille, à la facilité d'accès aux urgences, aux épidémies saisonnières (la grippe), au changement climatique et à la difficulté d'avoir un rendez-vous proche pour un soin non programmé (vu la saturation des hôpitaux). Bien que le coût de passage aux urgences soit différent entre les systèmes de soins, cet aspect reste très coûteux pour la majorité des pays surtout lorsque l'assurance médicale prend en charge le coût. Par exemple, en France, ce coût est d'environ 70 euros si le patient retourne chez lui après la prise en charge et il est complètement pris en charge par l'assurance maladie. Dans le système américain, ce coût est d'environ 1 000 dollars et il est souvent à la charge du patient s'il n'a pas de mutuelle. En se basant sur le rapport FEDORU<sup>10</sup>, il y a 20 millions de passages aux SU en 2017 dont 18% de patients non urgents (CCMU=1) contre 20% en 2019. En revanche, le nombre de passages en 2020 a diminué de 21.6% en relation avec la pandémie. Ces chiffres permettent de conclure que les français n'hésitent pas de consulter aux urgences même pour des symptômes légers. Par conséquent, ce facteur présente un avantage pour l'augmentation des arrivées aux SU. Les patients non urgents présentent une charge de travail faible et leur hospitalisation est très rare.

En outre, la plupart des professionnels de santé n'ont pas à leur disposition des outils adaptés permettant de prédire le nombre d'arrivées journaliers aux SU et donc prédire les admissions et anticiper les afflux. Par conséquent, la pathologie d'un patient doit être prise en considération lors de l'évaluation du niveau de tension parce que l'évolution de l'état de santé de ce dernier détermine la charge de travail associée. L'afflux important à l'amont des urgences peut entraîner une tension au début du parcours patient (attente primaire). Néanmoins, cet afflux n'engendre pas automatiquement une tension dans la chaîne des urgences, notamment si le reste du processus de soins fonctionne correctement.

La perturbation de la chaîne suite à une erreur dans le processus triage (Section cf. 1.3.2), qui permet de classer les patients selon leurs états de sévérité et ainsi les orienter vers les parcours adéquats, peut augmenter le risque d'encombrement. Ainsi, un manque ou un dysfonctionnement dans une partie du processus de la prise en charge des patients par un personnel de santé (infirmie(ère)s de triage, médecin, ...) peut déclencher une saturation dans le processus de

10. [FEDORU : Fédération des Observatoires Régionaux des Urgences](#)



Source : [DREES 2021](#)

FIGURE 1.10 – Evolution du nombre de lits d'hospitalisation depuis 2003

soins. L'effectif des soignants, qui reste approximatif, est déterminé en fonction de la dimension du SU et l'historique des situations de tension constatées. Bien qu'il y ait une pénurie des ressources humaines surtout la nuit, les jours fériés et le dimanche, il est crucial de calculer le rapport entre le nombre des patients présents et le nombre de médecins dans SU pour évaluer une situation de tension. Un manque de ressources humaines engendre une augmentation de temps d'attente (attente primaire et attente secondaire) accru et excessif qui peut être la cause d'une détérioration de l'état de santé du patient. Lors d'une situation de tension, l'infirmier de triage peut sous ou sur évaluer l'état d'un patient. Cela implique non seulement un erreur d'orientation qui peut augmenter le temps d'attente du patient mais aussi une contribution à la saturation du service et un risque de mortalité suite à un retard de prise en charge pour un cas urgent. D'une part, l'organisation et la gestion d'un SU sont complexes à cause d'un environnement incertain, une multitude des acteurs et des métiers impliqués (gouvernement, compagnies d'assurance, organisation professionnelles, logisticiens, etc.), l'influence de l'extérieur (amont, aval) et des facteurs externes difficiles à maîtriser comme le climat, les épidémies saisonnières et les pandémies. Ces éléments mettent les SU face à de nombreuses difficultés, alors que ce système devrait simplement fournir des soins techniques avec des soins de confort et de bien-être. Donc, des outils d'aide au pilotage, prévision et prédiction pour des professionnels de santé peuvent faciliter leurs tâches au cours d'une situation de tension et même avant.

Néanmoins, une augmentation massive d'afflux de patients peut engendrer aussi une saturation de l'aval des urgences qui est reconnue comme un élément majeur de la tension des SU. Actuellement, la recherche d'une place libre d'hospitalisation rend le délai d'attente d'un lit parmi les indicateurs les plus pertinents de la tension aux urgences françaises (NOEL, DRIGUES et VIJDES [2018](#)). En effet, la hausse du nombre d'hospitalisations et la diminution du nombre de lits d'hospitalisation en France provoque une saturation de l'aval des SU. La figure [1.10](#) montre l'évolution du nombre de lits d'hospitalisation depuis 2003 (MCO : médecine, chirurgie, obstétrique et odontologie; SSR : soins de suite et de réadaptation; USLD : unité de soins de longue durée). Ce nombre a baissé de 13% entre 2012 et 2019 ce qui peut être expliqué par un appel plus régulier à la chirurgie ambulatoire (BERGONZONI et al. [2020](#)). Dans la littérature, plusieurs études ont montré que la saturation d'un service d'aval a un impact direct et persistant sur l'engorgement des SU. Ainsi, plusieurs outils d'aide à l'optimisation et à la gestion d'aval des urgences ont été proposés afin de prédire et d'anticiper l'hospitalisation d'un patient au moment de son arrivée aux urgences (NOEL et al. [2019](#); CAMERON et al. [2017](#)).

### 1.3.3.3 Conséquences des situations de tension au SU

Les conséquences des situations de tension sont parfois graves et incontrôlables. Les études retenues qui examinent l'impact des situations de tension aux urgences peuvent être classées en trois grandes catégories : les effets sur le patient, le personnel et le système hospitalier (MORLEY et al. 2018). Les effets sur le patient comprennent les retards dans l'évaluation et la prestation des soins requis (LIU et al. 2011; REZNEK et al. 2017; TSAI et al. 2016; LINDEN, MEESTER et LINDEN 2016; PINES et al. 2009), la fréquence accrue de l'exposition à l'erreur (LEE et al. 2012), y compris les erreurs médicamenteuses (KULSTAD et al. 2010), la diminution de la satisfaction du patient (TEKWANI et al. 2013), l'augmentation de la durée du séjour du patient hospitalisé (DSPI) (NIPPAK et al. 2014; SINGER et al. 2011; SUN et al. 2013) et la détérioration de l'état de santé (PINES et al. 2009; SINGER et al. 2011; ZHOU et al. 2012). Ces derniers incluent une augmentation de la mortalité des patients hospitalisés (GUTTMANN et al. 2011; JO et al. 2015; SINGER et al. 2011; SUN et al. 2013; MCCUSKER et al. 2014). En effet, il existe dans la littérature plusieurs études qui exposent les différentes conséquences de tension notamment :

- Du retard dans l'évaluation et le traitement : Plusieurs cas de retards dans les SU suite à des situations de tensions ont été identifiés. Nous citons les retards dans l'intervention chirurgicale chez les patients se présentant aux urgences bondées avec une fracture du col du fémur selon une étude australienne (RICHARDSON et McMAHON 2009). Aussi, deux études ont rapporté des impacts négatifs de l'encombrement sur la rapidité des soins aux patients victimes d'un accident vasculaire cérébral aigu (REZNEK et al. 2017; TSAI et al. 2016). Une étude a fait état de retards significatifs dans les délais de triage, un nombre important de patients ne se voyant attribuer aucun score de triage en période d'affluence (LINDEN, MEESTER et LINDEN 2016).
- De l'exposition à l'erreur : Une étude américaine a identifié une fréquence accrue d'erreurs de médication, y compris l'administration de médicaments incorrects et contre-indiqués, pendant les périodes d'affluence (KULSTAD et al. 2010). Outre les retards dans l'administration des médicaments, trois études font état d'un lien entre l'affluence et l'absence totale d'administration des analgésiques ou des antibiotiques requis (MILLS et al. 2009; PINES et al. 2009);
- De l'augmentation de la durée de séjour des patients hospitalisés : Plusieurs études examinant la relation entre l'encombrement des urgences et la durée de séjour des patients hospitalisés trouvent une forte association (RICHARDSON 2002; SINGER et al. 2011; SUN et al. 2013). De même, dans (SUN et al. 2013), les auteurs ont constaté une augmentation de 0.8% de la durée de séjour des patients hospitalisés chez les patients admis aux urgences surchargées.
- De l'augmentation de la mortalité des patients hospitalisés. Plusieurs études qui examinent les effets de l'encombrement des urgences sur la mortalité des patients hospitalisés ont identifié que la mortalité augmente pendant les moments de tension (VERELST et al. 2015; DIERCKX et al. 2007; GAIESKI et al. 2017). L'étude de Verelst qui est menée dans un hôpital universitaire tertiaire en Belgique a spécifiquement étudié la mortalité des patients hospitalisés (VERELST et al. 2015). Verelst et ses collègues ont évalué les résultats de 32 866 patients adultes admis aux urgences sur une période de deux ans. Après ajustement en fonction de la gravité de la maladie, ils n'ont constaté aucune association entre l'encombrement des urgences et le risque de mortalité des patients hospitalisés à 10 jours

(VERELST et al. [2015]). À l'inverse, les sept études rétrospectives qui examinent l'effet de l'encombrement des urgences sur la mortalité des patients hospitalisés indiquent toutes que la mortalité augmente lorsque l'encombrement s'aggrave (GUTTMANN et al. [2011]; Jo et al. [2015]; SINGER et al. [2011]; SUN et al. [2013]; McCUSKER et al. [2014]). La diversité des résultats peut s'expliquer en partie par les différences dans la conception des études, ce qui rend difficile la comparaison de leurs résultats.

- De l'augmentation du nombre des abandons : plus l'attente est longue, plus le nombre des patients qui quittent l'Urgence avant leur première consultation augmente. Un certain nombre de ces départs nécessitent une admission ultérieure (BATT et TERWIESCH [2015]). Même les patients atteints d'une maladie grave peuvent décider d'abandonner avant la première consultation mais ça reste rare;
- Du manque de lits d'hospitalisation : l'attente d'un lit d'aval augmente la durée totale du séjour aux urgences, ceci aggrave encore le phénomène de la tension. Des études scientifiques ont montré que pendant une situation de tension aux SU, la durée de séjour est supérieure à une journée complète pour un patient hospitalisé dans les urgences, par rapport à un patient atteint d'une maladie similaire et hospitalisé dans une unité spécialisée (LIEW, LIEW et KENNEDY [2003]);

#### 1.3.3.4 Les indicateurs de tension dans les services des urgences

Un indicateur est défini comme une information sélectionnée, associée à un critère, destiné à observer l'évolution d'une situation à des intervalles bien définis (JAUPI [2002]). Les indicateurs de performance utilisés sont généralement orientés résultats et mettent l'accent sur la mesure des objectifs à atteindre. Mais dans la plupart du temps, leur incomplétude, ne leur permet pas de prendre en compte l'activité réelle d'un système sociotechnique (JORDAN et MESSNER [2012]). Malgré cela, les indicateurs de performance ont tendance à s'imposer comme critères d'évaluation dans plusieurs systèmes et organisations. Le choix de la pertinence et de la crédibilité de ces indicateurs est très important dans la modélisation et le suivi des situations de tension, en particulier, le choix des actions de correction pour chaque indicateur. Les indicateurs de tension et les valeurs des seuils peuvent être obtenus en combinant les connaissances du personnel médical et le retour d'expériences sur des situations de tension déjà observées au sein du SU. Nous citons quelques indicateurs de tension aux urgences identifiés dans la littérature (KADRI, CHAABANE et TAHON [2013]) :

- Le nombre d'arrivées des patients par heure.
- Le nombre total de patients.
- Le taux d'occupation par des patients hospitalisés.
- Le temps de séjour.
- Le temps d'attente entre l'enregistrement au guichet administratif et la prise en charge par l'hôtesse.
- Le temps d'attente entre la prise en charge par l'hôtesse et l'intervention de l'IAO.
- Le temps d'attente entre la prise en charge par l'hôtesse et le premier examen médical.
- Le délai écoulé entre l'enregistrement au guichet administratif et l'admission en UHCD <sup>11</sup>.

---

11. Unité d'hospitalisation à court terme

- Le délai écoulé entre l'enregistrement au guichet administratif et la sortie du service.
- Le taux d'occupation global des lits et des boxes.
- Le délai entre la demande de lit et son affectation.
- Le délai entre le premier triage et le premier soin.
- Le nombre des lits aux soins intensifs.
- Le nombre d'hospitalisation sur 24 h.
- Le nombre des patients actuellement hospitalisés dans le secteur d'UHCD depuis plus de 24h, 12h, etc.
- Le nombre de transferts à cause du manque de place depuis 24h.
- La moyenne de présence aux urgences sur 24h.
- La durée moyenne d'attente aux urgences depuis 2h.
- Le nombre des patients présents depuis plus de 10h.
- Le taux d'occupation ponctuel, c'est-à-dire le rapport à un instant t du nombre des patients hospitalisés sur la capacité d'accueil.
- Le taux d'hospitalisation post-urgence.

La liste ci-dessus présente les indicateurs qui décrivent la situation de tension au SU. Ces derniers peuvent aider les personnels de santé à anticiper les moments de tension et à bien gérer les situations tendues.

#### 1.3.3.5 La gestion des situations de tension

La tension dans un SU dépend des conséquences de l'organisation interne et des ressources disponibles, et aussi du niveau de la préparation, de la capacité d'anticipation des situations de tension, la capacité d'adaptation aux perturbations et la fluctuation des patients dans les systèmes en amont et en aval de ce service. Les hôpitaux préparent souvent un plan adéquat pour faire face aux situations de tensions. Ce plan contient des mesures préventives et des mesures correctives en prenant en considération le niveau de tension atteint et l'environnement qui l'entoure. En se basant sur les travaux de Kadri (KADRI 2014; FAKHFAKH et al. 2021b), les actions correctives sont divisées en deux catégories en fonction du niveau de surcharge :

- Actions sur le flux de la charge en soins (flux des patients) :
  - Flux des patients entrants : Diminution des patients entrants en appelant le SAMU pour orienter les patients vers d'autres structures d'urgence.
  - Flux des patients admis aux urgences : appliquer des règles de priorité pour mieux gérer le flux de patients présents afin de limiter les temps d'attente et la durée de séjour, transférer les patients du UHCD vers d'autres services et ajuster leur prise en charge. Ces règles peuvent être définies en fonction de différents critères pouvant être combinés : type du patient, durée de séjour, évolution des soins.
- Actions sur les ressources :
  - Ressources humaines : ajout de médecins ou d'infirmiers en fonction des disponibilités dans les autres services.
  - Ressources matérielles : transformer une ou deux salles de UHCD en salle de consultation.



### 1.3.4 L'impact de l'IA sur le fonctionnement du SU

La tension aux urgences est un problème majeur auquel sont confrontés les hôpitaux en France et dans le monde entier. La gestion des flux de patients, en particulier les flux récurrents et les flux consécutifs à des crises sanitaires (grippe, canicule, situations exceptionnelles) est l'un des problèmes les plus importants auxquels les urgences sont confrontées. Par conséquent, la planification des ressources et la gestion de la tension sont des opérations importantes aux urgences. Dans (SUN et al. 2013), les auteurs utilisent une technique d'analyse de séries chronologiques appelée moyenne mobile intégrée autorégressive (ARIMA) pour élaborer des modèles de prévision de la charge de travail aux urgences. Leur recherche a montré l'évidence de l'utilisation de modèles de prévision pour l'arrangement de la liste du personnel et la planification des ressources. De nombreuses études antérieures ont été développées pour prédire l'admission à l'hôpital au moment du triage aux urgences en utilisant des techniques d'apprentissage automatique. Dans (GRAHAM et al. 2018), les auteurs ont développé trois méthodes d'exploration de données pour établir un modèle de prédiction à partir de données historiques. Ils ont amélioré la qualité de la décision et réduit le taux d'erreurs mais les données non structurées et les entrées incertaines ont posé des problèmes dans les techniques de classification. Wang a utilisé des techniques d'apprentissage automatique pour prédire les admissions aux urgences, il a comparé la capacité des réseaux neuronaux Fuzzy Min-Max (FMM) à d'autres algorithmes standards d'exploration des données tels que la classification supervisée avec des arbres de décision et de régression (CART), SMLP, forêt aléatoire et AdaBoost (WANG et al. 2015). Dans l'ensemble, les modèles des réseaux de neurones et Random Forest se sont avérés les plus performants avec une précision de 80% et le FMM (avec un algorithme génétique) avec une précision de 77,97%, mais malgré ces résultats efficaces, le risque de données faussement positives reste important en raison de données médicales incohérentes et manquantes. Cependant, les études proposées dans littérature sont limitées pour plusieurs raisons. Les données manquantes et la qualité des données cliniques sont parmi les raisons les plus connues. Dans ce contexte, nous développons l'idée de qualité des données cliniques et comment les problèmes liés peuvent être résolus ?

## 1.4 L'imperfection des connaissances médicales dans les SU : Vers l'IA symbolique

Pour gérer l'afflux des patients, les services des urgences ont besoin de ressources humaines et matérielles importantes, ainsi que d'un haut degré de coordination entre ces ressources. Dans ces conditions, le personnel médical est fréquemment confronté à des situations de tension qui compliquent sa tâche et lui causent du stress. En effet, une urgence est une situation qui implique un risque critique pour les biens, la vie, la santé ou l'environnement. Pour cela, plusieurs études ont été proposées pour améliorer la qualité des soins et anticiper la tension en se basant sur des techniques de ML. Mais, le risque de se baser sur des données faussement positives et la qualité des données inhérentes restent importants en raison des données médicales incohérentes, manquantes et incertaines.

En biologie et en médecine, ainsi que dans de nombreux autres domaines, l'imperfection des connaissances ne peut être évitée. Il est difficile de construire des systèmes automatiques pour fournir des outils de classification ou de reconnaissance des formes ou pour aider les spécialistes à prendre une décision. Il existe deux types de difficultés :



- celles liées au type d'imperfection que nous devons considérer (informations partielles, incertitudes, imprécisions) et
- celles dues au type de problème que nous devons résoudre (par exemple, images à traiter, règles expertes, bases de données).

Quel modèle mathématique devons-nous choisir pour gérer ces connaissances imparfaites? Quelle est la meilleure représentation des connaissances pour un problème donné? Les réponses à ces questions ne sont pas évidentes, et notre objectif est de présenter plusieurs cadres disponibles pour représenter et gérer les connaissances imparfaites, en particulier dans le domaine de la santé. De plus, les approches statiques (ou subsymbolique) qui ont donné lieu à plus d'applications pratiques dans la littérature que les approches symboliques qui ne seront que brièvement mentionnées. Contrairement au ML, l'intelligence artificielle symbolique s'appuie sur un système de "règles". Ces règles sont construites par les experts humains puis intégrées aux machines afin de guider leur prise de décision autonome. Le moteur n'improvise donc pas par lui-même, il agit en fonction des enseignements qu'il a reçus.

Grâce à l'IA symbolique, tout est visible, compréhensible et explicable, ce qui conduit à ce que l'on appelle une « boîte transparente » par opposition à la « boîte noire » créée par la ML. Avec l'IA symbolique, il se concentre sur l'écriture de nouveaux contenus pour la base de connaissances, plutôt que sur la reformulation de contenus existants. Il dispose également d'une transparence totale sur la manière de régler le moteur lorsqu'il ne fonctionne pas correctement, car il peut comprendre pourquoi une décision spécifique a été prise. Pour conclure, l'une des principales différences entre la ML et l'approche symbolique traditionnelle est la manière dont l'apprentissage se fait. Avec l'apprentissage automatique (ML), l'algorithme apprend des règles en établissant des corrélations entre les entrées et les sorties. Avec l'approche symbolique, les règles sont créées via une intervention humaine, puis codées en dur dans un programme statique. Si le ML peut apparaître comme une approche révolutionnaire au premier abord, son manque de transparence et la grande quantité de données nécessaires pour que son système apprenne seul, sont ses deux principaux défauts. Récemment, les chercheurs et les entreprises commencent à réaliser combien il est important d'avoir une IA transparente, non seulement pour des raisons éthiques, mais également pour des raisons opérationnelles, et c'est pourquoi l'approche déterministe (ou symbolique) redevient populaire.

Dans le cadre des SU, le partage des connaissances et des informations sur les urgences et les entités affectées (personnes, infrastructures) est essentiel pour améliorer la sécurité et les infrastructures (CROCKETT et al. 2018). La gestion des connaissances (GC) a comme objectif de déterminer quelles informations sont nécessaires pour se remettre d'une situation critique. Améliorer l'efficacité de la GC peut non seulement aider les décideurs à prendre des décisions plus rapides et meilleures, mais aussi permettre à diverses organisations de partager et de réutiliser différentes ressources. La priorité principale du système d'aide à la décision est la gestion des connaissances qui peut influencer et guider les décisions prises. C'est la principale clé du succès de la prise de décision en temps réel (VILLENEUVE et al. 2019). Quelle est la méthode efficace qui peut nous permettre de gérer, représenter les connaissances efficacement et garantir en même temps un raisonnement symbolique performant pour éviter l'imperfection des connaissances? Nous détaillons cette partie dans la section suivante en proposant les solutions adéquates.

## 1.5 Problématique de la thèse

Aujourd'hui, les services des urgences présentent des systèmes sociotechniques dynamiques qui, par nature, sont soumis à des perturbations qui entraînent l'apparition de situations de tension. Pour les maîtriser et assurer le fonctionnement satisfaisant du service, il est nécessaire de détecter l'occurrence de ces situations et de pouvoir réagir le plus en amont possible. Le fonctionnement des urgences est donc plus difficile qu'avant et les ressources sont limitées en raison des besoins divers des patients, des différents niveaux de traitement et des heures d'arrivée imprévues, différentes de celles des autres services hospitaliers (MORLEY et al. 2018).

Au fil des années, la demande de soins des SU n'a cessé d'augmenter. Ils sont donc confrontés à une forte pression engendrée par le flux important de patients, ce qui en fait l'une des entités les plus encombrées des hôpitaux. De nombreuses études sur les urgences ont révélé que ces établissements ont de plus en plus de difficultés à remplir leurs missions. Une gestion inappropriée de la tension se traduirait par un fonctionnement inadéquat des urgences (SAVIOLI et al. 2022), ce qui pourrait entraîner des conséquences négatives pour les patients (ZHOU et al. 2012). L'amélioration des soins aux SU est limitée par un contrôle rigoureux des dépenses de santé et du processus des soins, et par une gestion proactive du flux des patients. Les pratiques conventionnelles (AJMI 2021) de gestion des flux patients aux urgences se sont avérées très bénéfiques et doivent être maintenues.

Toutefois, il convient de noter que ces pratiques semblent inefficaces pour gérer des situations présentant des perturbations majeures (par exemple, afflux irréguliers, saisonniers, épidémiques, vagues de chaleur et de froid). Dans ce cadre, l'organisation et la planification des processus ainsi que la communication et le partage d'information entre les différents acteurs de santé participent à l'amélioration de la qualité des soins. Ce qui présente une solution potentielle pour améliorer la proactivité des urgences. De plus, pour bénéficier d'une chaîne logistique hospitalière efficace et opérationnelle, il faut évaluer régulièrement la performance de cette dernière. Ainsi, l'intégration d'un système de mesure de la performance avec les différents éléments en interaction composant la chaîne, présente une démarche nécessaire pour améliorer régulièrement les bénéfices d'une logistique hospitalière. Par conséquent, dans la gestion de la chaîne logistique hospitalière, la prédiction des situations de tension est un enjeu majeur pour la santé publique. En outre, les acteurs du secteur hospitalier doivent maîtriser les causes de ce phénomène, alors que ces derniers sont démunis en méthodologies et outils d'aide à la décision appropriés pour gérer et anticiper ces situations critiques. De plus, l'organisation traditionnelle des ressources médicales peut s'avérer inefficace pour absorber un flux important de patients, ce qui entraîne fréquemment des conditions de tension qui augmentent les erreurs médicales et le stress du personnel médical et réduisent la satisfaction des patients (REZNEK et al. 2017; SINGER et al. 2011). Donc, l'intégration de l'intelligence artificielle et le traitement des données est devenu un enjeu crucial.

Plusieurs études récentes, qui optimisent la chaîne logistique des SU, sont basées sur les techniques de ML. Ces techniques consistent à prévoir à l'avance le flux des patients ainsi que leur admission afin de donner aux responsables des urgences suffisamment de temps pour se préparer à la charge de travail engendrée par ces prises en charge éventuelles comme la planification ou la mobilisation des ressources nécessaires, etc.). Aussi, ces techniques de ML permettent de mettre en place des systèmes d'aide à la décision destinés aux personnels de santé

afin de les aider à bien gérer les tensions et réduire ainsi le taux d'erreur des décisions subjectives prises. Compte tenu de l'encombrement des urgences et des ressources limitées (humaines et matérielles), l'intelligence artificielle est certainement une solution clé pour atténuer ce problème. Néanmoins, il ne faut pas oublier d'assurer une base de connaissances riche et exploitation des données textuelles non structurées. Le choix d'une méthode de traitement des données est lié au choix de la représentation des connaissances, qui peut être symbolique ou subymbolique, et dépend de la nature du problème à résoudre : classification, diagnostic automatique ou aide à la décision, par exemple. Les connaissances disponibles peuvent correspondre à des images ou des bases de données contenant des informations factuelles ou des connaissances expertes fournies par des spécialistes du domaine. Ces connaissances sont, dans certains cas, directement gérées par un outil approprié, comme un système expert ou une méthode de reconnaissance de formes si l'objet à identifier sur les images n'est pas trop variable, par exemple. Dans d'autres cas, l'apprentissage est nécessaire comme étape préliminaire à la construction d'un système automatique. Cela signifie que des exemples de situations connues sont donnés et affectés à une classe, un diagnostic, une décision, ou plus généralement une étiquette par un spécialiste. Il est également possible que des explications soient nécessaires pour les raisons qui conduisent le système à un diagnostic donné ou au choix d'une étiquette. Il est, par exemple, intéressant que le système automatique conçu ait des objectifs de formation.

Dans ce contexte, les ontologies décrivent une approche symbolique qui est devenue une technologie utile et populaire en informatique et en science de la connaissance (ILKOU et KOUTRAKI 2020). Une ontologie est une forme de conceptualisation des scénarios du monde réel. Cette approche a été déployée dans les systèmes d'aide à la décision (SAD) pour fournir une représentation formelle des connaissances. Elle peut améliorer l'interaction et la coordination entre les différentes organisations comme les services des urgences. L'ontologie de domaine pour la gestion des urgences est un mécanisme permettant de fournir une vue cohérente du domaine spécifique et qui peut être utilisée par toutes les autorités compétentes. L'ontologie ainsi créée devrait être capable de représenter et de capturer suffisamment d'informations sur des situations telles que les catastrophes naturelles, les accidents, les pandémies et les données climatiques qui peuvent influencer les flux de demandes sur les urgences. Il s'agit d'un modèle hiérarchique qui forme des représentations vraies et fidèles, de sorte que les interrogations du modèle donnent des résultats fiables. Ce modèle hiérarchique indique la classification des situations et la relation entre les éléments situationnels à différents niveaux de granularité. Prendre des décisions rapides dans le chaos des situations d'urgence est une tâche très difficile. Le processus peut devenir complexe lorsqu'une décision prend en compte plusieurs facteurs et ressources internes et externes. Avant de tirer toute conclusion ou d'aider à la prise de décision, le personnel médical doit être conscient des ressources nécessaires et des ressources disponibles à un moment donné.

En effet, les travaux de cette thèse s'inscrivent au cœur du projet ANR OIILH (ANR-18-CE19-0019)<sup>12</sup> : optimisation intra et inter logistique hospitalière, destinés au service des urgences adultes (SUA) du CHU<sup>13</sup> de Lille. Les situations de tension peuvent provenir de la détérioration de l'état de santé des patients, mettant leur vie en danger. Ces situations de tension mettent les acteurs du système de santé dans des situations critiques. Pour gérer ces crises sanitaires, il faut revoir le processus complet de la chaîne des urgences et notamment les parties en amont (arrivée) et en aval (orientation) du service. Il est donc crucial de mettre en place des mesures qui visent à maîtriser non seulement la totalité de « la chaîne logistique des urgences » (amont-intra-aval)

---

12. [Projet ANR OIILH](#)

13. [chu-lille.fr](http://chu-lille.fr)

mais aussi à aider le personnel de santé à gérer ces situations en leur proposant des solutions adéquates. Ces mesures ont pour objectifs d'améliorer la qualité des soins et la performance de la chaîne des urgences.

Dans ce cadre, cette thèse a trois objectifs principaux centrés sur le patient et le SU et basés sur l'analyse et l'exploitation des données médicales, issues du SUA du CHU de Lille :

- Analyse et prédiction des données de santé : La plupart des arrivées au SU sont non programmées. L'optimisation de l'amont consiste à anticiper les flux patients à partir de modèles de prévision basés sur les techniques de ML qui rendent le modèle plus performant et intelligent. La gestion de la sortie du patient du SU et son hospitalisation sont très complexe. Pour cela, un modèle de prédiction de l'admission permet de gérer efficacement le flux de sortie des patients de façon à permettre de retrouver un lit d'aval le plus rapidement possible (ayant à l'avance une prévision de d'hospitalisation). Ce travail de prédiction vise à assurer la continuité des soins dans les meilleures conditions.
- Aide au triage : Le score CCMU ne prend pas en considération toutes les variables qui influencent sur l'état de sévérité des patients comme les antécédents médicaux. Notre objectif est donc d'augmenter la précision de ce score afin d'aider les infirmiers de triage à attribuer le score adéquat à chaque patient en réduisant le risque d'erreur. Nous développons donc un système d'aide à la décision intelligent qui aide les infirmiers à orienter les patients dans le parcours adéquat en utilisant des techniques issues de l'intelligence artificielle (IA).
- Aide à anticiper et à gérer les situations de tensions : En se basant sur les indicateurs de performances, un modèle d'aide à la décision permet de prédire une situation de tension et de recommander au personnel de santé la bonne solution pour la gérer.

Par conséquent, après une étape de conception et de développement, la simulation et l'expérimentation de ces modèles et algorithmes seront réalisées en utilisant des données cliniques issues du SUA. Le but de cette thèse est d'étudier et de développer un système d'aide à la décision (SAD) de méta-modèle centré sur le patient basé sur l'alliance entre l'ingénierie de connaissance, l'optimisation et l'apprentissage.

## 1.6 Conclusion

Dans le domaine de la santé, l'IA a montré un grand potentiel pour améliorer l'efficacité des soins, réduire le risque d'erreur et aider à la prise de décision. Dans ce chapitre, nous avons défini l'IA et son impact sur la santé. Puis nous avons décrit les systèmes des urgences qui représentent le terrain d'étude de cette thèse. Nous avons mis en évidence les différents problèmes de ce service et la complexité de la gestion de la tension tout en montrant l'importance de gérer et d'anticiper ces situations en utilisant l'intelligence artificielle et le traitement de données médicales. De plus, nous avons montré que ces modèles sont destinés à aider les personnels de santé à bien accomplir leurs tâches et à améliorer la qualité des soins.

Dans le chapitre suivant, nous développons les principales méthodes de représentation et de gestion des connaissances et leurs imperfections ainsi que les techniques IA en lien avec les objectifs de cette thèse.



# Intelligence des données médicales : Des données vers les connaissances

## 2.1 Introduction

La qualité des données médicales présente un problème majeur dans la création des systèmes intelligents dans le domaine de la santé. Ce problème est dû principalement à la forme textuelle non structurée et à une composition complexe. Dans de multiples domaines de recherche, l'ingénierie des connaissances est devenue un outil d'aide à la réalisation des tâches complexes et de solutions performantes pour la recherche d'information, le web sémantique, le génie logiciel, l'intelligence artificielle ou encore l'informatique médicale. Dans le domaine médical, les ontologies sont déployées non seulement pour la modélisation et l'analyse des données mais également pour le prétraitement et la classification des données et aussi pour l'aide à la décision. En effet, les ontologies peuvent être intégrées dans des techniques de classification comme l'apprentissage automatique ou les réseaux de neurones. La combinaison d'ontologies avec l'apprentissage automatique correspond à un domaine récent permettant de développer de nouvelles stratégies de raisonnement. Cependant, la gestion de la défaillance des données et des connaissances médicales est primordiale pour créer des systèmes performants. Dans ce chapitre, nous explorons d'abord les notions liées aux ontologies et à la représentation des connaissances, ensuite les techniques et les méthodes existantes qui gèrent l'imperfection des connaissances.

## 2.2 L'ingénierie des connaissances

L'ingénierie des connaissances (IC) fournit une démarche d'analyse et de modélisation pour la résolution des problèmes (CHARLET 2002). Dans ce contexte, certains travaux de recherche fournissent des guides méthodologiques et de représentation de résolution des problèmes (AUSSENAC-GILLES, LAUBLET et REYNAUD 1996). Ces travaux puisent leurs sources dans des théories et des méthodes empruntées à diverses disciplines en étudiant l'activité rationnelle, comme l'intelligence artificielle. L'objectif de l'IC est de représenter les rôles que jouent les données et les informations dans une résolution des problèmes d'aide à décision. Ces rôles sont

présentés sous forme de connaissances et sont définis par le savoir et le savoir-faire utilisés par une personne ou un groupe de personnes afin de réaliser une action dans un contexte précis. Le processus de l'IC est composé de plusieurs étapes : recueil, modélisation et représentation des connaissances. Nous définissons chaque étape ci-dessous.

### 2.2.1 Recueil des connaissances

Une familiarisation avec le domaine d'expertise et de l'activité est indispensable afin d'identifier les thématiques ainsi que les sources de connaissances : experts, documents, Bases de données, etc. Un entretien libre avec l'expert peut être mené afin de dresser un schéma global de l'activité décrivant une planification des grandes étapes. Cet entretien, correspondant à une première phase de recueil, est souvent nécessaire. Plusieurs techniques de recueil existent et leur déploiement dépend des sources des connaissances. Par exemple :

- Le recueil dirigé par des questionnements de l'expert en dressant des classifications des objets, des problèmes et des stratégies.
- L'extraction de concepts à partir de texte (« TextMining ») (FELDMAN, SANGER et al. 2007). Des algorithmes de détection d'occurrence de termes sont d'abord appliqués à des corpus de texte. L'expert peut identifier les concepts parmi les termes identifiés et dresser des classifications de ces concepts.
- L'agrégation de données par l'application des algorithmes de « DataMining » (USAMA 1996).

### 2.2.2 Modélisation des connaissances

La modélisation des connaissances a marqué la nouvelle génération des techniques d'IC. La plupart des approches se basent sur une représentation au niveau connaissances (Knowledge level) au sens de Newell (ZERFASS, HAGELSTEIN et TENCH 2020). Ce niveau permet de modéliser un agent rationnel en rendant explicite le corps (« le Quoi »), les actions (le Comment) et les lois de conduite (« le Pourquoi »). Dans ce type de modélisation, le modèle de domaine représente le « Quoi » et le modèle de raisonnement représente le « Pourquoi et Comment ». C'est à travers cette modélisation de l'activité au niveau rationnel, en distinguant la tâche prescrite du contrôle de l'activité réelle, que l'IC fournit une flexibilité dans la modélisation des connaissances. Cette modélisation représente un cadre permettant de se focaliser sur la description d'agents rationnels et de leur conduite avant leur transformation dans un format calculable, programmable dans un automate. C'est dans ce sens que l'IC a permis non seulement de fournir des systèmes calculables (Systèmes à base de connaissances) mais également une représentation formelle de la connaissance, exploitable sous plusieurs formes. Nous pouvons donner comme exemples l'accès cognitif à l'information et au capital des connaissances d'une entreprise, une structuration conceptuelle de différentes facettes d'une donnée, etc. Cette modélisation décrit un modèle abstrait qu'on appelle modèle conceptuel, cadre sémantique partagé par des utilisateurs et des concepteurs qui leur permet de communiquer.

En IC, le modèle conceptuel est une représentation partagée entre l'expert (source des connaissances), l'ingénieur de la connaissance, les utilisateurs destinataires de la formalisation des connaissances et dans certains cas, l'informaticien programmeur d'un système à base de connaissances. Différentes approches sont définies en ingénierie des connaissances comme CommonKADS (BREUKER et VELDE 1994), KOD (VOGEL 1988), MASK (ARIES, LE BLANC et ERMINE 2008). Les techniques avancées de ces approches peuvent être vues comme une grammaire de

modélisation (appelée également langage de modélisation), un vocabulaire (dans lequel des primitives spécifiques à certains types de domaines sont définies) et une démarche (guidant l'ingénieur de la connaissance à définir le vocabulaire spécifique d'une application donnée en utilisant la grammaire définie). Citons par exemple, le langage CML «*Conceptual Modelling Language*» (SCHREIBER et al. [1994]) qui permet de représenter le modèle de domaine sous forme de concepts et le modèle de raisonnement avec des tâches et des inférences.

### 2.2.3 Représentation des connaissances

La représentation des connaissances est basée sur deux types de catégories (KAYSER [1997]) :

- Les frames, proches d'une représentation objet en informatique. Les concepts sont exprimés sous forme de classes hiérarchisées. Chaque classe (comme pour la programmation orientée objets) est décrite par des attributs/valeurs. Les instances représentent des exemples de « valeurs » de classes.
- Les réseaux sémantiques, formalisés sous forme de concepts et de relations. Les graphes conceptuels sont proposés par Sowa (Sowa [1992]) pour traduire cette représentation en logique propositionnelle. Les relations entre les concepts permettent de décrire ses propriétés. La relation « Est-un », utilisée dans les langages orientés objets, est privilégiée afin d'illustrer l'héritage de propriétés. Par analogie, toutes les relations au niveau « concept père » sont héritées au niveau « concepts fils ».

Un réseau sémantique, exploité dans ce qu'on appelle actuellement «**Ontologie**», permet de raisonner d'une manière extrêmement puissante. Une ontologie, notion héritée de la philosophie grecque illustrant la science de l'être, est une représentation de concepts d'un domaine (FENSEL [2001]). Elle est décrite sous forme d'un arbre d'héritage entre les concepts et un graphe décrivant les relations entre ces concepts. Plusieurs niveaux d'ontologies ont été définis (GANGEMI et al. [2002]) : générique, spécifique à un domaine et relative à une application dans un domaine particulier. Plusieurs langages d'implémentation sont également définis comme RDF<sup>1</sup> et OWL<sup>2</sup>. De même, des logiciels adossés à des moteurs d'inférences permettant de représenter les ontologies, sont proposés. Nous pouvons citer par exemple PROTEGE et CORESE. L'exploitation de l'ontologie utilisant ces logiciels permet par exemple d'offrir une recherche intelligente d'informations sur Internet. Ce que le Web sémantique (BERNERS-LEE, HENDLER et LASSILA [2001]) propose. Nous détaillons le domaine des ontologies dans la section suivante.

## 2.3 Les ontologies

Récemment, l'utilisation des ontologies, en créant une base de connaissances est devenue une voie incontournable pour représenter les connaissances sémantiques. En effet, l'ingénierie ontologique est devenue de plus en plus utile et a connu un succès important grâce à sa représentation d'un référentiel conceptuel développé sous la forme d'une modélisation informelle. En outre, une ontologie est caractérisée par une représentation explicite et compréhensible d'un domaine donné. Elle reflète également la description du monde réel à travers des langages de formalisation spécifiques. Nous présentons par la suite des généralités sur les ontologies classiques avant de présenter d'autres variantes d'ontologies plus spécifiques, dédiées à notre champ d'étude dans le cadre de cette thèse, à savoir les ontologies floues et les ontologies médicales.

---

1. Resource Description Framework
2. Web Ontology Language



### 2.3.1 Définitions d'une ontologie

Une définition claire et précise du terme ontologie n'est pas aussi facile, car ce terme dépend du domaine d'application et du contexte de l'étude. En effet, l'origine du mot « ontologie » est issue de la philosophie et caractérise une actualité qui peut décrire la réalité et l'existant sous formes d'entités et de relations entre ces entités pour suivre leurs interactions (HAWTHORNE et al. 2021). Scientifiquement, une ontologie ne vise pas à modéliser le monde réel, mais plutôt donne une interprétation correcte de l'existant, du système d'information ou plus précisément des données et des informations partagées (OSMAN, NOAH et SAAD 2022). Dans la littérature, il existe plusieurs définitions du terme « ontologie ». Selon Gruber, « *une ontologie est une spécification explicite d'une conceptualisation* » (GRUBER 1993). Elle est caractérisée par une représentation d'un domaine prenant la forme de concepts, de propriétés et de relations entre ces concepts. Elle est considérée également comme étant « *une base de connaissances particulière* » (GUARINO et al. 2000). Selon Euzenat (EUZENAT et SHVAIKO 2013), une ontologie présente un graphe qui est défini à travers des termes, des relations de base du vocabulaire et des règles qui définissent les conditions de combiner ces termes et ces relations de façon à pouvoir enrichir le vocabulaire. Elle peut être référencée aussi par des identificateurs universels (PIERRA 2008).

Dans (RANWEZ 2013), une ontologie est définie comme une convention de vocabulaire et de relations entre les mots de ce dernier. Elle est devenue une référence pour les systèmes d'information à travers un vocabulaire vaste et riche en informations. Elle offre un corpus de connaissances supportable et compréhensible par la machine. De plus, une ontologie peut être sous formes multiples, mais elle doit inclure obligatoirement un vocabulaire de termes et une spécification de leur signification (USCHOLD 1996). Elle englobe des définitions et des descriptions détaillées qui décrivent les relations entre les concepts, les liens imposant une structure sur le domaine et impliquant des contraintes sur les interprétations possibles des termes. Une ontologie permet donc de créer un monde de partage commun de connaissances entre les systèmes hétérogènes et les personnes ainsi qu'une structure d'information compréhensible entre eux, ce qui assure la clarté entre les termes et leurs sens. Elle offre tous les outils qui aident à rendre les constituants d'un domaine particulier compréhensible. En effet, elle garantit la modélisation du monde réel à travers des formalismes et des langages de représentation très spécifiques. De plus, nous pouvons considérer une ontologie comme une référence pour les systèmes d'informations avec un vocabulaire riche en informations. Il s'agit d'une spécification formelle des concepts d'un domaine et de leurs relations. Elle présente une méthodologie pour décrire la structure des connaissances dans un domaine spécifique. Elle favorise divers types de traitements sur les données visant à fournir des liens systématiques et sémantiques entre des groupes de concepts apparentés. Les ontologies sont utilisées pour représenter les connaissances d'un domaine. Ces connaissances sont représentés par des concepts, d'individus appartenant à ces concepts (instances) et de relations entre les concepts et entre les concepts et les individus (SHERIMON et al. 2013). Dans (GRUBER 1993), l'auteur considère qu'une ontologie vise à analyser les besoins des systèmes informatiques, ce qui la rend un composant réutilisable contenant des termes traduisibles pour assurer la compréhension commune des termes. Pour réaliser ses objectifs, une ontologie est composée de plusieurs parties que nous définirons ce qui suit.

### 2.3.2 Les composants d'une ontologie

Une ontologie est composée de huit éléments différents :

- Les individus sont les principaux composants d'une ontologie. Ils sont également connus

sous le nom d'« instances » (MESSAOUDI 2021).

- Les classes sont des ensembles d'instances (et donc d'individus) qui sont décrites comme des collections ou des concepts, selon le domaine. Une classe peut avoir de nombreuses sous-classes. Les sous-classes représentent des concepts qui sont plus spécifiques que la superclasse correspondante (NOY, MCGUINNESS et al. 2001). La hiérarchie super-classe-sous-classe est également connue sous le nom de taxonomie.
- Les attributs sont des objets d'une ontologie, utilisés pour être relié à d'autres objets de la même ontologie. Chaque attribut peut être une classe ou un individu. Il définit des variables qui décrivent les propriétés, les caractéristiques ou les particularités des objets de classes (ELLMAN et PULIDO 2002).
- Les relations sont utilisées pour relier les classes et les individus entre eux. Les relations entre les objets d'une ontologie spécifient comment les objets sont liés à d'autres objets de cette même ontologie (KLEIN et al. 2001).
- Les fonctions sont des structures complexes formées à partir de certaines relations qui peuvent être utilisées à la place d'un terme individuel dans une déclaration (SOININEN et al. 1998).
- Les restrictions sont des descriptions formellement énoncées de ce qui doit être vrai pour qu'une certaine assertion soit acceptée en entrée (JONES, BENCH-CAPON et VISSER 1998).
- Les règles sont des déclarations sous forme d'une phrase conditionnelle « If Then » (antécédent-conséquent) qui décrit les inférences logiques qui peuvent être tirées d'une assertion sous une forme particulière (SPYNS, MEERSMAN et JARRAR 2002).
- Les axiomes sont des assertions (y compris les règles) sous forme logique qui, ensemble, constituent la théorie globale que l'ontologie décrit dans son domaine d'application (STAAB et MAEDCHE 2000).

Une ontologie contient plusieurs composants et fonctionnalités qui aident à définir le domaine et à modéliser les connaissances pour créer un système intelligent selon le domaine d'application, que nous présentons dans ce qui suit.

### 2.3.3 L'application des ontologies

Au fil des ans, le terme ontologie est devenu un sujet de recherche à part entière en lien avec de nombreuses disciplines. Il vise à améliorer la compréhension d'un domaine de connaissances donné et à établir un consensus à ce sujet (HAWTHORNE et al. 2021). Une ontologie conduit également au partage des connaissances entre les systèmes et les personnes. En effet, les ontologies sont d'abord apparues dans les laboratoires d'IA, ou elles sont utilisées dans plusieurs domaines tels que :

- Le Web sémantique (NARAYANASAMY et al. 2022) : L'ontologie joue un rôle essentiel pour accélérer l'échange d'informations entre les environnements distribués. Comme les données sont traitées par des machines, le web sémantique est considéré comme l'extension du web actuel.
- L'Intelligence artificielle (TEIXEIRA, MARAN et DRAGONI 2021) : L'ontologie est le meilleur outil pour soutenir le partage et la réutilisation des connaissances et pour bien gérer les traitements entre les programmes et les services dans un domaine donné.

- Les systèmes Multi-agents (YOUSEFZADEH AGHDAM et al. [2022]) : L'importance de l'ontologie dans ce domaine est qu'elle fournit une compréhension partagée des connaissances du domaine, permettant une communication facile entre les agents artificiels et réduisant ainsi les erreurs de communication.
- Les moteurs de recherche (ZOUAOUI et REZEG [2021]) : L'ontologie est utilisée sous forme de thésaurus qui facilitent la recherche sur Internet pour trouver les synonymes des termes recherchés.
- Les systèmes d'aide à la décision clinique (NATARAJAN, KANNAN et MOHANTY [2021]) : L'ontologie est utilisée pour représenter les informations sur les maladies, les symptômes, les médicaments, les patients, les directives cliniques, etc.
- Le commerce électronique (FAROOQ et QAMAR [2022]) : L'ontologie est utilisée pour faciliter la communication entre le vendeur et l'acheteur par la description de la marchandise, ainsi que pour permettre la communication informatique.

### 2.3.4 Les méthodes de développement des ontologies.

Les méthodes de l'ingénierie ontologique présentent les stratégies qui assurent le processus de développement d'une ontologie. En effet, il faut suivre des directives bien structurées et communes pour garantir le développement dans des délais convenables. Une méthodologie caractérise les démarches ou les étapes à suivre pour la construction d'un travail ou d'un projet. Dans cette partie, nous présentons quelques méthodologies définies dans la littérature pour le développement d'une ontologie.

#### 2.3.4.1 La méthode de Gruninger et Fox (TOVE)

Cette méthodologie est fondée spécifiquement pour le projet TOVE qui vise à modéliser des processus et des activités (GRÜNINGER, ATEFI et FOX [2000]). Elle est basée sur la construction d'un modèle logique de connaissances. Ce modèle doit être spécifié et adéquat à l'ontologie créée. Le processus de développement de cette méthode suit un enchaînement particulier qui permet de :

1. déterminer les spécifications ;
2. citer les scénarios et écrire les questions de compétences informellement ;
3. décrire formellement la terminologie de l'ontologie ;
4. identifier les conditions et les contraintes pour accomplir la complétude de l'ontologie.

#### 2.3.4.2 La méthodologie de Uschold et King

Cette méthode est issue du domaine de la gestion d'une entreprise, qui caractérise une ontologie présentant le fonctionnement des processus au sein de l'entreprise (USCHOLD et al. [1998]). Elle offre une stratégie de construction en fonction des besoins et des objectifs attendus. Cette méthodologie comporte les étapes suivantes :

1. l'identification des buts ;

2. la création de l'ontologie en se basant sur trois phases, à savoir la capture des connaissances, le codage, et la réutilisation des ontologies existantes ;
3. l'évaluation de l'ontologie ;
4. la documentation de l'ontologie.

#### 2.3.4.3 La méthode de Bernaras

Cette méthodologie est proposée dans le cadre du projet Esprit KACTUS, elle montre la faisabilité des ontologies et leur réutilisation pour supporter les systèmes complexes (SCHREIBER, WIELINGA, JANSWEIJER et al. 1995). Elle impose le développement d'une application, et est basée essentiellement sur trois points :

- la spécification de l'application permettant l'extraction des tâches à modéliser ;
- l'organisation et la conception des termes (concepts, relations, attributs, etc.) ;
- l'affinement et la structuration de l'ontologie en se basant sur des modèles d'organisation hiérarchiques.

#### 2.3.4.4 La méthode Terminae

La méthode Terminae<sup>3</sup> s'inscrit dans le cadre de l'ingénierie des connaissances linguistiques (AUSSENAC-GILLES, DESPRES et SZULMAN 2008). C'est une succession des étapes suivantes :

1. la collection des données afin de présenter le corpus d'un domaine ;
2. l'extraction de la terminologie du thème choisi en utilisant l'outil LEXTER (AUSSENAC-GILLES, DESPRES et SZULMAN 2008) ;
3. la normalisation et la conceptualisation des termes ;
4. la formalisation des données

#### 2.3.4.5 La méthodologie Methontology

La méthodologie « Methontology » est proposée par (FERNÁNDEZ-LÓPEZ, GÓMEZ-PÉREZ et JURISTO 1997). Elle permet de clarifier les étapes de construction d'une ontologie en suivant les activités de gestion de projets (Figure 2.1). Elle est basée sur les étapes suivantes :

- la spécification : identifie l'objectif de l'ontologie à développer ainsi que les utilisateurs visés ;
- la conceptualisation : détermine les connaissances (concepts, propriétés, relations et instances) du domaine étudié et prépare le terrain pour garantir le passage de la création de diagrammes abstraits à la phase de l'implémentation ;
- la formalisation : assure la transformation de l'ontologie en un modèle formel en utilisant des traducteurs. Dans cette étape, l'ontologie est écrite avec un langage spécifique ;
- l'implémentation : il s'agit de l'expression du modèle ontologique formel à l'aide d'un langage d'implémentation tel que l'OWL ;
- la maintenance : améliore et raffine l'ontologie avec des mises à jour.

---

3. <http://lipn.univ-paris13.fr/fr/article/1314-terminae/166>

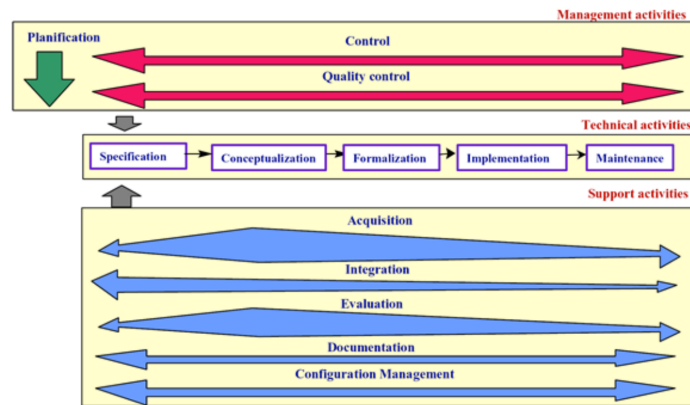


FIGURE 2.1 – Méthode « MethOntology », (FERNÁNDEZ-LÓPEZ, GÓMEZ-PÉREZ et JURISTO 1997)

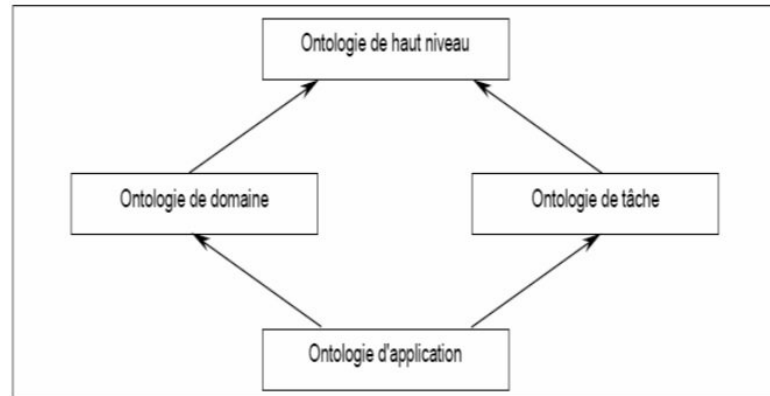


FIGURE 2.2 – Typologie d'ontologies , (GHAZOUANI 2018)

### 2.3.5 Les types d'ontologies

Les ontologies sont classifiées selon l'objet de leur conceptualisation (le but de leur utilisation) de la façon suivante : Haut niveau, Domaine, Tâche et Application. Les ontologies de haut niveau, les ontologies de domaine et les ontologies d'application saisissent les connaissances statiques indépendamment de la façon dont on résout les problèmes alors que les ontologies de tâches sont axées sur les connaissances visant à résoudre des problèmes. Tous ces types d'ontologie peuvent être fusionnés de façon à construire une nouvelle ontologie (c'est alors, une ontologie partagée qui peut être une ontologie ou une combinaison de quelques-unes d'entre-elles). Ces différents niveaux sont récapitulés dans la figure 2.2. En outre, les flèches représentent des relations de spécialisation.

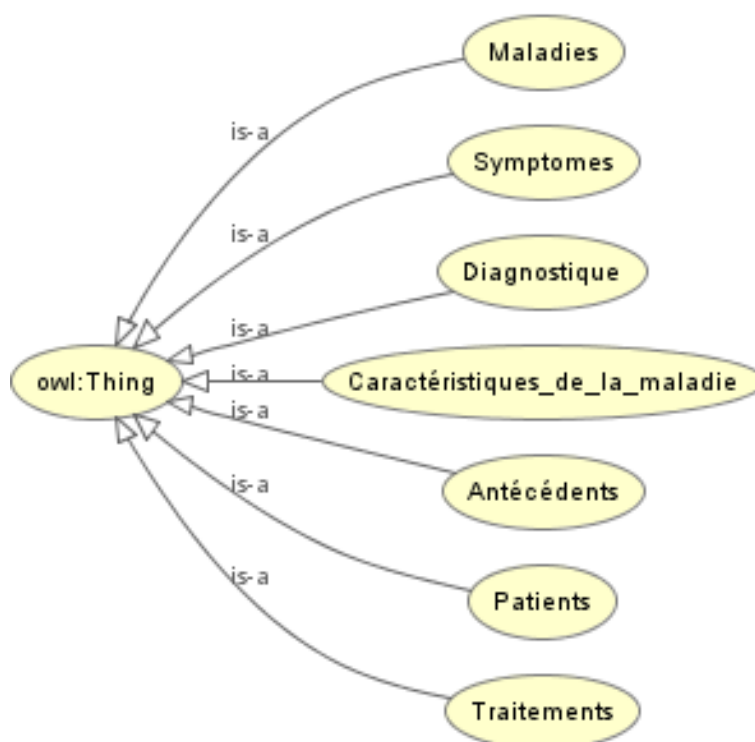


FIGURE 2.3 – Ontologie de haut niveau , (FAKHFAKH, MAALEL et FARHAT 2019)

### 2.3.5.1 Les ontologies de haut niveau

Ce type d'ontologies modélise des concepts de haut niveau qui doivent être reliés aux ontologies de plus bas niveaux. Ce lien se fait par les feuilles/sommets de l'arborescence de l'ontologie de haut niveau. Cependant, il existe plusieurs ontologies de haut niveau qui se différencient par le critère utilisé pour classer les concepts généraux de la taxonomie (EL-DIRABY, LIMA et FEIS 2005). Un exemple d'ontologie de haut niveau de domaine des maladies est présenté par la Figure 2.3

### 2.3.5.2 Les ontologies de domaine

Ces ontologies expriment des conceptualisations spécifiques à un domaine précis qui peuvent être réutilisables pour plusieurs applications. En effet, l'ontologie du domaine caractérise les connaissances du domaine pour que la tâche soit réalisée (EL-DIRABY 2013). Les ontologies sont désormais utilisées dans de nombreux domaines tels que l'informatique, l'intelligence artificielle et les banques de connaissances (POLI et SEIBT 2010). Ce développement est le résultat de l'avènement du World Wide Web, qui permet de partager les connaissances à une plus grande échelle. Une extension du World Wide Web est le Web sémantique, où les ontologies offrent un moyen de transférer des informations non seulement sous forme de documents textuels mais aussi de données. L'idée est de relier les données à l'aide de normes spécifiques afin de permettre le partage de la signification sémantique entre les utilisateurs (BERNERS-LEE, HENDLER et LASSILA

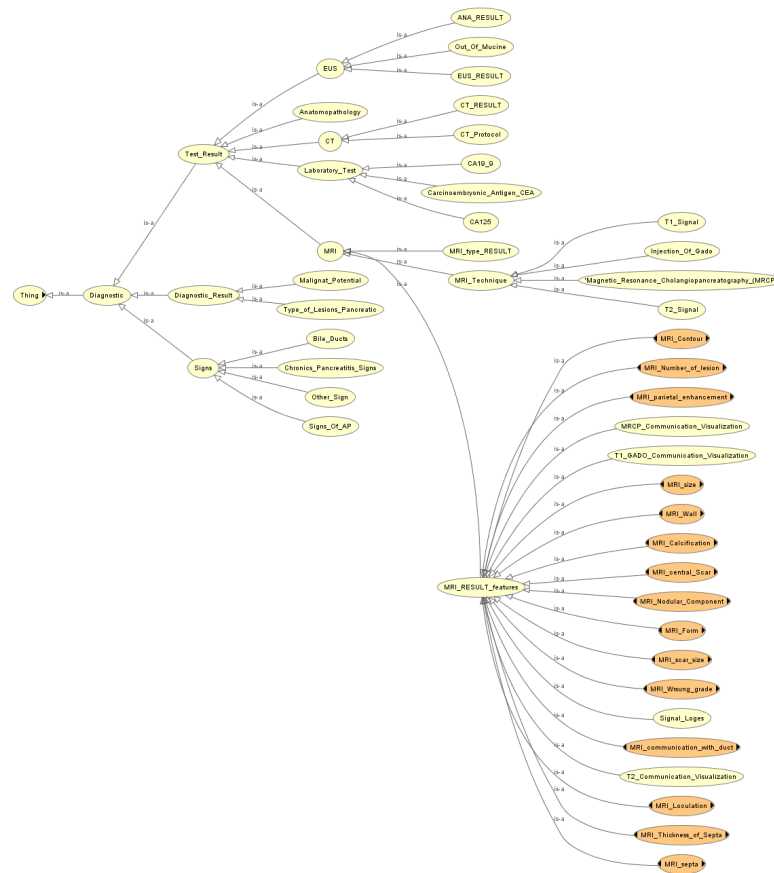


FIGURE 2.4 – Exemple d’une ontologie de domaine, (FAKHFAKH, MAALEL et FARHAT 2019)

2001). Par exemple, l’ontologie de la figure 2.4 ci-contre définit le domaine de la maladie des kystes pancréatiques (FAKHFAKH, MAALEL et FARHAT 2019). Nous pouvons remarquer dans cette figure le lien avec l’ontologie de haut niveau donné par l’exemple de la figure 2.3.

En effet, dans la figure 2.4, Les classes oranges sont des classes équivalents et les jaunes sont les classes ontologiques normales.

### 2.3.5.3 Les ontologies de tâches

Pour représenter les connaissances liées aux tâches, telles que l’emplacement, les caractéristiques temporelles et les propriétés d’exécution, nous utilisons une ontologie de tâches. Ce type d’ontologie est utilisé pour décrire un vocabulaire relatif à une tâche ou à une activité générique (e.g. faire un diagnostic, planifier une activité) en spécialisant certains termes de l’ontologie de haut niveau. Une ontologie de tâches fournit un ensemble de termes au moyen desquels on peut décrire, au niveau générique (haut niveau), comment résoudre un type de problème (RAJPATHAK, MOTTA et ROY 2001). Elle détaille, entre autres, ce qui est impliqué à chaque exécution de tâche, où et quand les activités sont réalisées, ce qui est nécessaire pour leur

... as a specific time when they might happen.

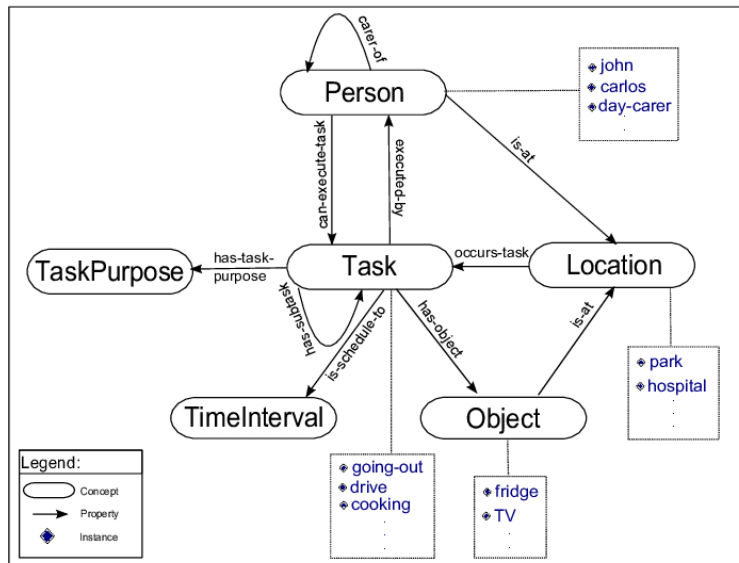


FIGURE 2.5 – Aperçu d'un exemple d'ontologie de tâches, (PANISSON et al. [2015])

achèvement et quels impacts sur les utilisateurs. Ces informations peuvent être utilisées par des algorithmes pour prendre des décisions à différents moments, par exemple lors de l'exécution de plans pour atteindre un objectif ou lors de la réaffectation de tâches entre agents. Pour déduire de nouvelles informations sur les tâches, des règles logiques et des raisonneurs sémantiques peuvent être associés à l'ontologie. Les programmeurs des logiciels informatiques peuvent avoir besoin de ces informations pour mettre en œuvre des méthodes de raisonnement sur les tâches, comme la reconnaissance, l'allocation et la négociation des tâches.

Par exemple, la figure 2.5 décrit une ontologie de tâches avec les principaux concepts, les caractéristiques (propriétés) et les exemples d'instances. Les notions de base (les concepts) sont les suivantes : Task, TaskPurpose, Person, Location, Object et TimeInterval. Comme on le voit dans le concept d'emplacement « location », une tâche peut avoir des limites basées sur les zones où elle peut se produire (par exemple, InternalLocation et ExternalLocation). Une tâche peut être confiée à un nombre quelconque de personnes qui l'exécuteront ou aideront à son exécution, selon un objectif fixé. Les personnes peuvent être subdivisées en fonction de la nécessité de définir des contraintes de tâche, par exemple, « Adulte » est une sous-classe de Personne qui peut être utilisée pour spécifier des tâches que seuls les adultes peuvent effectuer. L'idée d'objet désigne les objets impliqués dans l'exécution de la tâche, tandis que TaskPurpose désigne la classification des tâches par spécialisation.

#### 2.3.5.4 Les ontologies d'application

Ce sont les ontologies les plus spécifiques. Contrairement à l'ontologie de domaine, une ontologie d'application, spécifique à une application donnée, ne peut pas être réutilisée pour d'autres



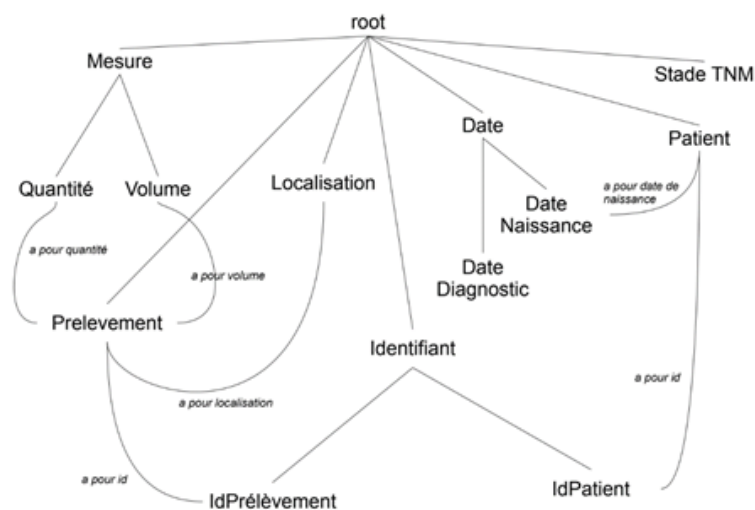


FIGURE 2.6 – Exemple d’une ontologie d’application, (NAUBOURG, SAVONNET et YÉTONGNON 2011)

applications puisqu’elle contient les connaissances requises pour une application particulière. Ce type d’ontologie décrit des concepts qui dépendent à la fois d’un domaine et d’un objectif spécifiques à une application. Par conséquent, elle spécialise souvent des ontologies de domaine et des ontologies de tâches pour une application donnée (RAJPATHAK, MOTTA et ROY 2001). Une ontologie d’application est utilisée afin de représenter des connaissances spécifiques à un sous-domaine, un système ou une application (GUARINO et GIARETTA 1995). Elle diffère de l’ontologie de domaine par sa représentation de la réalité du système d’information auquel elle est liée. Une ontologie de ce type peut être utilisée lors d’une coopération entre les systèmes des différents partenaires d’un domaine. Elle sert aussi de référence lors de discussions techniques entre les différents utilisateurs des systèmes d’un domaine afin de savoir si tel concept d’un système correspond bien à tel concept d’un autre système. Prenons l’exemple de deux systèmes de santé avec des identifiants de patients différents (NumDossier et CodePatient). Grâce à l’ontologie, ces deux identifiants feront tous les deux référence au même concept IdPatient afin de signifier ce qu’ils représentent. En effet, l’ontologie d’application représentée par la Figure 2.6, définit le domaine d’analyse de sang en identifiant le stade de TNM<sup>4</sup> (NAUBOURG, SAVONNET et YÉTONGNON 2011).

### 2.3.6 Le Langage OWL (Ontology Web Language)

Le langage des ontologies Web (OWL) est un langage du Web sémantique conçu pour représenter des connaissances riches et complexes sur des objets, des groupes d’objets et les relations entre les objets ((JAIN et SINGH 2013)). Le langage OWL est basé sur la logique informatique, de sorte que les connaissances exprimées dans OWL peuvent être exploitées par des programmes informatiques. OWL possède trois sous-langages (HORRIDGE et PATEL-SCHNEIDER 2009) :

- OWL-Lite : Ce sous-langage est destiné à être utilisé dans des situations où seule une hiérarchie de classes simple et des contraintes simples sont nécessaires, sa cardinalité est

4. Tumor, Nodes, Metastasis

limitée à 0 ou 1.

- OWL-DL : Pour combler le manque d'OWL-Lite, ce sous-langage possède des fonctionnalités qui enrichissent l'utilisation d'OWL comme les combinaisons booléennes de classes et les restrictions de propriétés de classes. D'autres propriétés permettant de décrire des classes disjointes. Avec toutes ces caractéristiques, OWL-DL devient le langage le plus utilisé car il offre à l'utilisateur une expressivité complète ((McGUINNESS, VAN HARMELEN et al. 2004)).
- OWL-Full : Ce sous-langage offre à ses utilisateurs le maximum d'expressivité et de liberté syntaxique de RDF ((roussey2011introduction)). Comme exemple, OWL-Full traite une classe comme un ensemble d'individus et comme un individu à la fois. Sa propriété de type de données se généralise pour inclure la propriété fonctionnelle inverse.

### 2.3.7 L'évaluation des ontologies

L'évaluation de la qualité d'une ontologie est une partie importante du développement d'une ontologie. Une ontologie peut être évaluée en fonction de nombreux critères : sa couverture d'un domaine particulier et sa complétude, la complexité et la granularité de cette couverture ; les cas d'utilisation spécifiques, les scénarios, les exigences, les applications, les sources de données pour lesquels elle a été développée, les propriétés formelles telles que la cohérence et la complétude de l'ontologie et le langage de représentation dans lequel elle est modélisée (OBRST et al. 2007).

### 2.3.8 Le raisonnement sémantique classique

Une ontologie permet d'intégrer les notions de raisonnement sémantique au modèle créé en les générant à travers un moteur d'inférence. Par ailleurs, le déploiement d'un raisonneur permet de garantir une formalisation hiérarchique des concepts ainsi que la cohérence de l'ontologie. Les ontologies construites à l'aide du langage OWL utilisent des règles logiques qui sont définies par l'être humain et elles sont compréhensibles par la machine. Les mécanismes de raisonnement permettent de déterminer certaines actions (décision) relatives à l'ontologie et à sa hiérarchie. Elles permettent également de déduire des conséquences logiques liées aux classes d'une ontologie. Elles sont implantées directement dans des moteurs d'inférence, où sont exécutées des règles SWRL(cf. section 2.3.8.2). Nous présentons ces notions dans ce qui suit.

#### 2.3.8.1 Les raisonneurs sémantiques

Un raisonneur sémantique, un moteur de raisonnement, un moteur de règles, ou simplement un raisonneur est un logiciel capable de déduire des conséquences logiques à partir d'un ensemble de faits/axiomes déclarés. Les capacités d'un raisonneur dépendent des axiomes et des règles d'inférence qu'il connaît, qui sont liés à un type particulier de logique. Le raisonneur est un composant clé pour travailler avec les ontologies OWL. Toute interrogation d'une ontologie OWL doit être effectuée à l'aide d'un raisonneur. Cela est dû au fait que la connaissance dans une ontologie peut ne pas être explicite et un raisonneur est nécessaire pour déduire la connaissance implicite afin d'obtenir les résultats corrects de la requête. Les raisonneurs OWL tels que Pellet, FaCT++ et HerMiT sont nécessaires pour exécuter les règles SWRL et déduire de nouveaux axiomes d'ontologie. Pellet a une fonctionnalité plus directe pour travailler avec OWL et les règles SWRL, il permet de définir des propriétés « build-in » qui définissent des SWRL personnalisés. Lorsque Pellet est utilisé pour raisonner sur une ontologie avec des règles SWRL

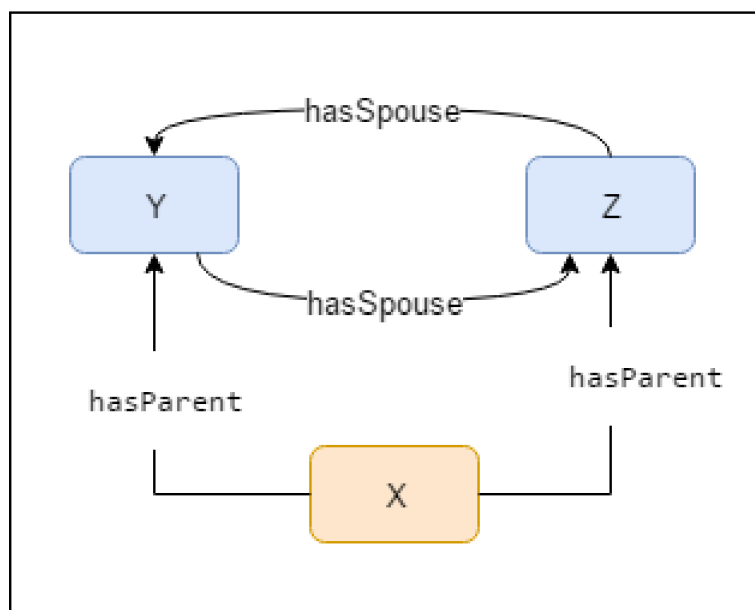


FIGURE 2.7 – Relation enfant de parents mariés (règle SWRL R1), (NAUBOURG, SAVONNET et YÉTONGNON 2011)

(cf. section 2.3.8.2), il prend ces règles en considération et renvoie des conclusions basées sur celles-ci.

### 2.3.8.2 Les règles SWRL (Semantic Web Rule Language)

Semantic Web Rule Language (SWRL) a été développé pour être le langage de règles du web sémantique. Ce langage permet aux utilisateurs d'écrire des règles qui peuvent être exprimées en termes de concepts OWL et qui peuvent raisonner sur des individus OWL. L'une des caractéristiques les plus puissantes du SWRL est sa capacité à prendre en charge des modules personnalisés, définis par l'utilisateur, pour étendre les modules SWRL de base afin que l'utilisateur puisse obtenir une extensibilité supplémentaire ((HORROCKS et al. 2004)).

Plusieurs types d'atomes sont pris en charge par le langage SWRL, tels que les atomes de classe, les atomes de propriété individuelle, les atomes de propriété de valeur de données et les atomes de plages de données. Les atomes les plus puissants sont les atomes intégrés, où le SWRL fournit plusieurs types d'annotations de propriétés sous la forme « built-in » en permettant à l'utilisateur de concevoir et d'utiliser ses propres « built-in » (O'CONNOR et al. 2005). Le langage OWL2 n'est pas capable d'exprimer toutes les relations. Par exemple, le SWRL ne peut pas exprimer la relation enfant de parents mariés, parce qu'il n'y a aucun moyen dans OWL2 d'exprimer la relation entre les individus avec lesquels un individu a des relations. Afin de couvrir cette limitation, les règles SWRL peuvent être formalisées comme suit :

$\text{Person}(?x), \text{hasParent}(?x, ?y), \text{hasParent}(?x, ?z), \text{hasSpouse}(?y, ?z) \Rightarrow \text{ChildOfMarriedParents}(?x)$   
 (R1) Cette règle SWRL (R1) indique qu'un individu  $x$  de la classe *Person*, qui a des parents  $y$  et  $z$  tels que  $y$  *hasSpouse*  $z$ , appartient à une nouvelle classe *ChildOfMarriedParents*. La figure 2.7 illustre la relation enfant de parents mariés de la règle SWRL R1.

$C, D \longrightarrow A$		(atomic concept)
$\top$		(universal concept)
$\perp$		(bottom concept)
$C \sqcap D$		(intersection)
$C \sqcup D$		(disjunction)
$\neg C$		(negation)
$\forall R.C$		(value restriction)
$\exists R.C$		(existential quantification)

FIGURE 2.8 – Aperçu des règles syntaxiques de la logique de descriptions, (WARREN et al. 2015)

### 2.3.9 Les formalismes de représentation des connaissances

Depuis l'apparition de l'intelligence artificielle, plusieurs formalismes de représentation de connaissances ont été proposés, pour formaliser les connaissances d'un domaine puis d'établir des raisonnements sur ces représentations. Parmi ces formalismes développés au niveau conceptuel pour la modélisation d'ontologie, nous trouvons trois grands modèles qui sont : les graphes conceptuels, les langages de frames et les logiques de descriptions (GHORBEL, BAHRI et BOUAZIZ 2009).

#### 2.3.9.1 Les logiques de descriptions

La recherche en logiques de descriptions (LDs) date depuis le début des années 90. Elles sont issues des travaux fondateurs de Brachmann et de son système KL-ONE (BRACHMAN et al. 1991). Les LDs peuvent être définies comme un fragment de la logique du premier ordre, dans lequel les formules ont une variable libre pour les descriptions de concepts et deux variables libres pour les descriptions de relations (HORROCKS 2005). Les logiques de descriptions peuvent aussi être considérées comme des logiques multimodales (car elles ont plusieurs relations d'accessibilité) propositionnelles. Comme ces dernières, elles ont aussi certaines extensions non exprimables en logique du premier ordre (comme la relation de clôture transitive) ou difficiles à exprimer (comme les cardinalités sur les rôles) (ROSATI 2007). Les entités de base qui sont définies et manipulées dans une logique de descriptions sont les concepts, les rôles et les individus. Un concept permet de représenter un ensemble d'individus, tandis qu'un rôle représente une relation binaire entre des individus. Un concept correspond à une entité générique d'un domaine d'application et un individu à une entité particulière, instance d'un concept (HORROCKS et al. 2007). Les concepts et les rôles peuvent être primitifs ou définis. Les concepts (éventuellement les rôles) primitifs sont comparables à des atomes et servent de base à la construction des concepts définis (éventuellement les rôles définis).

Une logique de descriptions est définie à partir d'un ensemble de concepts primitifs, un ensemble de rôles primitifs, des constantes  $\top$  et  $\perp$  et des règles de syntaxe (Figure 2.8).

La bonne formalisation des LDs tient à leur sémantique (HEMAN 2005). C'est cette sémantique qui permet d'avoir des mécanismes d'inférence bien fondés pour lesquels on peut démontrer des résultats de cohérence et de complétude.

### 2.3.9.2 Les limites des logiques de description

Les limitations des logiques de descriptions sont de plusieurs sortes, parmi lesquelles figurent :

- La difficulté de représenter des relations entre rôles, comme dans les exemples suivants :
  - deux personnes qui ont pour résidence des pays différents ;
  - deux enfants d'une même famille qui vont dans deux écoles différentes qui sont éloignées l'une de l'autre de 1 kilomètre ;
- La représentation de quantifications sur les relations comme dans l'exemple :
  - tous les élèves assistent à tous les cours ;
- Les traitements numériques en général ;
- Les définitions récursives ;
- Les relations n-aires.

Pour la plupart des formalismes de représentation des connaissances, les logiques de descriptions classiques sont primordiales pour la définition des connaissances. Elles ont un rôle considérable dans différents domaines malgré toutes leurs limitations. En effet, elles sont sévèrement limitées à la fois par leur faiblesse à représenter notre incertitude sur le monde, en raison du manque de connaissances sur le monde réel, et par leur faiblesse à représenter les connaissances intrinsèquement imprécises. Il y a des concepts, comme la chaleur par exemple, pour lesquelles aucune définition exacte existe et, par conséquent, un fait comme « 35° Celsius est chaud », étant plutôt vrai ou faux, a une valeur de vérité entre vrai et faux (DJELLAL [s. d.](#)).

La structure des logiques de descriptions classique qui ne peut exprimer des faits qu'avec « vrai » ou « faux » limite leur champs d'action dans des techniques et des applications de l'intelligence Artificielle comme l'aide à la décision et le Web sémantique, qui veulent imiter le raisonnement et l'esprit humain. C'est à dire des techniques qui s'appuient sur l'incertitude pour leur bon fonctionnement. De ce fait, on peut affirmer que les logiques de description classiques ont une expressivité considérable, mais elles sont très faibles lorsqu'elles modélisent un domaine dont les connaissances et les informations sont vagues et imprécises comme le domaine de soins. Pour cette raison il y a eu beaucoup de propositions permettant d'étendre les logiques de descriptions par des théories mathématiques qui traitent l'incertain et l'imprécis (DJELLAL [s. d.](#)). Le résultat étant la naissance des logiques de descriptions floues (KONSTANTOPOULOS et APOSTOLIKAS [2007](#)).

## 2.4 Les ontologies floues

Les ontologies représentent un grand intérêt pour divers domaines, et en particulier pour le domaine du Web. Cependant, leur application au Web sémantique, qui comporte souvent des imperfections (imprécisions, incertitudes et ambiguïtés), connaît des difficultés. Les ontologies doivent devenir capables de représenter non seulement des notions précises, mais également des notions floues. Dans ce qui suit, nous présentons un survol des travaux existants des systèmes à base d'ontologies traitant des connaissances imprécise ou incertaines, en se basant sur des logiques de descriptions floues.

### 2.4.1 Les logiques de descriptions floues

Les Logiques de descriptions floues (Fuzzy DLs) sont des extensions des logiques de descriptions classiques. Elles ont été proposées en tant que langages pouvant représenter et raisonner sur des connaissances vagues ou imprécises. Ces extensions ont gagné une attention considérable ces dernières années, d'une part parce qu'elles sont indispensables pour les nombreuses applications qui sont par nature imprécises, comme l'analyse multimédia et les applications géo-spatiales. D'autre part, ces extensions peuvent être déployées dans le cadre des applications du Web sémantique, comme la représentation des ontologies qui modélisent des domaines dont les connaissances sont imprécises (DJELLAL [s. d.](#)). Les extensions floues des logiques de descriptions ont une sémantique exprimée grâce à la théorie des ensembles flous : pour une interprétation  $I = (\delta^I, \cdot^I)$ , ou  $\delta^I$  présente un ensemble d'individus introduit dans le domaine d'interprétation, et  $I$  est une fonction d'interprétation qui fait correspondre à une expression conceptuelle d'un ensemble de concept  $C$  qui s'interprète comme :

- un concept flou considéré comme un ensemble flou  $C^I$  de  $\delta^I$  (cf. section ??),
- un rôle  $R$  comme une relation binaire floue  $RI$  de  $\delta^I * \delta^I$  (cf. section ??).

L'appartenance d'une instance à un concept  $C(a^I \in a^I)$  dans le cas classique devient le degré d'appartenance de  $a^I C^I : \mu_{C^I}(a^I)$ .

### 2.4.2 Définition des ontologies Floues

Les ontologies floues se basent sur l'intégration de la logique floue à la définition des ontologies précises pour représenter les incertitudes et les imprécisions dans le cadre du Web sémantique. Nous pouvons définir l'ontologie floue comme une ontologie qui possède, en plus des composants de base (concepts, relations, axiomes et instances), de nouveaux composants conformes à la logique floue : les concepts flous et les relations floues. Ces derniers assurent la représentation des parties floues d'un univers de discours.

### 2.4.3 Les composants des ontologies floues

Une ontologie floue comprend des concepts précis (exacts), des concepts flous, des relations précises (exactes), des relations floues, des axiomes et des instances. Les concepts et les relations précis gardent les mêmes définitions et jouent les mêmes rôles que dans une ontologie classique. Les concepts et les relations flous, définis selon la logique floue, servent à la représentation des éléments flous du domaine modélisé. Ils ont des répercussions sur l'expression des axiomes et des instances (GHORBEL, BAHRI et BOUAZIZ [2009](#)).

#### 2.4.3.1 Les concepts flous

Un concept flou est considéré comme un ensemble flou. Ses instances possèdent ainsi des degrés d'appartenance prenant leur valeur dans l'intervalle  $[0,1]$ . Ces degrés sont calculés conformément aux formules de calcul relatives à la fonction d'appartenance définie pour le concept (STRACCIA [2005](#)). Par exemple, nous présentons un concept flou qui décrit le taux de glycémie normale dans le sang (HOUILI [s. d.](#)).

Concept : Taux\_Glycémie\_Normal




FIGURE 2.9 – Fonction d'appartenance de taux de glycémie normal , (HOUILI [s. d.]

- Le terme linguistique : Normal (Taux Glycémie normal)
- Taux\_Glycémie\_Normal :  $(\forall x. \text{Appartient}(\text{Constituantsdusang})x) \sqcap \ni \text{Taux}_{\text{Glucose}}.\text{Normale}$
- Fonction d'appartenance : T\_Gly\_Nor (0.8, 0.9, 1.1, 1.2) de type trapézoïdale

#### 2.4.3.2 Les relations floues

Une relation floue est aussi définie comme un ensemble flou. Ses instances possèdent ainsi des degrés d'appartenance prenant leurs valeurs dans l'intervalle  $[0,1]$ . Ces degrés sont calculés conformément aux formules de calcul relatives à la fonction d'appartenance définie pour la relation. Par exemple, la relation floue « Est\_Diabétique » possède le domaine et co-domaine « Patient/Hyperglycémie ». Cette relation est définie par les axiomes flous suivants :

- Est\_Dia(Taux) = 1 si Taux  $\in [1.2, 5]$
- Est\_Dia(Taux) =  $\frac{\text{Taux}-1.1}{1.2-1.1}$  Taux  $\in [1.1, 1.2]$
- Est\_Dia(Taux) = 0 ailleurs

#### 2.4.3.3 Les axiomes

A part leurs utilisations classiques, les axiomes servent à exprimer les formules de calcul des fonctions d'appartenance. Par exemple, le concept flou « Taux\_glycémie\_normal » possède les axiomes flous suivants :

- T\_Gly\_Nor(Taux) = 1 Si Taux  $\in [0.9, 1.1]$
- T\_Gly\_Nor(Taux) =  $\frac{\text{Taux}-0.8}{0.9-0.8}$  Si Taux  $\in [0.8, 0.9]$
- T\_Gly\_Nor(Taux) =  $\frac{1.2-\text{Taux}}{1.2-1.1}$  Si Taux  $\in [1.1, 1.2]$
- T\_Gly\_Nor(Taux) = 0 Ailleurs

#### 2.4.3.4 Les instances

Dans les ontologies floues, l'appartenance d'une instance a un composant flou n'est pas sûre à 100%. Elle est déterminée par une variable probabiliste prenant ses valeurs entre 0 et 1, et déterminée par une fonction d'appartenance (GHORBEL, BAHRI et BOUAZIZ [2009]). Par exemple, le concept flou Hyper-Diastolique présente l'instance floue « 93 mmHg » et le degré d'appartenance « 1 ».

## 2.5 Les ontologies médicales

Cette section révèle l'avantage d'utiliser les ontologies dans le domaine de santé et dans d'autres plusieurs domaines. Les processus de soins deviennent de plus en plus pointus au cours de ces dernières décennies en raison des progrès techniques et de l'augmentation croissante des connaissances dans le domaine de la santé. Ces connaissances accrues nécessitent un système performant pour le stockage, la gestion et le transfert des informations entre les plateformes médicales. Les ontologies offrent un moyen de créer un langage commun pour partager ces informations ainsi qu'un transfert transparent des données, même hétérogènes, entre différents systèmes. La santé a été l'un des premiers domaines à intégrer des ontologies dans la recherche, afin de faire face à l'évolution des connaissances avec des données volumineuses et une terminologie hétérogène et incohérente. Cependant, l'utilisation des ontologies dans les applications proches des environnements cliniques est encore faible (KOLIAS et al. [2014]; ZENUNI et al. [2015]). Nous présentons dans cette section les ontologies de domaines médicaux et ses applications.

### 2.5.1 Les ontologies de standardisation médicales

Depuis la classification des espèces de Linné en 1735, il y a eu une explosion du nombre de classifications dans le domaine biomédical (DEUVE [2004]). Ces classifications ont été construites pour répondre à des besoins divers selon des perspectives différentes liées par exemple à la biologie, la génétique ou la médecine. Par conséquent, pour faciliter la recherche biomédicale et la normalisation du vocabulaire médical, plusieurs ontologies et bases de connaissances ont été définies, telles que la « Systematized Nomenclature of Medicine Clinical Terms (SNOMEDCT) », la « Classification internationale des maladies (CIM) », la « Disease Ontology (DO) », la « Gene Ontology (GO) ». Récemment, avec le progrès technologique et l'utilisation massive des outils informatiques, le problème de la réutilisation et du partage des données codées avec différents systèmes de classification s'est accentué. Dans ce qui suit, nous présentons quelques classifications médicales principales.

#### 2.5.1.1 La classification ICD

La ICD (International Statistical Classification of Diseases and Related Health Problems), ou la CIM (Classification Statistique Internationale des Maladies et des Problèmes de Santé Connexes), abrégée en français en Classification Internationale des Maladies, est publiée par l'Organisation Mondiale de la Santé. Elle est utilisée à travers le monde pour enregistrer les



causes de morbidité et de mortalité. La classification ICD permet le codage des maladies, des traumatismes et de l'ensemble des motifs de recours aux services de santé. L'objectif principal de cette classification est de "permettre l'analyse systématique, l'interprétation et la comparaison des données de mortalité et de morbidité recueillies dans différents pays ou régions à des époques différentes" (JONASSEN et SABOE 1995).

### 2.5.1.2 SNOMED CT

La SNOMED CT<sup>5</sup> (Systematized Nomenclature of MEDicine - Clinical Terms) est une terminologie clinique qui regroupe la SNOMED Reference Terminology (SNOMED RT) et la Version 3 de la United Kingdom's Clinical Terms (anciennement connue sous le nom de Read Codes). Son objectif est de fournir un environnement commun pour coder et partager les informations relatives à un patient (histoire, maladie, traitement, etc.). Elle est utilisée dans plusieurs tâches : l'indexation de documents cliniques, l'aide à la décision clinique, l'indexation d'images, etc. Une organisation internationale, l'IHTSDO (Health Terminology Standards Development Organisation) a pris la propriété de la SNOMED CT depuis le 26 avril 2007 pour être responsable de son développement et de ses révisions.

### 2.5.1.3 Le thésaurus MeSH

Le MeSH (Medical Subject Headings) est un thésaurus médical conçu par la NLM<sup>6</sup> (National Library of Medicine) aux États-Unis. Il est utilisé en particulier par PubMed (Interface de la NLM à la base de données MEDLINE<sup>7</sup>) pour l'indexation et la recherche des publications scientifiques. Il compte 24 767 descripteurs dans sa version de 2008. Les descripteurs MeSH sont organisés en 16 catégories : la catégorie A pour les termes anatomiques, la catégorie B pour les organismes, la catégorie C pour les maladies, etc. Chaque catégorie est subdivisée en sous-catégories. À l'intérieur de chaque catégorie, les descripteurs sont structurés hiérarchiquement, du plus général au plus spécifique. Le MeSH est traduit en français par l'INSERM et sert aussi de thésaurus au site CISMef (cf. section 2.5.1.6) et au site HON que nous allons présenter plus loin.

### 2.5.1.4 L'ontologie FMA

La FMA (Foundational Model of Anatomy) est une ontologie de référence dans le domaine de l'anatomie. Elle vise à représenter les entités anatomiques et les relations nécessaires pour la modélisation symbolique de la structure phénotypique du corps humain sous une forme qui soit compréhensible par l'homme et qui soit également traitable par une machine (ROSSE et MEJINO 2008). Les entités anatomiques sont représentées dans la FMA, allant des macromolécules biologiques aux cellules, tissus, organes, systèmes d'organes, les majeures parties du corps, y compris le corps entier. Elle contient actuellement autour de 75 000 entités (concepts) anatomiques et plus de 120 000 termes.

5. <http://www.snomed.org/snomedct/index.html>

6. <https://www.nlm.nih.gov/>

7. MEDLINE est une base de données bibliographique qui couvre tous les domaines médicaux de l'année 1966 à nos jours : plus de 11 millions de références issues de 4 300 périodiques, principalement en langue anglaise.

### 2.5.1.5 L'ontologie DOLCE

L'ontologie DOLCE<sup>8</sup> (Descriptive Ontology for Linguistic and Cognitive Engineering), élaborée par l'équipe de Nicola Guarino (LOA, Trento, Italie), est une ontologie de haut niveau. Elle est l'un des résultats du projet européen WonderWeb Foundation Ontologies Library. Son objectif est d'être utilisé pour concevoir des ontologies de domaine plus spécifiques.

### 2.5.1.6 Le projet CISMef

En France, l'équipe CISMef du Centre Hospitalier Universitaire de Rouen a initié le projet CISMef<sup>9</sup> (Catalogue et Index des Sites MEDicaux Francophones), qui a débuté en même temps que le site Web du CHU en février 1995. Ce catalogue indexe les principaux sites et documents francophones de qualité médicale contrôlée. En décembre 2007, il a dépassé les 41 300 ressources indexées avec une moyenne de 80 nouvelles ressources par semaine. Cette liste de sites contient un classement thématique, en particulier des spécialités médicales, un classement alphabétique, et un accès par type de ressources. Depuis juin 2000, l'outil associé, Doc'CISMef, permet d'effectuer des recherches dans le catalogue de ressources, et offre des possibilités de recherches plus étendues (DARMONI et al. 2000). CISMef utilise deux outils standards pour organiser l'information : le thésaurus MeSH (cf. section 2.5.1.3), utilisé notamment par la base de données bibliographique Medline, et le format de métadonnées du Dublin Core.

## 2.5.2 Les ontologies en santé

Comme de nombreuses autres industries, le domaine de la santé rencontre actuellement les possibilités et les défis de la numérisation. Cela ouvre la voie à de nombreuses applications différentes utilisant des ontologies. Dans ce qui suit, plusieurs domaines d'application importants seront présentés, où les ontologies peuvent être et ont été utilisées avec avantage : les systèmes d'information en santé, les dossiers médicaux électroniques, les systèmes d'aide à la décision clinique, les terminologies, la simulation et la recherche.

### 2.5.2.1 Systèmes d'information en santé (SIS)

À la fin des années 1980, un système électronique de connaissances sur les informations de santé est apparu. Ce système basé sur des données logicielles et matérielles pour faciliter les processus de soins tels que le diagnostic et le traitement. Il est appelé système d'information en santé (SIS) (STAVERT-DOBSON 2016). Aujourd'hui, les SIS se sont développés en un système sociotechnique à part entière. La facilité d'utilisation du SIS ne dépend pas seulement des données, du matériel ou du logiciel, mais aussi des personnes qui l'utilisent et de l'organisation dans laquelle elles opèrent. Par conséquent, l'utilisation fréquente de digitalisation des technologies augmente le nombre de données disponibles ceux qui facilitent l'efficacité et la validité du SIS. Les applications basées sur les ontologies au sein des SIS visent deux objectifs principaux : (1) permettre au SIS de partager différents formats de données de manière transparente et (2) établir

8. <http://www.loa-cnr.it/DOLCE.html>

9. <https://www.cismef.org/cismef/>

un langage commun pour la terminologie utilisée. Ces fonctions rendent possible l'interopérabilité des sous-systèmes dans le SIS et fournissent les fonctions nécessaires au traitement des données. Un SIS peut donc être utilisé pour évaluer le niveau d'interopérabilité dans le cadre des processus de soins (KOLIAS et al. [2014]).

### 2.5.2.2 Les dossiers de santé électroniques (DES)

L'un des principaux systèmes intégrés aux SIS est le DES, qui comprend des informations concernant les patients, telles que les dossiers médicaux. Le DES fonctionne comme une norme dans le domaine de la santé qui est utilisée pour contenir et attribuer des informations sur les patients. En outre, les informations représentées dans un DSE sont tirées de systèmes subordonnés dans le SIS (KOLIAS et al. [2014]). Le système de données DES permet un accès plus facile aux informations sur les patients à un niveau international. Dans le domaine des ontologies, un DES fonctionne principalement comme une source d'informations, éventuellement basée sur les technologies et les normes du web sémantique, comme les archétypes du cadre openDSE (CARMEN LEGAZ-GARCÍA et al. [2016]).

### 2.5.2.3 Systèmes d'aide à la décision clinique (SADC)

Un système d'aide à la décision clinique (SADC) est une technologie de l'information visant à aider les cliniciens dans les processus de prise de décision. Il nécessite l'entrée d'un ou plusieurs types de données et utilise des algorithmes mathématiques et logiques basés sur des procédures cliniques et de grands ensembles de données pour l'aide au diagnostic. Un SADC fait généralement partie d'un SIS et en tire des informations. L'utilisation d'ontologies lors de la création d'un SADC permet de combiner des données provenant de différents systèmes. Un exemple de SADC basé sur les technologies du Web sémantique a été présenté par Zhang et ses collaborateurs (Zhang et al. 2016). Il permet d'améliorer la validité et la convivialité du SADC, car les données peuvent être transférées et interprétées sémantiquement. Dans ce contexte, on trouve dans la littérature des systèmes d'aide au triage basés sur les ontologies pour les professionnels de santé aux urgences. Par exemple, dans (MICHALOWSKI et al. [2005]) un système accessible par un modèle d'information médicale basé sur une ontologie a été défini pour le triage des patients afin de modéliser leur plainte principale. Dans (FARION et al. [2009]), les auteurs ont proposé un modèle qui traite des décisions cliniques hétérogènes. Ils ont suggéré l'utilisation de des ontologies afin d'extraire de nouveaux symptômes après ils ont évalué le système en effectuant quelques simulations. (PEDRO et al. [2005]) ont proposé un modèle mobile qui indique le pourcentage de confiance pour chacune de leurs réponses concernant l'état du patient afin de déterminer automatiquement la meilleure catégorie de triage pour un patient. Dans (JAYARAMAN et al. [2013]), les auteurs ont combiné le système de triage avec une architecture orientée services (SOA) pour stocker et manipuler les données de triage en temps réel avec les données stockées dans l'ontologie du domaine. (WUNSCH, DA COSTA et RIGHI [2017]) ont étudié la capacité de différents protocoles de triage basés sur une ontologie de domaine pour automatiser le triage des patients. Cependant, ce système n'inclut pas toutes les données médicales nécessaires ayant un impact significatif sur la décision de triage, comme les antécédents médicaux qui ne sont pas pris en compte. En effet, chaque modèle ontologique proposé peut être enrichi avec une technique d'apprentissage automatique. Cette combinaison peut aboutir à créer des systèmes rationnels. Cependant, il faut assurer une meilleure qualité des données et des connaissances pour que le modèle d'apprentissage soit fiable et performant. Nous définissons dans ce qui suit

les différentes catégories liées aux imperfections des données et les meilleures méthodes pour gérer ce problème.

## 2.6 La gestion des connaissances imparfaites

Dans le domaine de santé, ainsi que dans de nombreux autres domaines, l'imperfection des données liées aux connaissances du domaine est difficile à éviter. Dans ce cas, il est difficile d'aider les spécialistes à prendre une décision comme par exemple de construire des systèmes automatiques pour fournir des outils de classification ou de reconnaissance de formes. Il existe deux types de difficultés : (1) celles liées au type d'imperfection que nous devons considérer (e.g. informations partielles, incertitudes, imprécisions) et (2) celles liées au type de problème que nous devons résoudre (e.g. images à traiter, règles expertes, bases de données). Quel modèle mathématique devons-nous choisir pour gérer ces connaissances imparfaites? Quelle est la meilleure représentation des connaissances pour un problème donné? Les réponses à ces questions ne sont pas évidentes. Notre objectif est de présenter plusieurs cadres possibles pour représenter et gérer les connaissances imparfaites, en particulier dans les domaines biologiques et médicaux. Dans ce qui suit, nous commençons par expliquer les causes de l'imperfection de ces connaissances avant de présenter les différents types d'imperfection.

### 2.6.1 Causes des connaissances imparfaites

Dans plusieurs domaines, nous pouvons trouver des connaissances imparfaites qui sont dues à des causes diverses, comme :

- des conditions d'observation insuffisantes pour obtenir la précision nécessaire (par exemple, dans le cas des images radiographiques).
- de la nature même du phénomène observé.

C'est souvent le cas en biologie ou en médecine, car les facteurs naturels n'ont souvent pas de valeur précise, éventuellement disponible pour tous les patients. Les conditions ou les valeurs des critères varient selon la situation (par exemple, la taille et la forme des micro calcifications malignes dans le cancer du sein). Il arrive aussi que plusieurs formes d'imprécision ne puissent être gérées indépendamment. Il y a plusieurs types d'imperfection des données. Par exemple, les incertitudes peuvent être présentées en même temps que les imprécisions, et généralement l'incomplétude entraîne des incertitudes. Nous présentons par la suite la différence ainsi que les liens entre ces terminologies.

### 2.6.2 Typologie de l'imperfections des données

Nous détaillons dans ce qui suit les différentes formes d'imperfections des données.

#### 2.6.2.1 Les incertitudes sur les données

Les imperfections sont appelées incertitudes lorsqu'il y a un doute sur l'information. Cela signifie que nous ne sommes pas certains qu'une affirmation est vraie ou fausse à cause :

- Du comportement aléatoire d'un phénomène (par exemple, les facteurs de transmission des caractéristiques génétiques) lié à l'incertitude probabiliste. Nous parlons ici d'incertitude aléatoire, liée à la variabilité d'un phénomène naturel.
- De la fiabilité ou la solidité limitée d'un observateur du phénomène qui exprime l'affirmation, ou du capteur utilisé pour une mesure. L'incertitude est alors non probabiliste. Les incertitudes peuvent être représentées soit par des nombres, tels que des probabilités ou des degrés de confiance indiquant le niveau de certitude de la validité d'un énoncé, soit par des expressions telles que " je crois que... "ou "il est possible que...".

### 2.6.2.2 Les imprécisions des données

Le deuxième type d'imperfection est l'imprécision, lorsque certaines caractéristiques d'un phénomène ne peuvent être décrites avec exactitude. Les imprécisions se présentent sous deux formes principales :

- Des valeurs approximatives (par exemple, les limites du niveau normal de glycémie à un âge donné ne sont pas sensibles à une variation de 1%) ou des descriptions vagues utilisant des termes du langage naturel (par exemple, "une température élevée " ou " des attaques fréquentes ").

### 2.6.2.3 L'incomplétude des données

La connaissance incomplète est le dernier type d'imperfection, dans lequel il y a un manque d'information sur certaines variables ou critères ou éléments d'une situation donnée. Cette incomplétude peut apparaître à cause de défauts dans l'acquisition des connaissances (par exemple, l'âge d'un patient n'a pas été enregistré) ou à cause de règles ou de faits généraux qui sont habituellement vrais mais admettent quelques exceptions, dont la liste est impossible à donner (par exemple, en général, le médicament *X* ne provoque pas de somnolence). Nous parlons ici d'incertitude épistémique, liée à un manque de connaissances.

## 2.6.3 Choix d'une méthode de traitement des données

Le choix d'une méthode de traitement des données est lié au choix de la représentation des connaissances, qui peut être numérique, symbolique, logique ou sémantique. Ce choix dépend de la nature du problème d'aide à la décision comme la classification ou le diagnostic automatique. Les connaissances disponibles peuvent consister en des images ou des bases de données contenant des informations factuelles ou des connaissances expertes fournies par des spécialistes du domaine. Ces connaissances sont, dans certains cas, directement gérées par un outil approprié, comme un système expert ou une méthode de reconnaissance de formes (e.g. si l'objet à identifier sur les images n'est pas trop variable). Dans d'autres cas, l'apprentissage est nécessaire comme étape préliminaire à la construction d'un système automatique. Cela signifie que des exemples de situations connues sont donnés et affectés à une classe, un diagnostic, une décision, ou plus généralement une étiquette par un spécialiste (on parle de labélisation des données). Sur la base de ces exemples fournis à la machine, une méthode générale est construite pour effectuer une affectation similaire dans de nouvelles situations, par exemple par apprentissage inductif, raisonnement à partir de cas, ou réseaux neuronaux ??). Il est également possible que des explications soient nécessaires pour les raisons qui conduisent le système à un

Type of imperfection	Representation method	Management method
	Symbolic beliefs	Modal logic Truth maintenance systems Autoepistemic logic
Uncertainties	Probabilities Confidence degrees Belief, plausibility measures Possibility, necessity degrees	Probabilistic logic Bayesian Induction Belief networks Propagation of degrees Evidence theory Possibilistic logic
Imprecisions	Fuzzy sets Error intervals Validity frequencies	Fuzzy logic Fuzzy set-based techniques Interval analysis Numerical quantifiers
General laws, exceptions	Hypotheses Default rules	Hypothetical reasoning Default reasoning

FIGURE 2.10 – Les méthodes de gestion des imperfections de connaissances , (BOUCHON-MEUNIER 2000)

diagnostic donné ou au choix d'une étiquette. De tels problèmes de communication homme-machine sont étudiés en intelligence artificielle. La figure 2.10 présente les principales méthodes de représentation et de gestion des connaissances correspondant aux trois types d'imperfection que nous avons mentionnés (cf. section 2.6.2). Dans ce qui suit, nous nous focalisons sur les méthodes numériques liés à l'incertitude et l'imprécision (cadre en gras de la figure 2.10). Il existe d'autres types de méthodes qui ne sont pas directement dédiées aux imperfections que nous avons mentionnées mais qui fournissent des approches numériques de gestion des données, telles que le chaos, les fractales, les ondelettes, les réseaux neuronaux et la programmation basée sur la génétique, qui sont également utilisées de manière intensive, notamment en médecine. Tous ces outils ont des avantages et aussi certains inconvénients. Il est donc intéressant d'utiliser plusieurs d'entre eux comme éléments complémentaires d'un système général de traitement des données, en tirant parti de la synergie entre eux, de sorte que les qualités d'une méthode compensent les inconvénients d'une autre. Par exemple, la logique floue est utilisée pour sa capacité à gérer des connaissances imprécises, mais elle peut être complémentaire aux réseaux de neurones pour apprendre des coefficients ou des fonctions (JOSHI, RANJAN et BHARTI 2021). Une telle association de méthodes est typique de ce que l'on appelle l'informatique douce, qui a été initiée par (ZADEH 1990) dans les années 1990 et fournit des résultats intéressants dans de nombreuses applications du monde réel. Dans les sections suivantes, nous présentons les principes fondamentaux des principales méthodes numériques mentionnées dans la figure 2.10.

## 2.6.4 Les approches de gestion des connaissances imparfaites

### 2.6.4.1 La logique floue

La théorie des ensembles flous, introduite en 1965 par Zadeh (ZADEH 1965), fournit une représentation des connaissances adaptée aux problèmes biologiques et médicaux car elle nous permet de travailler avec des informations imprécises et de gérer donc un certain type d'incertitude. Nous pouvons prendre comme exemple le niveau de glycémie des patients. Nous considérons que le seuil est égal à 1,4 g/L, fournissant deux classes de niveaux : les niveaux égaux au seuil, étiquetés "normaux", et les niveaux supérieurs au seuil, étiquetés "anormaux". Le passage d'une étiquette à l'autre apparaît brusquement car un niveau de 1,39 g/l est considéré




FIGURE 2.11 – La fonction d'appartenance A , (BOUCHON-MEUNIER 2000)

comme normal et un niveau de 1,41 g/l est considéré comme anormal. Nous pouvons plutôt établir un passage progressif de la classe des niveaux normaux à celle des niveaux anormaux et considérer que le niveau est normal jusqu'à 1,3 g/l ; que plus le niveau est grand entre 1,3 et 1,5 g/l, moins ce niveau est normal ; et enfin que le niveau est considéré comme réellement anormal lorsqu'il est supérieur à 1,5 g/l. Nous définissons ensuite un ensemble flou A de l'ensemble X des valeurs possibles du taux de glycémie au moyen d'une fonction d'appartenance, qui associe un coefficient  $f_A(x)$  dans  $[0,1]$  à chaque élément  $x$  de X. Ce coefficient indique dans quelle mesure  $x$  appartient à A (cf. figure 2.11). La principale nouveauté de la théorie des ensembles flous par rapport à la théorie classique des ensembles est le concept d'appartenance partielle d'un élément à une classe ou à une catégorie. Cela correspond à l'idée qu'un niveau peut être « peu anormal ». Ce concept découle de la possibilité de représenter une connaissance graduelle, telle que "plus la valeur augmente entre des limites données, plus le niveau est anormal", et de permettre le passage progressif d'une classe (la classe des niveaux normaux) à une autre (la classe des niveaux anormaux). Cette possibilité justifie l'utilisation d'une telle représentation des connaissances pour la modélisation de phénomènes biologiques, dans lesquels il n'existe généralement pas de frontière stricte entre des situations voisines.

Une telle représentation est également intéressante car elle peut être adaptée à l'environnement. Si les patients observés sont âgés, la fonction d'appartenance à la classe des glycémies anormales indiquée dans la figure 11 doit être décalée de 0,4 g/l vers la droite (un patient âgé a une glycémie normale jusqu'à 1.7 g/l). Un autre avantage de cette approche est que l'on peut mettre en place une interface entre les valeurs numériques (1,3 g/l) et les valeurs symboliques exprimées en langage naturel (niveau normal). Par exemple, un jeune patient dont le niveau de glycémie est de 1,7 g/l (valeur numérique) est associé à la valeur symbolique "anormal". Inversement, un nouveau patient sans dossier dans un hôpital peut indiquer qu'il a eu un niveau de glycémie anormal dans le passé ; cette information symbolique est prise en compte avec les niveaux mesurés (numériques) à obtenir. Il est facile de voir que les ensembles flous sont utiles pour représenter des connaissances imprécises aux limites mal définies, telles que les valeurs approximatives avec des caractéristiques vagues ((BOUCHON-MEUNIER 2000)). Une telle repré-




FIGURE 2.12 – La fonction d'appartenance B , (BOUCHON-MEUNIER 2000)

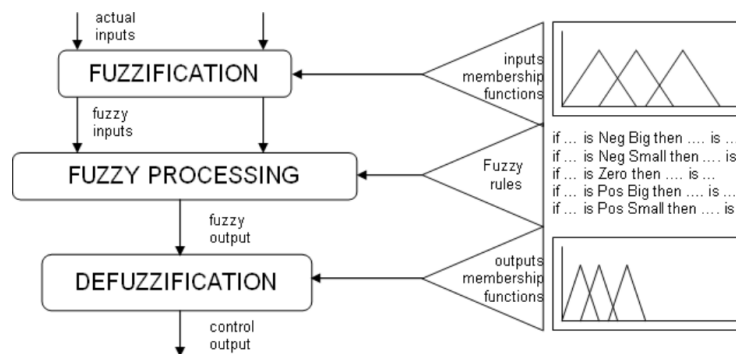


FIGURE 2.13 – Les étapes de la logique floue , (BOUCHON-MEUNIER 2000)

sentation est également compatible avec la représentation de certains types d'incertitudes au moyen de la théorie des possibilités, que nous développons ultérieurement (cf. section 4.4.2.2). La logique floue, dans la plupart des applications actuelles, permet de prendre en compte toutes sortes de connaissances qualitatives de concepteurs et d'opérateurs dans l'automatisation des systèmes. Le moteur d'inférence est le cœur du fonctionnement d'un contrôleur flou (et de tout système de règles floues). Son fonctionnement réel peut être divisé en trois étapes (figure 2.13) :

- Fuzzification - les entrées réelles sont fuzzifiées et des entrées floues sont obtenues grâce à la fonction d'appartenance présentée précédemment (cf. Figures 2.11 2.12).
- Traitement flou - traitement des entrées floues selon les règles définies et production de sorties floues.
- Défuzzification - production d'une valeur réelle nette pour une sortie floue.

La logique floue est également une approche commune en médecine ((PHUONG et KREINOVICH 2001)) et dans le domaine du biomédical ((BECKER et al. 1997)). Elle est aussi utilisée pour quantifier la qualité de service médical ((BÜYÜKÖZKAN et ÇİFÇİ 2011)) ou encore l'évaluation des



risques dans les établissements de soins ((YUCEL et al. 2012; SMITH et ELOFF 2000)). Elle représente un outil qui permet à la fois de représenter et de gérer l'imprécision des connaissances.

#### 2.6.4.2 La théorie des possibilités

La théorie des ensembles flous fournit une représentation des connaissances imprécises. Elle ne donne pas de représentation immédiate des connaissances incertaines, qui est pourtant nécessaire pour raisonner avec des connaissances imprécises. Considérons la règle précise et certaine suivante : "si la patiente a au moins 40 ans, alors exigez une mammographie". Une information imprécise telle que "la patiente a environ 40 ans" conduit à la conclusion incertaine : "nous ne sommes pas certains que la mammographie soit nécessaire." Cet exemple simple prouve que l'imprécision et l'incertitude sont étroitement liées. La théorie des possibilités a été introduite en 1978 par Zadeh (ZADEH 1978) pour représenter l'incertitude non probabiliste liée à des informations imprécises afin de permettre le raisonnement sur des connaissances imparfaites. Elle est basée sur deux mesures définies pour tout sous-ensemble d'un univers  $X$  donné, la mesure de possibilité et la mesure de nécessité. Soit  $P(X)$  l'ensemble des sous-ensembles de l'univers  $X$ . Une mesure de possibilité est une correspondance  $\Pi : P(X) \rightarrow [0, 1]$ , telle que :

$$\Pi(\emptyset) = 0, \Pi(X) = 1, \forall A_1 \in P(X), A_2 \in P(X) \dots \Pi\left(\bigcup_{i=1,2,\dots} A_i\right) = \max_{i=1,2,\dots} \Pi(A_i) \quad (2.1)$$

Dans le cas d'un univers fini  $X$ , on peut réduire l'équation 2.1 à l'équation 2.2, qui est un cas particulier de la formule 2.1 pour tout  $X$

$$\forall A \in P(X), B \in P(X) \Pi(A \cup B) = \min(\Pi(A), \Pi(B)) \quad (2.2)$$

Nous pouvons interpréter cette mesure comme suit :  $\Pi(A)$  représente la mesure dans laquelle il est possible que le sous-ensemble (ou l'événement)  $A$  de  $X$  se produise. Si  $\Pi(A) = 0$ ,  $A$  est impossible ; si  $\Pi(A) = 1$ ,  $A$  est absolument possible.

Remarquons que deux sous-ensembles peuvent être individuellement possibles  $\Pi(A) \neq 0$ ,  $\Pi(B) \neq 0$  mais conjointement impossibles  $\Pi(A) \cap \Pi(B) = 0$ . Considérons l'exemple de l'identification d'une maladie dans un ensemble  $X = d_1, d_2, d_3, d_4$ . Nous supposons qu'il est absolument possible d'être en présence de la maladie  $d_1$  ou de la maladie  $d_2$ , que la maladie  $d_3$  est relativement possible, et que la maladie  $d_4$  est impossible, et nous représentons cette information comme suit :

$$\Pi(d_1, d_2) = 1, \Pi(d_3) = 0.8, \Pi(d_4) = 0$$

On en déduit qu'il est absolument possible que la maladie soit dans l'ensemble  $d_1, d_2, d_4$ , puisque :

$$\Pi(d_1, d_2, d_4) = \max(1, 0) = 1$$

Il est relativement possible que la maladie soit dans l'ensemble  $d_3, d_4$  puisque :  $\Pi(d_3, d_4) = \max(0.8, 0) = 0.8$ . Mais l'intersection  $d_4$  des deux sous-ensembles  $d_1, d_2, d_4$  et  $d_3, d_4$  de  $X$  correspond à une mesure de possibilité égale à 0. On déduit aussi des conditions de l'équation 2.1 que  $\Pi$  est monotone par rapport à l'inclusion des sous-ensembles de  $X$  :

$$\text{Si } A \supseteq B, \text{ alors } \Pi(A) \geq \Pi(B) \quad (2.3)$$

Si l'on considère tout sous-ensemble  $A$  de  $X$  et son complément  $A^c$ , au moins l'un d'entre eux est absolument possible. Cela signifie que soit un événement, soit son complément est absolument possible :

$$\forall A \in P(X) \max(\prod(A^c), \prod(A)) = 1; \prod(A^c) + \prod(A) \geq 1 \quad (2.4)$$

Il est facile de voir que les mesures des possibilités sont moins restrictives que les mesures de probabilités, car le degré des possibilités d'un événement n'est pas nécessairement déterminé par le degré des possibilités de son complément.

### 2.6.4.3 La théorie de Dempster Shafer(D-S)

La théorie des fonctions de croyance est dérivée des travaux de Dempster sur les limites inférieures et supérieures d'une famille de distributions de probabilité (BREIMAN [1992]). Elle a été développée par Shafer (SHAFER [1992]) qui a montré l'intérêt des fonctions de croyance comme formalisme de représentation de l'incertitude. Le principe de la théorie de la croyance est basé sur la manipulation de fonctions de masse sur des sous-ensembles et non sur des singletons comme en théorie des probabilités. Ces fonctions ont généralement des valeurs dans l'intervalle  $[0,1]$ , et sont appelées fonctions de masse ou masses élémentaires ou encore masses de croyance. Considérons l'ensemble  $\Omega$  appelé cadre de discernement avec  $\Omega = x^1, x^2, \dots, x^n$ . Il correspond à toutes les décisions ou réponses possibles à une question donnée comme l'ensemble de toutes les variables possibles dans un problème de classification. Un élément de preuve est représenté par une fonction de masse  $m$  définie à partir de l'ensemble de puissances de  $\Omega$  vers  $[0,1]$ . Cet ensemble de puissances est communément dénoté par  $P(\Omega)$  ou  $2^\Omega$ , correspondant à l'ensemble de tous les sous-ensembles possibles de  $\Omega$ , y compris l'ensemble vide. Ainsi, il est nécessaire d'ajouter toutes les intersections possibles entre deux éléments de  $2^\Omega$  puisqu'un élément de  $\Omega$  doit respecter son exclusivité. Dans la théorie de Dempster (SHAFER [1992]), une affectation de croyance de base (BBA), correspondant à une source d'information, est une fonction de masse  $m$  avec :

$$\sum_{A \in 2^\Omega} m(A) = 1 \text{ et } m(\emptyset) = 0 \quad (2.5)$$

La fonction de masse  $m(A)$  avec  $A \in 2^\Omega$  est interprétée comme une mesure de croyance allouée exactement à l'hypothèse  $X \in A$ . Elle est appelée BBA ou BPA (basic probability assignment) ou BOE (body of evidence). Si  $m(A) > 0$  alors  $A$  est appelé un élément focal, et l'ensemble de tous les éléments focaux est nommé un corps de preuves (BOE). Pour deux sources indépendantes disponibles  $m_p$  et  $m_q$ , nous pouvons utiliser la règle de combinaison de Dempster par les preuves exprimée par les équations suivantes [2.7]:

$$m_{q,p} = m_q \oplus m_p \quad (2.6)$$

$$m_{q,p}(A) = (1 - k)^{-1} \sum_{B \cap C = A} m_q(B) m_p(C) \text{ si } A \neq \emptyset \quad (2.7)$$

Où  $A, B$  et  $C$  sont des éléments dans  $2^\Omega$  et  $k$  correspond au degré de conflit entre les ensembles de masse  $m_p$  et  $m_q$  avec :

$$k = \sum_{B \cap C = \emptyset} m_q(B) m_p(C) \quad (2.8)$$

	$m_2(C) = 0.6$	$m_2(\Omega) = 0.4$
$m_1(B) = 0.8$	$m_3(Tom) = 0.6 * 0.8 = 0.48$	$m_3(B) = 0.4 * 0.8 = 0.32$
$m_1(\Omega) = 0.2$	$m_3(C) = 0.2 * 0.6 = 0.12$	$m_3(\Omega) = 0.2 * 0.4 = 0.08$

TABLEAU 2.1 – Les masses de fonctions de sources 1 et 2

Le facteur de normalisation  $(1 - k)$  permet d'ignorer les conflits. Ainsi, il n'est pas approprié dans le cas d'un conflit élevé entre différentes sources. Dans ce contexte, lorsque les informations issues de données réelles liées à l'état de santé d'un patient, ces informations ne devraient pas être conflictuelles.

Cependant, il peut être approprié de proposer dans des travaux futurs une amélioration de cette théorie au sein de notre approche proposée pour prendre en compte les conflits potentiels entre les différentes sources d'information. Dans ce contexte, nous pensons notamment à l'entropie proposée dans les travaux de Wang (WANG et al. 2020) pour gérer correctement les conflits potentiels entre les sources. Dans la théorie D-S, la fonction de croyance de  $A$  notée  $Bel(A)$  est définie comme suit :

$$Bel(A) = \sum_{\emptyset \neq B \subseteq A} m(B) \quad (2.9)$$

La fonction de plausibilité de  $A$ , notée  $Pl(A)$  est définie comme suit :

$$Pl(A) = \sum_{A \cap B} m(B) \quad (2.10)$$

Où  $\forall A \in 2^\Omega$ ,  $Bel(A)$  représente le degré de croyance total en  $A$ , justifié par l'élément de preuve considéré. Il correspond à la borne inférieure du degré de croyance susceptible d'être attribué à  $A$ .  $Pl(A)$  correspond à la borne supérieure du degré de croyance susceptible d'être attribué à  $A$ , compte tenu des nouvelles informations. Ainsi, la probabilité de  $A$ , notée  $P(A)$  est dans  $[Bel(A), Pl(A)]$ . Dans la partie suivante, nous présentons un exemple qui illustre l'utilisation de la théorie D-S.

**2.6.4.3.1 L'exemple de la théorie D-S** Dans cette partie, nous prenons l'exemple l'assassinat de M. White (SMETS 1990). Il y a trois individus qui sont suspects pour le meurtre de M. White, à savoir, Henry, Tom et Sarah. Dans le cadre de la théorie de D-S, ces 3 individus constituent le cadre de discernement,  $\Omega = \text{Henry, Tom, Sarah}$ . Il y a deux témoins qui ont des informations concernant le meurtre de M. White; le témoin 1, qui est sûr à 80% que le meurtrier était un homme, il s'ensuit, le (BOE), défini  $m_1(B)$ , comprend  $m_1(\text{Henry, Tom}) = 0,8$ . Comme nous ne savons rien de la valeur de la masse restante, elle est considérée comme une ignorance, d'où  $m_1(\Omega) = 0,2$ . Le témoin 2, est sûr à 60% qu'Henry partait en avion au moment du meurtre  $m_2(\text{Tom, Sarah}) = m_2(C) = 0,6$  et  $m_2(\Omega) = 0,4$ . L'agrégation de ces deux sources d'information (preuves des deux témoins), à l'aide de l'équation 2.7, est basée sur l'intersection et la multiplication des éléments focaux et des valeurs de masse des BOE,  $m_1(B)$  et  $m_2(B)$  (table 2.1). Dans la table 2.1, les nouveaux éléments focaux trouvés sont tous non vides. En utilisant l'équation 2.8, il s'ensuit que le niveau de conflit est :

$$k = \sum_{B \cap C = \emptyset} m_q(B)m_p(C) = 0 \quad (2.11)$$

	$m_4(D) = 0.6$	$m_4(\Omega) = 0.4$
$m_1(B) = 0.8$	$m_5(\emptyset) = 0.48$	$m_1(B) = (0.4 * 0.8)/0.52 = 0.615$
$m_1(\Omega) = 0.2$	$m_5(Sarah) = (0.6 * 0.2)/0.52 = 0.231$	$m_5(\Omega) = (0.2 * 0.4)/0.52 = 0.154$

TABLEAU 2.2 – Les masses de fonctions de source 1 et 4

	Combinaison 1 : $m_3$		Num dossier	
Tom	$Bel(Tom) = 0.48$	$Pl(Tom) = 0.48 + 0.32 + 0.08 + 0.12 = 1$	$Bel(Tom) = 0$	$Pl(Tom) = 0.615 + 0.154 = 0.769$
Sarah	$Bel(Sarah) = 0$	$Pl(Sarah) = 0.12 + 0.08 = 0.2$	$Bel(Sarah) = 0.23$	$Pl(Sarah) = 0.154 + 0.231 = 0.385$
Henri	$Bel(Henri) = 0$	$Pl(Henri) = 0.32 + 0.08 = 0.4$	$Bel(Henri) = 0$	$Pl(Henri) = 0.615 + 0.154 = 0.769$

TABLEAU 2.3 – La combinaison des deux possibilités de sources

Pour permettre une comparaison de ce processus de combinaison, la preuve du témoin 2 est légèrement modifiée par : Le témoin 2, est confiant à 60% qu'Henry et Tom partaient en avion à réaction lorsque le meurtre a eu lieu, donc une BOE définie  $m_4(D)$  comprend,  $m_4(Sarah) = 0,6$  et  $m_{\Omega}(D) = 0,4$ . La différence entre les deux déclarations du "témoin 2" est que Tom est également considéré comme partant dans l'avion à réaction avec Henry. Les nouveaux calculs intermédiaires lors de la combinaison des preuves  $m_1$  et  $m_4$  des deux témoins sont montrés dans la table 2.2 où il y a une occasion où l'intersection de deux éléments focaux de  $m_1$  et  $m_4$  résulte en un ensemble vide ( $\emptyset$ ). Il s'ensuit que le niveau de conflit est :

$$k = \sum_{B \cap D = \emptyset} m_1(B)m_4(D) = 0.8 * 0.6 = 0.48$$

En donnant la valeur,  $1 - 0,48 = 0,52$ , donc le BOE résultant est présenté dans la table 2.2. Ainsi, la table 2.3 présente les résultats de la croyance 2.7 et de la plausibilité 2.10 de chaque suspect. Les résultats des deux combinaisons : Dans cet exemple, la première combinaison identifie le suspect Tom comme le meurtrier de M. White (ayant le plus de preuves). Cependant, cette théorie ne peut pas donner de décisions précises pour la deuxième combinaison car le degré de conflit est assez élevé entre les deux témoins. La théorie de Dempster est une technique qui calcule l'incertitude liée à une source ou à une combinaison de sources d'information. Une incertitude très élevée prouve une ignorance totale de l'information donnée. Nous détaillons cette partie et la méthode proposée dans la suite de ce travail.

## 2.7 Synthèse : Vers un modèle intelligent

Nous avons présenté les ontologies et les principaux problèmes concernant la gestion de l'incertitude et de l'imprécision dans les systèmes d'informations, notamment en lien avec les applications médicales. Nous avons introduit des méthodologies qui permettent de faire face à ces imperfections afin d'améliorer la qualité des données cliniques et précisément, les données cliniques des patients du SU du CHU de Lille qu'on va l'exploiter dans le cadre de cette thèse (cf. section 4.3). En se basant sur cette étude, nous trouvons que la théorie de Dempster Shafer, qui présente la gestion des degrés de croyance attribués à des occurrences d'événements, est

une méthode adéquate à la gestion et la représentation de l'incertitude des données cliniques. L'intérêt principal réside dans la règle de combinaison introduite par Dempster qui permet d'agréger des informations obtenues de plusieurs sources en lien avec les patients, les médecins urgentistes, les infirmiers de triage, etc. Une autre méthodologie utilisée dans les applications médicales est la construction de réseaux causaux, généralement considérés comme des graphes, dont les sommets sont associés à des situations comme les symptômes ou les maladies. Les arcs transmettent les probabilités d'occurrence des événements d'un sommet à l'autre mettant en évidence des dépendances entre éléments et permettant de mettre à jour les probabilités des hypothèses (nouvelles informations).

Cependant, cette méthode est utilisée en général dans le cadre des problèmes basiques de diagnostic et de traitement médical. Notre objectif dans cette thèse est de proposer un système rationnel basé sur les connaissances et les données cliniques du SU afin de fournir un modèle d'aide à la décision pointu au profit du personnel soignant. Ce système d'aide vise à optimiser la gestion de la tension et à cibler l'orientation de chaque patient vers le parcours de soins le plus adapté à sa pathologie en prenant en compte toutes les informations requises et leur complexité. Ainsi, les méthodes de traitement des imprécisions et des incertitudes, et plus précisément, les ensembles flous et la théorie de Dempster sont intéressants pour atteindre notre objectif car :

- Nous devons faire face à des connaissances imparfaites issues des sources d'informations médicales des données du SU comme celles des patients inconscients.
- Nous devons faire face à des connaissances incertaines et imprécises à cause d'une base de données avec des connaissances ambiguës et non structurées.
- Nous devons gérer des connaissances numériques (Saturation d'oxygène O<sub>2</sub> "97%") et des connaissances symboliques (descriptions des variables en langage naturel, «douleurs abdominales»), dans un cadre commun.
- Nous devons tenir compte des classes imprécises et des catégories mal définies ("position douloureuse").
- Les acteurs humains sont impliqués dans notre étude (observateurs, utilisateurs du système, agents) et apportent des descriptions approximatives ou vagues des variables, de la subjectivité (degré de risque de tension, effets négatifs sur les patients), des règles qualitatives ("si le risque de tension est trop élevé, appliquez des mesures préventives"), et des connaissances graduelles ("plus le temps d'attente est important, plus le risque de tension est élevé").
- La modélisation précise du système des urgences est difficile car il y'a plusieurs acteurs à prendre en compte comme les médecins, les infirmiers et les patient et une multitude de variables à considérer comme la saison, les pandémies et les événements nationaux.
- Nous recherchons une gestion souple des connaissances, adaptable à l'environnement ou à la situation rencontrée.
- Le système est évolutif, ce qui rend difficile la description précise de chacun de ses états.

L'IA est composée de 2 catégories complémentaires : les approches symboliques et les approches sub-symboliques qui sont basées sur la modélisation du raisonnement logique, sur la représentation des connaissances par des langages formels (comme les systèmes experts et les moteurs d'inférence) et les raisonnements mathématiques. Dans ce contexte, l'utilisation d'ontologies est nécessaire pour définir un modèle complet d'aide à la décision en représentant toutes les connaissances liées au domaine d'application et en traitant toutes les données médicales textuelles non structurées. Dans le domaine de la santé, les ontologies sont généralement utilisées pour gérer

les connaissances et les informations médicales. Elles sont également déployées pour créer des systèmes intelligents pour la recherche d'informations médicales, des moteurs de recherche médicale sur Internet et des systèmes d'aide à la décision clinique (ALKAHTANI et al. [2019](#)). En revanche, l'ontologie ne peut pas toute seule fournir des résultats performants. La combinaison entre les approches symboliques et sub-symboliques, peut être très efficace ou l'intégration des techniques d'apprentissages permet la création des systèmes intelligents basés sur des ontologies. Dans ce contexte, nous présentons les différents modèles et techniques d'apprentissages dans le chapitre suivant.

## 2.8 Conclusion

Ce chapitre permet de montrer l'importance de la représentation de connaissances en mettant l'accent sur les problématiques des données médicales incertaines et imprécises. Nous montrons que l'utilisation des méthodes de gestion des connaissances imparfaites permet d'améliorer la qualité du système de connaissance en soulignant l'importance de combiner ces systèmes avec des techniques d'apprentissages pour créer un système intelligent performant. Dans le chapitre suivant, nous détaillons le domaine de l'apprentissage artificiel, qui fait partie de l'IA sub-symbolique, avec les techniques les plus utilisées et les mesures de performances adoptées pour évaluer ces techniques.



# L'apprentissage Artificiel en santé : Outils et approches

## 3.1 Introduction

Nous avons vu dans le chapitre précédent que, dans le domaine de l'ingénierie des connaissances, les ontologies sont employées pour modéliser et analyser les données et ainsi les transformer en des connaissances. Les ontologies sont également déployées pour le prétraitement et la classification des données pour l'aide à la décision. En effet, elles sont liées à plusieurs techniques de classification à savoir l'apprentissage automatique ou les réseaux de neurones. Le fait de combiner les ontologies aux techniques issues des domaines de l'apprentissage automatique caractérise un domaine récent permettant de concevoir de nouvelles stratégies de raisonnement. Dans ce chapitre, nous explorons en premier lieu les notions liées aux ontologies et en deuxième lieu les techniques de l'apprentissage automatique, puis nous finissons par les méthodes existantes qui gèrent l'imperfection des connaissances. Nous abordons dans ce chapitre les méthodologies de prétraitement de données puis nous définissons le domaine de l'apprentissage et ses techniques et nous finissons ce chapitre par les mesures de performances et les applications de ML à la santé.

## 3.2 Le prétraitement des données

Selon (VANNAN 2001), les données ne doivent pas être parfaites pour les traiter et les intégrer dans des modèles d'apprentissages mais dans le but de les rendre exploitable, il faut assurer qu'elles sont :

- **Précises** : ne doivent pas contenir des erreurs ;
- **Complètes** : avoir toutes les valeurs présentes ;
- **Cohérentes** : doivent satisfaire un ensemble de contraintes et représenter le phénomène qu'elles mesurent ;
- **Opportunes** : doivent être disponibles quand elles sont réclamées ;



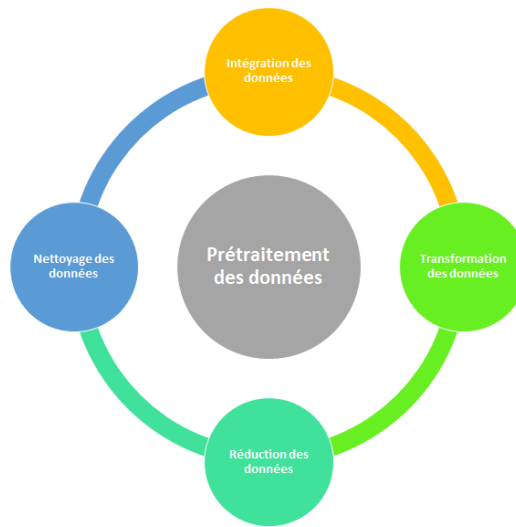


FIGURE 3.1 – les étapes de prétraitement des données

- **Flexibles** : doivent être exploitable et décrites d'une façon permettant les analyser avec des différentes méthodes.

Paul Jermyn a défini que le traitement des données représente environ 60 à 80% du temps impliqué dans le processus d'extraction de l'information (JERMYN, DIXON et READ [1999]). Cette difficulté dépend de la nature des problèmes existants avec les données à savoir tels que les données erronées (par exemple une valeur quantitative à la place d'une valeur qualitative), Les données manquantes (absence de données / valeurs), les données aberrantes qui s'écartant de la norme, du modèle normal et les données doublons (données faussement dupliquées) (BENNANE [2010]). Donc le traitement des données doit être réalisé pour résoudre les problèmes qui peuvent empêcher l'application d'une technique de classification, la compréhension de la nature des données pour pouvoir les analyser et l'extraction efficace de l'information puisque la qualité des résultats finaux est largement conditionnée par le soin porté à cette première étape.

Le prétraitement des données comprend les étapes que nous devons suivre pour transformer ou coder les données afin qu'elles puissent être facilement analysées par la machine. Pour qu'un modèle soit exact et précis dans ses prédictions, il faut que l'algorithme soit capable d'interpréter facilement les caractéristiques des données ((GARCÍA et al. [2016])). La majorité des ensembles de données existants sont très susceptibles d'être manquants, incohérents et bruyants en raison de leur origine hétérogène. L'application d'algorithmes d'exploration de données sur ces données bruitées ne donnerait pas de résultats de qualité car ils ne parviendraient pas à identifier efficacement les modèles. Le traitement des données est donc important pour améliorer la qualité globale des données. En effet, les valeurs dupliquées ou manquantes peuvent donner une vision incorrecte des statistiques globales des données (GAO [2012]). Les points de données aberrants et incohérents ont souvent tendance à perturber l'apprentissage global du modèle, ce qui conduit à des prédictions erronées. Les bonnes décisions doivent être basées sur des données de qualité. Les variables indépendantes individuelles qui fonctionnent comme une entrée dans les modèles d'apprentissage automatique (cf. section [3.3]) sont appelées caractéristiques. On peut les considérer comme des représentations ou des attributs qui décrivent les données et aident les modèles à prédire les classes/étiquettes. Maintenant, nous examinons plus en détail les quatre principales étapes du prétraitement des données (figure [3.1]).

### 3.2.1 Nettoyage des données

Le nettoyage des données est particulièrement effectué dans le cadre du prétraitement des données pour nettoyer les données en remplissant les valeurs manquantes, en lissant les données bruyantes, en résolvant les incohérences et en supprimant les valeurs aberrantes (ILYAS et CHU 2019).

1. **Valeurs manquantes** : Pour résoudre ce problème, il faut :
  - Ignorer ces tuples : cette méthode doit être envisagée lorsque l'ensemble de données est énorme et que de nombreuses valeurs manquantes sont présentes dans un tuple.
  - Remplir les valeurs manquantes : il existe de nombreuses méthodes pour y parvenir, telles que le remplissage manuel des valeurs, la prédiction des valeurs manquantes à l'aide d'une méthode de régression ou de méthodes numériques comme la moyenne des attributs.
2. **Données bruitées** : Il s'agit de supprimer une erreur ou une variance aléatoire dans une variable mesurée. Elle peut être réalisée à l'aide des techniques suivantes (XIAO et al. 2010) :
  - Binning : il s'agit d'une technique qui fonctionne sur des valeurs de données triées afin de lisser tout bruit présent dans celles-ci. Les données sont divisées en bacs de taille égale, et chaque bac/segment est traité indépendamment. Toutes les données d'un segment peuvent être remplacées par leurs valeurs moyennes, médianes ou limites.
  - Régression : cette technique d'exploration de données est généralement utilisée pour la prédiction. Elle permet de lisser le bruit en ajustant tous les points de données dans une fonction de régression. L'équation de régression linéaire est utilisée s'il n'y a qu'un seul attribut indépendant ; sinon, on utilise des équations polynomiales.
  - Clustering : c'est la création de groupes/clusters à partir de données ayant des valeurs similaires. Les valeurs qui ne se trouvent pas dans le cluster peuvent être traitées comme des données bruitées et peuvent être supprimées.
3. **Suppression des valeurs aberrantes** : Les techniques de clustering regroupent les points de données similaires. Les tuples qui se trouvent en dehors du cluster sont des données aberrantes/inconsistantes donc il faut les supprimer.

### 3.2.2 Intégration des données

L'intégration des données est l'une des étapes de prétraitement des données utilisées pour fusionner les données présentes dans plusieurs sources en un grand échelle, tel qu'un entrepôt de données. L'intégration des données est nécessaire surtout lorsque nous cherchons à résoudre un scénario du monde réel comme la détection de la présence de nodules à partir d'images de tomodensitométrie. La seule option est d'intégrer les images de plusieurs nœuds médicaux pour former une base de données plus importante. Nous pourrions rencontrer certains problèmes en adoptant l'intégration de données comme l'une des étapes du prétraitement des données (STONEBRAKER, ILYAS et al. 2018) :

- Intégration des schémas et correspondance des objets : les données peuvent être présentes dans différents formats et attributs qui peuvent causer des difficultés dans l'intégration des données.

- Suppression des attributs redondants de toutes les sources de données.
- Détection et résolution des conflits de valeur des données.

### 3.2.3 Transformation des données

Une fois le nettoyage des données effectué, nous devons consolider les données de qualité dans d'autres formes en modifiant la valeur, la structure ou le format des données à l'aide des stratégies de transformation des données suivantes (DEY et PANDIT [2020](#)) :

- **Généralisation** : Les données de bas niveau ou granulaires que nous avons converties en informations de haut niveau en utilisant des hiérarchies de concepts. Nous pouvons transformer les données primitives de l'adresse, comme la ville, en informations de plus haut niveau, comme le pays.
- **Normalisation** : Il s'agit de la plus importante technique de transformation des données largement utilisée. Les attributs numériques sont augmentés ou diminués pour s'adapter à une plage spécifiée. Dans cette approche, nous limitons l'attribut de nos données à un conteneur particulier pour développer une corrélation entre différents points de données. La normalisation peut être effectuée de plusieurs façons, qui sont présentées ici :
  - Normalisation Min-Max
  - Normalisation du Z-Score
  - Normalisation par échelle décimale
- **Sélection d'attributs** : De nouvelles propriétés de données sont créées à partir d'attributs existants pour faciliter le processus d'exploration de données. Par exemple, la date de naissance, attribut de données, peut être transformée en une autre propriété comme "est\_un\_citoyen\_âgé" pour chaque tuple, qui influencera directement la prédiction des maladies ou les chances de survie, etc.
- **Agrégation** : Il s'agit d'une méthode de stockage et de présentation des données dans un format synthétique. Par exemple, les ventes, les données peuvent être agrégées et transformées pour être présentées sous forme de mois et d'année.

### 3.2.4 Réduction des données

La taille de l'ensemble de données dans un entrepôt de données peut être trop importante pour être traitée par des algorithmes d'analyse et d'exploration de données. Une solution possible est d'obtenir une représentation réduite de l'ensemble de données qui est beaucoup plus petite en volume mais produit la même qualité de résultats analytiques. Les différentes stratégies de réduction des données utilisées sont (NAMEY et al. [2008](#)) :

- **Agrégation de cubes de données** : Il s'agit d'une méthode de réduction des données, dans laquelle les données recueillies sont exprimées sous une forme résumée.
- **Réduction de la dimensionnalité** : Les techniques de réduction de la dimensionnalité sont utilisées pour effectuer l'extraction de caractéristiques. La dimensionnalité d'un ensemble de données fait référence aux attributs ou aux caractéristiques individuelles des données. Cette technique vise à réduire le nombre de caractéristiques redondantes que nous prenons en compte dans les algorithmes d'apprentissage automatique. La réduction de la dimensionnalité peut être effectuée à l'aide de techniques telles que l'analyse en composantes principales (ACP), etc.

- **Compression des données** : En utilisant des technologies de codage, la taille des données peut être réduite de manière significative. Mais la compression des données peut se faire avec ou sans perte. Si les données d'origine peuvent être obtenues après la reconstruction à partir des données comprimées, on parle de réduction sans perte ; dans le cas contraire, on parle de réduction avec perte.
- **Discrétisation** : La discrétisation des données est utilisée pour diviser les attributs de la nature continue en données avec des intervalles. En effet, les caractéristiques continues ont tendance à avoir moins de chances d'être corrélées avec la variable cible. Ainsi, il peut être plus difficile d'interpréter les résultats. Après avoir discrétisé une variable, les groupes correspondant à la cible peuvent être interprétés. Par exemple, l'âge de l'attribut peut être discrétisé en tranches telles que moins de 18 ans, entre 18-44 ans, entre 44-60 ans, plus de 60 ans.
- **Réduction de la numération** : Les données peuvent être représentées sous forme de modèle ou d'équation, comme un modèle de régression. Cela permet d'éviter de stocker des ensembles de données énormes au lieu d'un modèle.
- **Sélection de sous-ensembles d'attributs** : Il est très important d'être spécifique dans la sélection des attributs. Sinon, cela pourrait conduire à des données de grande dimension, qui sont difficiles à former en raison de problèmes de sous-adaptation et de sur-adaptation. Seuls les attributs qui ajoutent de la valeur à la formation du modèle doivent être pris en compte, les autres pouvant être rejetés.

Maintenant que les techniques de prétraitement ont été présentées, nous détaillons dans la section suivante l'apprentissage automatique et ses techniques les plus utilisées.

## 3.3 L'apprentissage automatique

L'apprentissage automatique (ML) est un vaste domaine pluridisciplinaire qui trouve ses racines dans les statistiques, l'algèbre, le traitement des données, l'analyse des connaissances, etc (MITCHELL et al. 1990). ML est une méthode sub-symbolique d'intelligence artificielle qui collecte des informations à partir de données d'entraînement. L'apprentissage automatique est divisé en catégories suivantes, représentées par la figure 3.2 (MISHRA et SHUKLA 2017). Nous présentons dans cette section les principales notions de l'apprentissage automatique et ses techniques.

### 3.3.1 Les catégories d'apprentissage automatique

Le domaine de l'apprentissage automatique comprend des apprenants supervisés, semi-supervisés et non supervisés mais aussi nous trouvons l'auto-supervisé et l'apprentissage par renforcement (ARULKUMARAN et al. 2017a; KRISHNAN, RAJPURKAR et TOPOL 2022). Précisément, les données d'entraînement sont à la disposition de l'apprenant avant de construire le modèle, et les données de test sont utilisées pour évaluer l'algorithme [18][19][20]. L'apprentissage supervisé consiste à apprendre une fonction cible à partir d'exemples de formation en entrée et en sortie (ZHOU 2021). L'apprentissage non supervisé tente d'apprendre des modèles d'entrée pour lesquels il n'existe pas de valeurs de sortie. Nous définissons dans ce qui suit chaque type d'apprentissage.




FIGURE 3.2 – La classification des techniques de ML

### 3.3.1.1 Apprentissage supervisé

Concernant l'apprentissage supervisé, des données contenant des informations cibles antérieures sont fournies pour l'apprentissage, et l'on s'efforce de réduire la **fonction d'erreur** (fonction de risque)  $R(t)$ . Dans un problème de classification supervisée,  $R(t)$  présente l'espérance de vie de la fonction de perte et son objectif est de trouver un classifieur  $f$  qui minimise  $R(t)$  [3.1](#). La fonction de perte  $L(y, f(x))$  est égale à 0 si  $y = f(x)$ , sinon à 1.

$$R(t) = \int L(y, f(x)) dP(x, y) = \epsilon_{y \neq f(x)} dP(x, y) = P(y \neq f(x)) \quad (3.1)$$

Les algorithmes d'apprentissage supervisé évaluent les données d'apprentissage pour élaborer une règle. Une fois le modèle d'apprentissage formé, il peut alors classer ou estimer l'attribut cible (ou l'étiquette de classe) des données de test (ou échantillons). Si les attributs ciblés estimés sont des étiquettes, la tâche d'apprentissage supervisé est appelée classification. En revanche, si l'attribut prédit est une valeur numérique continue, l'algorithme est appelé régression ou prédiction. L'apprentissage supervisé fait référence au mécanisme qui infère la relation sous-jacente entre les données d'entrée et une étiquette de classe connue. Un exemple de données étiquetées est celui des antécédents médicaux qui sont étiquetés avec l'occurrence ou l'absence d'une maladie (RAJDHAN et al. [2020](#)). Dans ce cas, la sortie du modèle serait une prédiction de diagnostic. Le processus d'apprentissage se base sur l'ensemble de données d'entraînement étiquetées pour combiner la fonction du modèle qui généralise la relation entre les vecteurs de caractéristiques d'entrée et les sorties (ZHOU [2021](#)). Toutefois, le modèle peut être confronté au problème de l'adaptation excessive, qui représente généralement une généralisation insatisfaisante et une classification erronée. Le surajustement (surapprentissage) entraîne une précision de classification élevée. Dans le contexte du processus de classification, la fonction qui associe une entrée  $x$  à une sortie  $y$  est appelée un classificateur. En statistique,  $y$  est connue comme une variable de classe (sorties discrètes telles que "oui" ou "non"), et  $x$  est un vecteur réel. La régression est un processus d'apprentissage dans laquelle une fonction cible  $f$  fait correspondre chaque attribut indépendant  $x$  à une sortie continue  $y$ . Nous pouvons citer comme exemple

de régression : (a) l'analyse de la demande dans l'entreprise, y compris la prévision de l'indice boursier et (b) la prédiction de la probabilité de réadmission d'un patient ainsi que la prédiction des coûts des soins dans le domaine de la santé (BOLOURANI et al. [2021]; KUMAR, SARANGI et VERMA [2021]).

### 3.3.1.2 Apprentissage non supervisé

L'approche de l'apprentissage non supervisé découvre des structures cachées dans l'ensemble des données non étiquetées. Cet ensemble de données ne contient donc pas d'étiquette de classe, contrairement à l'apprentissage supervisé, qui fournit des données d'entrée étiquetées (HASTIE, TIBSHIRANI et FRIEDMAN [2009]). Les instances du problème sont identiques à la classification supervisée, mais la classe des exemples n'est pas donnée : les exemples font partie de  $X$ . L'objectif est toujours de trouver un classifieur qui minimise le risque (erreur). Mais on ne peut plus évaluer le risque sur l'échantillon d'apprentissage. Il faut donc se servir d'autres informations pour segmenter les données en classes (information sur le nombre de classes, topologie de l'espace des attributs, etc.). Le clustering est l'approche la plus courante de l'apprentissage non supervisé (MADHULATHA [2012]). L'algorithme le plus connu de l'apprentissage non supervisé est le K-means (ZHANG et al. [2017]). Il s'agit d'une approche de regroupement basée sur la représentation (GUO et al. [2003]). Les algorithmes peuvent utiliser différentes mesures, telles que les mesures statistiques et l'erreur de quantification. Dans l'apprentissage non supervisé, aucune étiquette n'est attribuée aux données. Il n'y a donc pas de moyen direct d'évaluer la précision des résultats produits par l'algorithme.

### 3.3.1.3 Apprentissage semi-supervisé

L'apprentissage semi-supervisé utilise une combinaison de grands ensembles de données non étiquetées et d'un petit nombre de données étiquetées pour générer un classificateur (VAN ENGELEN et HOOS [2020]). Sa méthodologie se situe entre les lignes directrices de l'apprentissage supervisé et de l'apprentissage non supervisé pour produire une bonne amélioration des performances de l'apprentissage. Pour l'apprentissage semi-supervisé, une stratégie possible consiste à utiliser un petit ensemble d'apprentissage étiqueté pour construire un modèle, qui est ensuite affiné en utilisant des informations non étiquetées (ZHU et GOLDBERG [2009]). Par exemple, nous pouvons utiliser le modèle initial pour prédire des données non étiquetées, puis utiliser les prédictions les plus fiables comme nouvelles données d'apprentissage. Ensuite, le modèle est réentraîné sur cet ensemble d'apprentissage élargi. Récemment, l'apprentissage semi-supervisé a été utilisé dans diverses applications, notamment celles en lien avec les données Web, les données boursières, les images et les données biologiques (VAN ENGELEN et HOOS [2020]). Ces domaines impliquent une petite quantité d'instruction directe et une grande quantité d'expérience non étiquetée.

### 3.3.1.4 Apprentissage par renforcement

L'apprentissage par renforcement (RL pour Reinforcement Learning) fait référence à une classe de problèmes d'apprentissage automatique, dont le but est d'apprendre, à partir d'expériences successives, ce qu'il convient de faire de façon à trouver la meilleure solution en construisant de modèles successifs (SUTTON et BARTO [2018]). Cette méthode s'est basée sur l'interaction avec l'environnement, ce qui permet de renforcer les comportements à produire les

réponses adéquates (HAN et al. [2019]). Dans un tel problème, on dit qu'un « **agent**<sup>1</sup> » (l'algorithme et des variables qu'il utilise) interagit avec « l'environnement » pour trouver la solution optimale. L'apprentissage par renforcement est différent fondamentalement de problèmes supervisés et non supervisés par ce côté interactif et itératif où l'agent essaie plusieurs solutions, observe la réaction de l'environnement et adapte son comportement (les variables) pour trouver la meilleure stratégie (SUTTON et BARTO [2018]).

### 3.3.1.5 Apprentissage auto-supervisé (SSL)

Forme intermédiaire entre l'apprentissage supervisé et non supervisé, l'apprentissage auto-supervisé ou self-supervised learning (SSL) est une méthode d'apprentissage automatique reposant sur un réseau de neurones conçu pour ingérer des données non étiquetées (JAISWAL et al. [2020]). Le SSL est proposé pour utiliser des données non étiquetées avec les avantages de l'apprentissage supervisé. La production d'un ensemble de données avec de bonnes étiquettes est coûteuse, alors que des données non étiquetées sont générées en permanence. L'idée principale de l'apprentissage auto-supervisé est de générer des étiquettes à partir de données non étiquetées, selon la structure ou les caractéristiques des données elles-mêmes, puis de s'entraîner sur ces données non supervisées de manière supervisée. L'apprentissage auto-supervisé est très utilisé dans l'apprentissage des représentations pour qu'un modèle apprenne les caractéristiques latentes des données. Cette technique est souvent utilisée en computer vision, dans du traitement vidéo et la robotique (AFOURAS et al. [2020]).

L'apprentissage auto-supervisé a donné des résultats pertinents ces dernières années et a trouvé un succès dans le traitement audio. Il est utilisé aussi par Facebook et d'autres pour la reconnaissance vocale (RAVANELLI et al. [2020]). L'apprentissage auto-supervisé imite plus étroitement la façon dont les humains apprennent à classer les objets (BAEVSKI et al. [2022]).

## 3.3.2 Les techniques d'apprentissage automatique

Il existe plusieurs types de techniques d'apprentissage. Chaque technique a ses propres caractéristiques et sa propre façon de résoudre certains problèmes d'apprentissage. Concernant les algorithmes de classification, ces derniers ont été utilisés avec succès dans de nombreux domaines. Les algorithmes les plus connus sont C4.5 (QUINLAN [2014]), SVM (Support vector machine) (HUANG et al. [2018]), RF (Random Forest) (RIGATTI [2017]), AdaBoost (Adaptive Boosting) (CHENGSHENG, HUACHENG et BING [2017]), KNN (k-nearest neighbors) (GUO et al. [2003]), CART (Classification And Regression Trees) (LEWIS [2000]) et NB (Naïve Bayes) (WEBB, KEOGH et MIKKULAINEN [2010]). Dans cette section, nous abordons différents algorithmes d'apprentissage supervisé, notamment DT (Decision Tree), RF, NB, SVM, ANN (Artificiel Neural Networks) et KNN, et aussi les méthodes d'apprentissage par renforcement les plus utilisées. Il y a deux classes d'algorithmes d'apprentissage automatique. Les algorithmes issus des statistiques et les algorithmes imaginés à partir des sciences cognitives, à savoir les réseaux de neurones.

### 3.3.2.1 Les réseaux de neurones (Artificiel Neural Networks ou ANN)

Les réseaux neuronaux sont utilisés dans de nombreuses applications telles que la reconnaissance des formes (IQBAL et AFTAB [2019]), la classification (LIVIERIS [2018]) et la prédiction (YACIM et

1. un agent est une entité logicielle ou physique à qui est attribuée une certaine mission qu'elle est capable d'accomplir de manière autonome et en coopération avec d'autres agents






FIGURE 3.3 – Structure de réseaux de neurones (YACIM et BOSHOFF 2018)

BOSHOFF 2018; GUPTA et al. 2019). Le réseau neuronal artificiel contient des nœuds, des neurones et des connexions pondérées entre ces neurones, comme le montre la figure 3.3. Au cours du processus d'apprentissage du réseau, les poids sont adaptés. Une fonction d'activation définit la valeur de sortie de chaque nœud en fonction de ses valeurs d'entrée.

La figure 3.3 représente un réseau de neurones monocouche, appelé perceptron. Il existe 2 types de perceptrons, les perceptrons à propagation avant ou feed-forward (les neurones ne sont connectés que dans un sens) et les perceptrons récurrents (ceux qui alimentent leurs entrées avec leurs sorties). Le réseau neuronal multicouche contient une couche d'entrée, une couche de sortie et les couches cachées. Pour un réseau neuronal à propagation avant, la couche d'entrée obtient les données de sources externes (valeurs d'attribut), la couche de sortie génère la sortie du réseau, et les couches cachées relient la couche d'entrée et la couche de sortie (MURTAGH 1991). La valeur d'entrée de chaque nœud dans chaque couche est calculée en faisant la somme de tous les nœuds entrants, puis multipliée par le poids de l'interconnexion entre les nœuds (RAMCHOUN et al. 2016). Ensuite, et afin de permettre un meilleur apprentissage pour un réseau de neurones, il faut un mécanisme capable de corriger l'erreur de prédiction. Ce mécanisme est représenté par un algorithme appelé la rétropropagation ou backpropagation (du gradient). La Backpropagation (propagation des erreurs vers l'arrière) est une méthode standard de formation d'un réseau neuronal. L'algorithme de Backpropagation ajuste donc les poids dans le réseau neuronal en fonction du taux d'erreur obtenu lors de l'itération précédente (époque) (RAMCHOUN et al. 2016).

Il a été démontré depuis longtemps que les réseaux neuronaux à action directe avec au moins une couche cachée sont des approximateurs de fonctions universels (BISHOP et al. 1995), capables d'approximer n'importe quelle fonction, même non linéaire, avec suffisamment de données d'apprentissage. Les modèles d'entrée  $x$  sont présentés à la couche la plus basse. Chaque neurone des couches supérieures a accès à tous les neurones de la couche inférieure, multipliant chaque entrée par le poids correspondant, additionnant toutes les entrées pondérées, appliquant une fonction d'activation  $F_{act}$  à la somme et transmettant le résultat à la couche suivante (Figure 3.3). La couche la plus élevée produit la prédiction du réseau pour l'entrée donnée. Pour former un réseau neuronal à action directe, l'erreur entre une sortie réelle  $y$  et la cible souhaitée  $d$  est calculée et rétro-propagée à travers la couche de sortie vers la couche d'entrée. En appliquant de manière répétée la règle de la chaîne, on peut calculer l'importance de la contribution de



chaque poids à l'erreur et la quantité de poids à modifier pour compenser l'erreur. Un taux d'apprentissage  $0 < \alpha \leq 1$  assure une convergence lente mais régulière pendant la descente du gradient.

### 3.3.2.2 Les arbres de décision (Decision Tree ou DT)

Les arbres de classification (décision) émulent le raisonnement humain car ils peuvent être interprétés comme un ensemble de règles ou comme un flux d'informations arborescent (RUGGIERI 2002). Le classificateur à arbre de décision est l'une des techniques de classification les plus courantes. Il utilise des données, qui contiennent des vecteurs de caractéristiques assignés à une classe spécifique. Cette technique est utilisée pour classer les données et pour représenter les résultats dans une structure arborescente (MYLES et al. 2004).

Les arbres de décision (DT) peuvent être visualisés sous une forme de représentation arborescente, facile à comprendre et à interpréter. L'arbre de décision contient des nœuds internes et des nœuds terminaux (feuilles) qui attribuent des étiquettes de classe aux régions. La technique classe les données en allant de la racine à travers une structure de requête jusqu'à atteindre la feuille à classe unique. Il divise l'ensemble de données de manière récursive en fonction de l'attribut, ce qui divise les données jusqu'à ce qu'un critère d'arrêt spécifié soit atteint. Le domaine est divisé en régions (sous-ensembles) (QUINLAN 1996). Pour un ensemble de données entrantes  $d$ , différents points de division sont évalués pour chaque variable dans  $d$ . La décision des attributs numériques est de la forme  $x_1 \leq V$  pour une valeur de  $V$  dans l'intervalle de  $x_1$ . La décision des attributs catégoriques est de la forme  $x_1 \in V$  pour le sous-ensemble de valeurs dans le domaine  $x_1$ . Le meilleur point de séparation est sélectionné pour diviser les données en sous-ensembles,  $d_t$  et  $d_f$ . Les points  $x \in d$  qui satisfont la décision de partage sont dans  $d_t$ , et ceux qui ne satisfont pas la décision de partage sont dans  $d_f$ . Le processus de partitionnement récursif peut être arrêté en utilisant des conditions d'arrêt, notamment la taille de la partition  $d$ . Cette condition permet d'éviter le sur-apprentissage du modèle car celui-ci évite de traiter un petit sous-ensemble des données (QUINLAN 1996).

Les algorithmes DT les plus courants sont ID3, C4.5, C5.0, CART et CHAID (CHI-squared Automatic Interaction Detector) (QUINLAN 1996). L'algorithme Itérative Dichotomiser 3 (ID3) a été le premier algorithme concernant la formation d'arbres de décision (JIN, DE-LIN et FEN-XIANG 2009). Les algorithmes C4.5 et C5.0 ont amélioré l'ID3 en traitant les données manquantes, en effectuant l'élagage, en traitant les données continues et en réalisant la division et les règles (JIN, DE-LIN et FEN-XIANG 2009). RossQuinlan les a développés en 1986 et 1993 (WU et al. 2008). Au fil des années, différents algorithmes issus de la technique de l'arbre de décision ont été développés.

Certains critères sont utilisés pour définir le point de séparation pour un attribut numérique ou catégorique. Un point de division qui fournit la meilleure séparation entre les étiquettes de classe doit être sélectionné. Parmi ces critères, nous trouvons les théories de Shannon étant à la base de l'algorithme ID3 et donc de C4.5. L'entropie de Shannon est la plus connue et la plus appliquée. Elle définit d'abord la quantité d'information apportée par un événement : plus la probabilité d'un événement est faible, plus la quantité d'information qu'il apporte est grande (LIN 1991). En effet, une entropie mesure la quantité d'incertitude dans un système et l'entropie

d'un ensemble de points  $d$  est définie comme suit :

$$H(d) = - \sum_{i=0}^k P(c_i|d) \log^2(c_i|d) \quad (3.2)$$

Où,  $P(c_i|d)$  est la probabilité de la classe  $c_i$  dans  $d$ , et  $k$  le nombre de classes. Lorsque  $d$  est divisé en  $d_t$  et  $d_f$  l'entropie est donnée comme :

$$(d_t, d_f) = \frac{n_t}{n} H(d_t) + \frac{n_f}{n} H(d_f) \quad (3.3)$$

Où,  $n$  est le nombre de points dans  $d$ ,  $n_t$  présente le nombre de points dans  $d_t$ , et  $n_f$  présente le nombre de points dans  $d_f$ .

Le gain d'information est utilisé pour vérifier l'entropie globale. Le gain d'information est donné par :

$$Gain(d, d_t, d_f) = H(d) - H(d_t, d_f) \quad (3.4)$$

En position  $p$  ( $d_t$  et  $d_f$ ) (non maximale), on choisit le test qui maximise le GainRatio (option par défaut de C4.5). On peut modifier les options pour utiliser le Gain : Affecter une classe à une feuille. On attribue la classe majoritaire. S'il n'y a aucun exemple on attribue la classe majoritaire du noeud père.

CART (Classification And Regression Tree) construit un arbre de décision strictement binaire avec exactement deux branches pour chaque noeud de décision (LEWIS 2000). L'algorithme partitionne l'ensemble d'entraînement de façon récursive selon méthode de conception consistant à diviser un problème de grande taille en plusieurs sous-problèmes analogues. CART utilise l'indice de Gini (IG) pour déterminer l'attribut de la branche qui doit être généré. La stratégie est de choisir l'attribut dont indice de Gini est minimum après la séparation. IG est défini comme suit :

$$IG(d) = 1 - \sum_{i=0}^k P(c_i|d)^2 \quad (3.5)$$

Nous trouvons aussi le modèle de Forêt Aléatoire (Random Forest ou RF), tel que présenté par Breiman (BREIMAN 2001). Il s'agit d'une combinaison de plusieurs classificateurs à arbres de décision. Le RF est un algorithme robuste de machine supervisée utilisé pour les problèmes de régression et de classification. Chaque arbre est développé sur la base de deux procédures. La première procédure consiste à construire le modèle d'ensemble bootstrap. À ce stade, un sous-ensemble de l'ensemble des données d'entraînement est sélectionné indépendamment pour tous les arbres de la forêt. Le reste des exemples est appelé ensemble "out-of-bag" (OOB) et est utilisé pour évaluer la qualité de l'ajustement de la RF (RIGATTI 2017; BREIMAN 2001).

En général, le modèle RF est un algorithme d'apprentissage d'ensemble qui peut aider à améliorer les résultats de l'apprentissage automatique en combinant plusieurs modèles. Il existe de nombreuses raisons qui poussent à utiliser la technique de DT. Par exemple, ses modèles sont faciles à lire. En revanche, le principal inconvénient de cette technique est la possibilité de création d'un modèle complexe, basé sur les données qui sont incluses dans l'ensemble d'apprentissage. La table 3.1 ci-dessous présente les avantages ainsi que les inconvénients des arbres de décision.

Points forts des arbres de décision	Points faibles des arbres de décision
<ul style="list-style-type: none"> <li>— Grande lisibilité</li> <li>— Apprentissage et classification rapides.</li> <li>— Le classifieur peut traiter un grand nombre de données.</li> <li>— Le classifieur peut traiter différents types de données (QUINLAN 1996).</li> <li>— Ils tendent à être précis, même si les hypothèses des données source ne sont pas respectées.</li> <li>— Le coût d'utilisation de l'arbre pour prédire des données diminue à chaque point de donnée supplémentaire.</li> </ul>	<ul style="list-style-type: none"> <li>— Les arbres de décision peuvent être instables.</li> <li>— Les arbres de décision peuvent être surajustés.</li> <li>— Les attributs numériques peuvent conduire à une ramification extensive et générer des arbres de décision complexes (MYLES et al. 2004).</li> <li>— Lors de la gestion de données de catégorie comportant plusieurs niveaux, le gain d'information est biaisé en faveur des attributs disposant plus de niveaux.</li> <li>— Les calculs peuvent devenir compliqués lorsque l'incertitude ainsi que les liens entre les résultats sont importants.</li> </ul>

TABLEAU 3.1 – Avantages et inconvénients des arbres de décision

### 3.3.2.3 Machine à vecteurs de support (Support vector machine ou SVM)

Le classifieur SVM est une puissante technique d'apprentissage supervisé utilisée pour la classification et la régression. Le classifieur SVM figure parmi les méthodes les plus précises de tous les algorithmes bien connus d'exploration des données. L'algorithme de base des SVM a été développé par Vapnik au milieu des années 1990 grâce à l'utilisation de concepts développés de la théorie de l'apprentissage statistique (VISHWANATHAN et MURTY 2002). L'objectif de l'algorithme de classification SVM est de trouver un hyperplan qui peut séparer les classes (deux classes) de points de données avec une marge maximale. La figure 3.4 illustre l'hyperplan obtenu avec le SVM, sur deux dimensions et deux classes (SVM linéaire). Les observations les plus proches de la frontière sont appelés les vecteurs de support (représentés par des formes pleines), tandis que l'hyperplan correspond au classifieur (VISHWANATHAN et MURTY 2002). La marge maximale est la distance perpendiculaire entre la fonction du classificateur SVM (ligne pointillée) et les vecteurs de support les plus proches (lignes pleines). La complexité du modèle SVM dépend du nombre de vecteurs de support car ces derniers contrôlent la dimensionnalité de la fonction de classification. La complexité du modèle SVM diminue lorsque le nombre de vecteurs de support diminue. Dans la littérature, plusieurs variantes des techniques de détection SVM sont présentées et évaluées (WANG et HU 2005). L'algorithme SVM a une complexité de calcul élevée en raison du problème d'optimisation quadratique qui doit être résolu. Cependant, le SVM présente généralement les meilleures performances en termes de précision et d'indices de performance F-score (cf. section 3.3.3.1) (MOHAPATRA, JAWAHAR et KUMAR 2014).

### 3.3.2.4 Régression logistique et multinomiale

La régression logistique et la régression multinomiale sont des méthodes de classification, où le résultat n'est pas une variable continue mais une classe catégorielle (c'est-à-dire un état parmi




FIGURE 3.4 – Structure de réseaux de neurones (GARCÍA-GONZALO et al. 2016)

un nombre fini d'états). La régression logistique est un algorithme de classification binaire, qui sépare les modèles d'entrée dans l'une des deux classes de sortie lorsque les données ne sont pas linéairement séparables. La régression multinomiale est l'extension de ce principe à plusieurs classes. Dans l'une ou l'autre version, la probabilité qu'un modèle d'entrée appartienne à l'une des classes résultantes est modélisée. La régression logistique utilise une fonction logistique, appelée Sigmoid ou courbe en S. Cette fonction, ayant donc une forme sigmoïde (figure 3.5) est définie comme suit :

$$\sigma(x) = \frac{1}{1 + \exp^{-x}} \quad (3.6)$$

### 3.3.2.5 Les K plus proches voisins (K-Nearest Neighbours ou KNN)

Le K plus proches voisins (KNN) est un algorithme conventionnel basé sur la distance pour classer les objets en fonction des résultats des objets les plus proches dans les données d'apprentissage (LAROSE et LAROSE 2014). Un classificateur KNN utilise la distance (similarité) entre le point de test et chaque point de données dans l'ensemble des données d'apprentissage. Ensuite, il sélectionne les K points les plus proches et vote sur leurs étiquettes de classe pour déterminer l'étiquette du point de test (MA et KABAN 2013). Cependant, les classes avec des résultats plus fréquents ont tendance à dominer la classification des objets de test et il n'y a que les K instances les plus proches de l'ensemble d'apprentissage qui sont considérés. La classe du nouveau point est donc placée en fonction de la plupart des membres de cet ensemble des K instances les plus proches (FAN et al. 2019). Les étapes de la méthode de classification par les k plus proches voisins (HAN, PEI et TONG 2022) sont les suivantes :

1. Prendre un ensemble d'objets étiquetés avec des caractéristiques.
2. Calculer la distance entre les objets de l'ensemble d'apprentissage. Une métrique de distance est une fonction d à valeur réelle, telle que pour tout point de données  $x, y$ ,  $d(x, y) \geq 0$ , et  $d(x, y) = 0$  si et seulement si  $x = y$ . La fonction de distance la plus utilisée est la




FIGURE 3.5 – La fonction logistique est une fonction sigmoïde, qui met en correspondance des valeurs continues du domaine des nombres réels avec l'intervalle  $[0, 1]$ , (GHAMRI 2016)

distance euclidienne, qui est calculée comme suit (Equation 3.7) :

$$d(x, y) = \sqrt{(x_i - y_i)^2} \quad (3.7)$$

Où  $x_i$  et  $y_i$  désignent les valeurs d'attribut de deux points.

3. Considérer les plus proches voisins ( $k$ ) de l'observation pour laquelle nous recherchons le groupe d'appartenance.  $K$  est une constante définie par l'utilisateur, et un échantillon de test avec des variables données est classé en assignant à l'étiquette la plus fréquente parmi les  $k$  ensembles de formation les plus proches de cet échantillon de test (MURPHY 2022).
4. Déterminer la classification la plus fréquente. La classe prédite pour  $x$  est (Equation 3.8) :

$$\hat{y} = \arg \max P(c_i|x) = \arg \max k_i \quad (3.8)$$

Où est la classe prédite, et  $P(c_i|x)$  est la probabilité a posteriori de la classe  $\hat{y}$  et  $k_i$  indique le nombre de points parmi les plus proches voisins de  $x$  qui sont étiquetés avec la classe  $c_i$ .

Le problème avec cette technique est le cout de calcul puisqu'il faut déterminer les distances entre les données. Ainsi, cet algorithme est performant sur un petit nombre d'observations.

### 3.3.3 Evaluation et validation des modèles d'apprentissages

#### 3.3.3.1 Mesures de performances

Cette section fournit les différentes mesures pour quantifier la performance des algorithmes de classification. Les mesures de performance qui s'appliquent aux modèles de classification sont donc présentées. Les critères spécifiques aux problèmes de classification sont répartis entre le

Les classes de données réelles	Les classes de données prédites	
	Positive	Négative
Positive	Vrais positifs (TP)	Vrais négatifs (TN)
Négative	Faux positifs (FP)	Faux négatifs (FN)

TABLEAU 3.2 – Matrice de confusion pour la classification binaire

classificateur binaire et les classificateurs multiples. L'évaluation du modèle de classification est essentielle pour évaluer sa qualité. L'objectif principal de l'évaluation du modèle de classification est d'obtenir une appréciation fiable de la qualité des résultats obtenus du modèle. En général, deux sujets liés à l'évaluation des classificateurs sont : la mesure de la performance et la procédure du processus d'évaluation (MIAO et ZHU 2022). Diverses mesures de performance sont utilisées, dans le cadre de travaux de recherche, pour évaluer l'efficacité des modèles de classification. Pour la classification binaire, la précision, la sensibilité (rappel), la spécificité, la valeur prédictive positive (VPP), la valeur prédictive négative (VPN), l'aire sous la courbe (AUC), la courbe ROC, la précision et le score F1 sont les mesures de performance les plus utilisées (GRANDINI, BAGLI et VISANI 2020). La classification binaire est l'affectation de classification la plus courante. L'entrée est classée dans l'une des deux classes non superposées (C1, C2).

En règle générale, le modèle peut être défini comme la manière de représenter les données utilisées pour le processus d'apprentissage en fonction des hypothèses définies. Après avoir construit un modèle d'apprentissage automatique et obtenu la sortie sous forme de classes ou de probabilités, l'effet du modèle est évalué sur la base de plusieurs métriques en utilisant des données prédites. Pour les problèmes de classification et de régression, il existe de nombreuses métriques pour mesurer les performances. Différentes mesures de performance peuvent être utilisées pour évaluer les modèles de classification binaire, telles que l'exactitude, la précision et l'aire sous la courbe (AUC).

L'une des meilleures approches pour illustrer les performances des programmes d'apprentissage automatique est la **matrice de confusion**. Il s'agit d'un moyen d'évaluer la précision des modèles. Ce moyen visualise les performances de la classification prédite par rapport à la classification réelle sous la forme d'informations sur les faux positifs (FP), les vrais positifs (TP), les faux négatifs (FN) et les vrais négatifs (TN). Il y a deux classes pour la classification binaire, ainsi, les entrées de la matrice de confusion résultante sont 2x2 matrice de confusion avec quatre cas possibles (NIJEWEME-D'HOLLOSY et al. 2018; AGGARWA et al. 2015), comme le montre le tableau 3.2. A partir de la matrice de confusion présentée dans le tableau 3.2, l'**exactitude (accuracy)** peut être calculée, comme indiqué dans l'équation 3.9: L'accuracy est une mesure de performance utilisée pour évaluer les modèles ML, il indique le pourcentage de bonnes prédictions.

$$Accuracy = \frac{TP + TN}{TP + FP + TN + FN} \quad (3.9)$$

Ainsi, dans le cadre d'une classification binaire, la mesure de la précision n'est pas une mesure efficace pour les données déséquilibrées. **L'erreur de classification** peut être calculée par 3.10:

$$Erreur de classification = \frac{1}{N} \sum_{i=1}^N I(y_i \neq \hat{y}) \quad (3.10)$$

Où  $\hat{y}$  désigne la classe prédite par le classificateur,  $y_i$  désigne la classe réelle,  $I$  est une fonction indicatrice qui a la valeur 1 si son argument est vrai et sinon elle prend la valeur 0 et  $N$

présente l'ensemble des données prédites. Plus le classificateur est performant, plus l'erreur de classification est faible (taux d'erreur).

Le **taux de vrais positifs**, appelé **sensibilité** (sensitivity) ou **rappel** (recall), est le taux de vrais positifs. Il s'agit du nombre d'instances de la classe positive qui sont prédites correctement, divisé par le nombre réel d'observations positives (Equation 3.11) :

$$Sensitivity(TVP) = \frac{TP}{TP + FN} \quad (3.11)$$

Le **taux de vrais négatifs**, appelé la **spécificité** (specificity) est le nombre d'instances de la classe négative (deuxième classe) qui ont été prédites correctement, divisé par le nombre total d'observations négatives réelles (Equation 3.12) :

$$Spcificity(TVN) = \frac{TN}{TN + FP} \quad (3.12)$$

La **courbe ROC (Receiver Operating Characteristics)** est une métrique couramment utilisée pour évaluer les performances des classificateurs binaires (deux classes). Cette courbe trace la sensibilité sur l'axe des  $y$  et la spécificité sur l'axe des  $x$ . L'aire sous la courbe ROC dans le cas binaire, notée par ASC ou AUC pour Area Under Curve, a des valeurs dans une zone de 0 à 1, ce qui représente le degré de précision du modèle. Le classificateur aléatoire dans le tracé ROC correspondant à une ligne diagonale, une surface de 0,5 représente un modèle aussi bon qu'un modèle aléatoire. Ainsi, un point au-dessus de cette ligne diagonale dénote une précision meilleure qu'une prédiction aléatoire. Inversement, un point en dessous de cette diagonale indique que la précision est pire qu'une prédiction aléatoire. L'AUC représente la capacité d'un modèle à discriminer entre les classes positives et négatives.

La **précision** est un indicateur performant dans le processus d'évaluation du modèle lorsqu'il y a une distribution équilibrée des classes de l'ensemble de données d'entraînement, elle peut être calculée en divisant le nombre d'observations positives correctement prédites par le nombre total d'observations positives prédites (Equation 3.13) :

$$Precision = \frac{TP}{TP + FP} \quad (3.13)$$

### 3.3.3.2 Généralisation et surajustement (overfitting)

La capacité de classification des données de test, qui n'ont pas encore été vues par le modèle, est appelée généralisation. La généralisation avec un faible taux d'erreur est l'objectif principal de toutes les méthodes d'apprentissage. La propriété de généralisation d'une méthode d'apprentissage peut être vérifiée en validant le modèle avec des ensembles de tests différents et séparés. En essayant de réduire les erreurs de classification/régression de l'ensemble d'entraînement, la complexité du classificateur doit être ajustée. En revanche, les modèles surentraînés peuvent effectuer une classification parfaite sur l'ensemble de données entraînées pendant le processus d'apprentissage, mais pas sur les nouvelles données (RADO 2019). Ce phénomène est connu sous le nom de surapprentissage ou surajustement ou surinterprétation (overfitting). Il s'agit de l'un des principaux défis de la recherche dans l'apprentissage automatique et la reconnaissance des formes.

Dans ce qui suit, un focus est fait sur l'apprentissage par renforcement, qui a été brièvement évoqué dans la section 3.3.1.4






FIGURE 3.6 – Le cycle d'apprentissage par renforcement. (RÜCKSTIESS 2016)

## 3.4 Techniques de l'apprentissage par renforcement

### 3.4.1 Généralité sur l'apprentissage par renforcement

D'une manière générale, l'apprentissage par renforcement (Reinforcement learning ou RL) vise à optimiser le comportement d'un agent artificiel suite à l'interaction entre ce dernier et son environnement au fil du temps. Le terme **agent** est utilisé pour tout type d'entité interactive plus ou moins autonome, comme un programme, un algorithme, un robot ou autre système capable de percevoir des entrées et d'y réagir par des sorties. Ces entrées sont appelées des **états** et les sorties des **actions**. Le comportement de l'agent, sa correspondance entre les états et les actions, est appelé une **politique** et peut être manipulé par le biais d'un retour d'information à l'agent. Ce retour est communément appelé **récompense** et peut être perçu par l'agent comme un signal. Les états peuvent être des états réels d'une machine physique (par exemple, marche/arrêt), une représentation interne d'un environnement virtuel ou des concepts abstraits. Un agent peut, par exemple, être dans l'état "Je ne sais pas ce que c'est cet objet". Il en va de même pour les actions : Elles peuvent être des commandes motrices très concrètes de bas niveau ou des concepts de haut niveau, comme "aller déjeuner". Les étapes temporelles ne doivent pas nécessairement faire référence à des intervalles fixes de temps réel, elles peuvent aussi être des étapes successives de prise de décision non liées à un cadre temporel fixe. La figure 3.6 illustre le cycle d'interaction entre un agent et son environnement. L'agent reçoit l'état actuel  $s_t$  de l'environnement et réagit par une action  $a_t$ . Celle-ci fait passer l'environnement à l'état  $s_{t+1}$  et provoque une récompense de  $r_{t+1}$ . Les récompenses peuvent être considérées comme provenant d'une source externe. Dans ce cas, l'environnement joue un rôle passif et réactif et on considère qu'il n'a pas d'intention ou de "plan" pour l'agent. Cependant, il n'est pas rare que les récompenses proviennent directement de l'environnement. C'est certainement le cas dans les scénarios de la vie réelle. Les deux versions sont équivalentes du point de vue de l'agent, qui ne s'intéresse qu'au montant de la récompense et non à sa source. L'optimisation dans l'énoncé ci-dessus fait référence à **la maximisation des récompenses reçues au fil du temps**. Dans la section suivante, nous détaillons le processus de décision de Markov (MDP) et l'algorithme de l'apprentissage utilisé pour la mise en œuvre de l'apprentissage par renforcement.



### 3.4.2 Processus de décision de Markov (MDP) et algorithme d'itération des valeurs

Le processus de décision de Markov (GARCIA et RACHELSON 2013) offre un formalisme standard pour décrire la prise de décision multi-état dans un environnement probabiliste. Plus précisément, un MDP est un processus de contrôle stochastique à temps discret. À chaque pas de temps, le processus se trouve dans un certain état  $s$ , et le décideur peut choisir n'importe quelle action  $a$  qui est disponible à partir de l'état  $s$ . Le processus répond au pas de temps suivant en passant aléatoirement dans un nouvel état  $s'$  et en donnant au décideur une récompense correspondante  $R(s, a, s')$ .

La probabilité que le processus passe dans son nouvel état  $s'$  est influencée par l'action choisie. Cette probabilité est donnée par la fonction de transition d'état  $T(s'|s, a)$ . Les transitions d'état d'un processus de décision de Markov satisfont la propriété de Markov qui implique que, étant donné l'état actuel  $s$  et une action  $a$ , l'état suivant  $s'$  est conditionnellement indépendant de tous les états et actions précédents. Le problème central des MDPs est de trouver une politique pour le décideur : une fonction  $\pi$  qui spécifie l'action  $\pi(s)$  que le décideur choisit lorsqu'il est à l'état  $s$ . Le but du MDP est de choisir une politique  $\pi$  qui maximise la fonction cumulative des récompenses aléatoires, formalisée par l'équation 3.14 :

$$\sum_{t=0}^{\infty} \gamma^t R(s_t, a_t, s_{t+1}) \quad (3.14)$$

Où  $t$  indique le pas de temps et  $\gamma$  est un facteur d'actualisation compris entre 0 et 1 qui affecte le degré de référence des récompenses immédiates par rapport aux récompenses ultérieures. Le processus de décision de Markov peut être résolu par l'**Itération de Valeur** ou **Value Iteration (VI)** qui est un algorithme qui trouve la fonction de valeur optimale et identifie donc ainsi la **politique optimale** (la récompense future actualisée attendue d'être dans un état et de se comporter de manière optimale à partir de celui-ci). L'idée centrale de l'algorithme Value Iteration est l'équation de Bellman, qui stipule que la valeur optimale d'un état est la valeur de l'action ayant le rendement futur escompté actualisé maximal (l'action ayant la valeur  $Q$  maximale) (RÜCKSTIESS 2016). La valeur  $Q$  d'une paire état-action est définie comme la valeur attendue, sur toutes les transitions d'états possibles, de la récompense immédiate additionnée à la valeur actualisée de l'état résultant. La formule est présentée par les équations (3.15 et 3.16) :

$$V(s) = \max_a Q(s, a) \quad (3.15)$$

$$Q(s, a) = \sum_{s'} T(s', s, a) [R(s, a, s') + V(s')] \quad (3.16)$$

### 3.4.3 L'algorithme Q-Learning

Contrairement à un algorithme de planification, un algorithme d'apprentissage tel que le Q-learning (CLIFTON et LABER 2020) implique la détermination du comportement lorsque l'agent ne sait pas comment le monde fonctionne et peut apprendre comment se comporter à partir d'une expérience directe avec le monde. Comme son nom l'indique, le Q-Learning estime les valeurs  $Q$  optimales d'un MDP, ce qui signifie que le comportement peut être appris en prenant des actions de manière avide par rapport aux valeurs  $Q$  apprises. Avec l'algorithme Q-learning, la façon la plus courante de choisir une action dans le(s) état(s) actuel(s) est d'utiliser une politique

avide. La fonction de mise à jour de Q-Learning est la suivante (Equation [3.17](#)) :

$$Q(s, a) = Q(s, a) + \alpha [R(s, a, s') + \gamma \max_{a'} Q(s', a') - Q(s, a)] \quad (3.17)$$

La valeur  $Q$  est actualisée par la valeur  $Q$  de la dernière paire état-action  $(s, a)$  par rapport à l'état de résultat observé  $s'$  et à la récompense directe  $R(s, a, s')$ . Le paramètre  $\alpha$  entre 0 et 1 représente le taux d'apprentissage. La différence des règles de mise à jour entre l'itération de la Valeur (VI) et l'algorithme Q-Learning est que la valeur  $Q$  d'un état dans l'itération de la valeur est la valeur  $Q$  maximale qui est la somme attendue de la récompense et de la valeur actualisée de l'état suivant, alors que la valeur  $Q$  de l'algorithme Q-Learning est la somme des récompenses et de la valeur  $Q$  maximale actualisée de l'état suivant observé, ce qui implique que nous utilisons uniquement les états et les récompenses que nous obtenons en interagissant avec l'environnement. Tant que nous continuons à essayer des actions aléatoires sur le même état, nous pouvons atteindre tous les états possibles du prochain.

L'algorithme Q-learning peut être résumé dans le pseudocode suivant. En effet, l'idée de base du Q-learning est d'estimer la fonction action-valeur en utilisant l'équation de Bellman comme mise à jour itérative. Dans ce cas, la fonction  $Q$  converge vers la fonction de valeur optimale lorsque l'itération  $i$  tend vers l'infini. Cependant, ce n'est pas pratique puisque la fonction action-valeur est estimée séparément pour chaque séquence sans aucune généralisation. Au lieu de cela, il est courant d'utiliser un approximateur de fonction pour estimer la fonction action-valeur. L'autre problème est que les algorithmes d'apprentissage par renforcement traditionnels dépendent fortement de la qualité des représentations des caractéristiques fabriquées à la main, ce qui limite le champ d'application de ces algorithmes. Il est évident que nous pourrions bénéficier davantage de l'extraction directe de caractéristiques à partir d'entrées sensorielles brutes de haute dimension, par exemple, les informations visuelles et auditives de type humain. Dans des études récentes, les modèles d'apprentissage profond sont des extracteurs de caractéristiques efficaces sur des données à haute dimension, ce qui sera discuté en détail dans le chapitre 5 (cf. section ??).

#### Algorithme Q-Learning

1. Initialiser les valeurs  $Q(s, a)$  arbitrairement pour toutes les paires état-action.
2. Faire jusqu'à la fin de l'apprentissage
3. Choisir une action  $a$  dans l'état actuel  $s$  en fonction des estimations des valeurs  $Q$  actuelles dans  $Q(s, -)$ .
4. Effectuer une action  $a$  et observer l'état de résultat  $s'$ , et la récompense  $R(s, a, s')$
5. Mettre à jour l'équation [3.17](#)

### 3.5 L'apprentissage automatique et le domaine de santé

Les méthodes et approches mathématiques et informatiques, dont l'apprentissage automatique, permettent d'offrir des services précieux à tous les domaines. Dans ce cadre, l'IA englobe l'ensemble des théories et techniques permettant de raisonner comme l'humain mais avec une capacité d'apprentissage de plus en plus performante et une mémoire infinie. Vu la croissance des technologies de l'Information et de la communication (TIC), ce n'est pas étonnant que l'IA est de plus en plus convoitée aujourd'hui, et dans tous les domaines. Il n'est pas prévu, ni conseillé, que l'IA soit conçue pour remplacer l'humain dans les prises de décisions sensibles, mais l'humain qui ne s'appuiera pas sur l'IA dans ces prises de décisions sera de toute façon

dépassé (ZHANG et LU [2021]). En effet, l'IA apportera une aide précieuse qui dépasse largement les capacités cognitives humaines (calculateurs de plus en plus performants, espaces de stockages de plus en plus importants, etc.). C'est pour ça qu'aujourd'hui on parle de Systèmes d'Aide à la Décision (SAD) Intelligents (SADI) qui s'appuient sur l'IA pour proposer à l'humain des solutions pointues, efficaces et rapides même si l'espace de recherche de solution soit démesuré. Comme indiqué précédemment, l'apprentissage automatique s'appuie sur l'ensemble de données de formation, puis classe l'ensemble des données de test en fonction des connaissances acquises. Dans le domaine de la santé, il existe déjà, et de plus en plus, une grande quantité de données cliniques cruciales qui pourraient être utiles pour la recherche. En effet, les techniques d'apprentissage automatique dans le domaine de la santé fournissent aux professionnels des meilleures informations pour prendre les meilleures décisions. Les techniques d'apprentissage automatique (ML) sont des outils puissants et flexibles pour analyser et prédire des résultats à partir de données cliniques ou biologiques. La technique ML a le potentiel d'améliorer efficacement le domaine de soins de plusieurs façons. Les ensembles de données cliniques sont des cibles optimales pour les méthodes d'exploration de données. Plusieurs techniques d'exploration de données ont été déployées aux données médicales pour prédire de nombreuses maladies. Certains algorithmes utilisés pour prédire le pronostic permettent aux personnels de santé d'allouer les ressources de manière optimale et aux médecins d'offrir de meilleures possibilités de traitement aux patients. Dans ce qui suit, les principaux domaines d'applications possibles de l'apprentissage automatique dans le domaine de santé sont décrits.

### 3.5.1 Le diagnostic médical

Dans le domaine de la santé, les praticiens peuvent s'appuyer sur des modèles de diagnostic pour orienter efficacement la prise en charge des patients et mieux recommander ainsi des tests et des traitements appropriés. Les modèles de diagnostic peuvent donc contribuer à réduire la charge de travail des médecins, à améliorer l'accès des patients aux soins, à réduire les coûts et à économiser les ressources. Cependant, malgré les progrès de la recherche sur les techniques de ML, l'intégration de ses techniques dans les systèmes de santé est encore limitée (CHEN et al. [2021]). Or, un diagnostic précis à un stade précoce de la maladie joue un rôle important dans la prise en charge des patients. Dans ce cadre, l'IA et plus précisément les outils de ML peuvent classer l'importance des caractéristiques à partir de grands ensembles de données complexes. La diversité des techniques de ML, y compris la machine à vecteur de support (cf.section [3.3.2.3]), les arbres de décision (cf.section [3.3.2.2]), l'apprentissage profond (DP) (BOLHASANI, MOHSENI et RAHMANI [2021]) et le réseau neuronal (cf.section [3.3.2.1]), est utilisé au profit du diagnostic de maladies (IQBAL et al. [2021]) telles que la maladie d'Alzheimer, les maladies cardiaques (BISGIN et al. [2022]) et le cancer (MAHMOOD et al. [2021]). Le but est de construire des modèles de classification et de prédiction adaptés. Les algorithmes de reconnaissance de formes, basés sur le ML, utilisés pour le diagnostic assisté par ordinateur peuvent aider les médecins à interpréter les images médicales en un temps relativement court. Les images médicales provenant de divers examens médicaux tels que les rayons X, l'IRM et les ultrasons sont les sources d'information qui décrivent la situation médicale des patients (WESSLING et al. [2022]).

### 3.5.2 Découverte de médicaments

La découverte de médicaments fait appel à un large éventail de disciplines scientifiques, notamment dans les domaines de la biologie et de la chimie. Il s'agit du processus d'identification des médicaments potentiels qui influenceraient les maladies. Le ML et l'intelligence artificielle

(AI), y compris l'apprentissage profond, sont des méthodes puissantes pour comprendre les conditions qui affectent les molécules car ces techniques, comme mentionné précédemment, peuvent traiter efficacement les bases de données à haute dimension. Les approches ML couramment utilisées dans la découverte de médicaments sont les SVM (cf.section 3.3.2.3), DT (cf.section 3.3.2.2), k-NN (cf.section 3.3.2.5), les méthodes bayésiennes naïves (IBRAHIM et SAFAR 2021) et les ANN (cf.section 3.3.2.1) (VATANSEVER et al. 2021).

### 3.5.3 Les urgences hospitalières

Plusieurs travaux sont proposés dans la littérature pour aider les infirmiers d'accueil et d'orientation à prendre des décisions pour améliorer le système de triage existant. Ces travaux déploient généralement des modèles basés sur les données et les techniques de ML. Dans le cadre de ces études, la plupart des modèles proposés n'incluent que les informations collectées au moment de l'arrivée, telles que les données démographiques, les signes vitaux, la raison de l'arrivée, les observations de l'infirmière et le diagnostic primaire (LUCKE et al. 2018). Par ailleurs, rares sont les travaux qui incluent des caractéristiques supplémentaires telles que les antécédents médicaux (HM) (WANG et al. 2020).

Dans ce contexte, de nombreux modèles de prédiction basés sur des techniques ML sont développés pour évaluer la probabilité de l'hospitalisation au moment de l'arrivée du patient aux urgences et aussi pour classer les patients en fonction de leur état de gravité. Parmi ces études, LaMantia et ses collaborateurs (LAMANTIA et al. 2010) ont utilisé la régression logistique pour prédire les admissions à l'hôpital en utilisant une série de données cliniques et démographiques pour les patients âgés. Cette équipe a prédit les admissions avec une précision modérée mais n'a pas pu gérer l'incertitude des données utilisées. Baumann et Strout (BAUMANN et STROUT 2007) ont démontré une relation entre le score de gravité l'ESI (Emergency severity index) (cf.section 1.3.2) et l'admission des patients de plus de 65 ans, mais cette relation ne peut pas être utilisée pour aider à la prise de décision car le score ESI reste imprécis. D'un autre côté, Graham et ses collaborateurs (GRAHAM et al. 2018) ont proposé un modèle de prédiction basé sur trois méthodes d'apprentissage automatique utilisant des données historiques. Ce modèle a permis d'améliorer la qualité des décisions et de réduire le taux d'erreur. Cependant, il était incapable de gérer des données non structurées et incertaines. Wang et al. (WANG et al. 2015) ont prédit l'admission dans les services d'urgence, en comparant les performances du réseau neuronal Fuzzy Min-Max (FMNN) avec d'autres algorithmes standard d'exploration des données tels que la classification supervisée avec des arbres de décision et de régression (CART), le réseau neuronal classique, la forêt aléatoire et AdaBoost. Ils ont prouvé que le réseau neuronal et la forêt aléatoire sont les méthodes les plus efficaces avec un taux de précision de 80% et aussi le FMNN avec une précision de 77,97%, ce dernier est basé sur un algorithme génétique. Néanmoins, malgré ces résultats efficaces, le risque de données faussement positives reste important en raison de données médicales incohérentes et manquantes. Fernandes et ses collaborateurs (FERNANDES et al. 2020) ont proposé un modèle de prédiction basé sur des techniques de ML et de traitement du langage naturel. Cette méthode est utilisée pour traiter la plainte principale du patient sous forme de données textuelles non structurées. Le modèle de Fernandes a été amélioré par rapport aux études précédentes, mais les données manquantes et incertaines n'ont pas été prises en compte. Zhang et ses collaborateurs (ZHANG et al. 2017) ont également utilisé le traitement du langage naturel pour analyser, comprendre et extraire des informations des données non structurées et semi-structurées avant l'étape de classification, mais le modèle proposé, le système ignore l'ordre des mots et les informations contextuelles correspondantes, ce qui entraîne une

perte de sémantique.

Les établissements hospitaliers visent aujourd'hui un système de triage efficace car ce dernier est essentiel pour atténuer l'effet de l'augmentation du volume. Un triage efficace doit être fait en déterminant avec précision l'acuité du patient, les besoins en ressources et en établissant efficacement la priorité du patient en fonction de son acuité. Plusieurs études ont classé les patients en fonction de leur niveau de gravité sur la base du score ESI (cf. section 1.3.2). Ivanon et ses collaborateurs (IVANOV et al. 2020) ont déterminé que les données médicales historiques peuvent être extraites et synthétisées avec le traitement du langage naturel clinique (C-NLP) et les derniers algorithmes ML peuvent produire des modèles prédictifs très précis de l'ESI. Cependant, ils ne disposent pas de suffisamment de données pour les patients gravement malades pour analyser toutes les possibilités. En outre, dans (CHONDE et al. 2013), les auteurs ont comparé les capacités de prédiction du niveau de gravité (ESI) en utilisant la régression logistique ordinaire (OLR), les réseaux neuronaux artificiels (ANN) et les réseaux bayésiens naïfs (NBN). Ils ont ainsi constaté que le NBN est la meilleure méthode en ce qui concerne la vitesse d'apprentissage et la précision des résultats, sauf qu'ils ne peuvent pas traiter les données textuelles non structurées qui peuvent grandement influencer le résultat final. Gligorijevic et ses collaborateurs (GLIGORIJEVIC et al. 2018) ont proposé un nouveau modèle profond basé sur le mécanisme du mot d'attention conçu pour prédire le nombre de ressources dont un patient aurait besoin dans une salle d'urgence. Ils ont utilisé des données structurées et non structurées, ce qui a donné un AUC (cf. section 3.3.3.1) de 88%. Soufi et collaborateurs (SOUFI et al. 2018) ont utilisé une combinaison d'approches de raisonnement à base de règles (RBR) et de classificateur à logique floue (FLC) pour prédire le niveau de triage des patients en fonction de l'avis du spécialiste du triage et de la sévérité des directives de l'indice d'urgence (UIG), mais n'ont pas pris en compte toutes les données médicales susceptibles d'influencer la décision.

### 3.6 Synthèses et Positionnement

Dans le cadre de cette thèse, nous nous focalisons sur le problème de triage et de tension dans les urgences hospitalières. Pour traiter ces problèmes, nous nous basons sur les techniques de classification de ML. Pour utiliser les algorithmes de classification dans le domaine de santé, nous pouvons conclure que :

- Les techniques ML se concentrent uniquement sur les données structurées et textuelles collectées. Les données textuelles non structurées sont généralement exclues en raison du dépistage et des difficultés opérationnelles, à l'exception de quelques études (WANG et al. 2020), sachant que ce type de données est considérée comme très importante dans la prise de décision.
- La plupart des études issues de la littérature se concentrent sur la précision de la classification, et peu d'études ont pris en compte les autres critères qui sont très importants comme la sensibilité et la spécificité.
- La taille de l'ensemble des données utilisées est faible dans certaines recherches. Comme peu de données sont utilisées pour la formation et les tests, l'absence d'une exploitation des modèles formés à partir de différentes sources à de nouvelles données.
- La qualité des données médicales inhérentes et incertaines influencent négativement sur la performance et les résultats fournis par le système proposé.

Le tableau ( 3.3) suivant fournit un résumé des travaux déjà évoqués précédemment et des

Travaux	Applications au SUA	ML	Données textuelles	Ontologies	Logique floue	Données manquantes
(LAMANTIA et al. 2010)	Aval	X				
(GRAHAM et al. 2018)	Aval	X				X
(WANG et al. 2015)	Aval	X			X	
(FERNANDES et al. 2020)	Aval	X	X			
(ZHANG et al. 2017)	Aval	X	X			
(IVANOV et al. 2020)	Triage	X	X			
(CHONDE et al. 2013)	Triage	X				
(GLIGORIJEVIC et al. 2018)	Intra	X	X			
(SOUFI et al. 2018)	Triage				X	
(MICHALOWSKI et al. 2005)	Triage		X	X		
(FARION et al. 2009)	Triage		X	X		
(PEDRO et al. 2005)	Triage		X	X		
(JAYARAMAN et al. 2013)	Triage		X	X		
(WUNSCH, DA COSTA et RIGHI 2017)	Triage	X	X	X		

TABLEAU 3.3 – Résumé des références clés discutées

travaux liés au SUA. En effet, nous nous sommes concentrés sur les travaux qui s'intéressent au triage, à l'aval en prédisant l'admission des patients au moment d'arrivées et à la gestion de tension. Nous pouvons déduire d'après le tableau qu'ils existent des travaux basés sur les techniques d'apprentissage qui présentent une solution potentielle pour les personnels de soin au SU dans le but d'optimiser le système d'urgence et anticiper ainsi les pics de tension. Nous pouvons remarquer que les combinaisons entre les ontologies et le raisonnement sémantique sont rarement développées (JAYARAMAN et al. 2013). De plus, le problème des données manquantes, des connaissances imprécises et du traitement des données textuelles non structurées reste parmi les principales limites des systèmes existants. Dans ce contexte, l'utilisation des techniques de gestion de l'imperfection des connaissances constitue une solution intuitive à ce problème comme nous avons expliqué dans le chapitre précédent.

Nous nous concentrons dans cette thèse sur le développement d'un système d'aide à la décision (SAD) intelligent basé sur des ontologies de domaines classiques et floues. En effet, il s'agit d'un champ d'étude issu de l'intelligence artificielle qui se fonde sur des approches mathématiques et statistiques pour donner aux calculateurs la capacité d'« apprendre » à partir des données et d'améliorer leurs performances à résoudre des tâches sans modéliser explicitement les stratégies de résolution. Plus largement, il concerne la conception, l'analyse, l'optimisation, le développement et l'implémentation des modèles intelligents qui ont la capacité de raisonner en se basant sur les données. De plus, nous montrons que la combinaison de techniques d'IA sub-symbolique comme les techniques d'apprentissage avec l'IA symbolique, comme les ontologies nous permet d'avoir un modèle puissant qui fournit des connaissances sémantiques pertinentes. Cette combinaison entre l'apprentissage et les ontologies est donc basée sur deux aspects : les approches symboliques sont proposées afin d'extraire des connaissances pertinentes et transformer les données cliniques brutes en des connaissances, et les approches cognitives sont basées sur les théories de probabilités et mathématiques afin de créer des modèles capable d'apprendre. En effet, les ontologies jouent trois rôles importantes dans notre système : Premièrement, elles contribuent à traiter les données non structurées textuelles en assurant l'extraction les données sémantiques utilisées. Deuxièmement, elles présentent notre base de

connaissances (données traitées) en exploitant les fouilles de connaissances afin de les générer avec des algorithmes d'apprentissages dans la suite. Troisièmement, elles présentent un système expert en générant une base de règles sémantiques avec un moteur d'inférence intégré, ce qu'on appelle le raisonnement sémantique automatique. Nous nous focalisons ainsi sur les théories de gestion de l'imprécision et de l'incertitude telles que la logique floue et la théorie de Dempster Shafer, que nous intégrons dans notre modèle, ce qui permet d'améliorer le triage, anticiper la tension et la gérer.

### 3.7 Conclusion

Dans ce chapitre, nous avons décrit les notions de base de fonctionnement des techniques d'apprentissage automatiques et les mesures de performances utilisées pour évaluer les modèles de classification. D'après la présentation de ces concepts et l'étude de la littérature, nous pouvons conclure que l'intégration des outils, méthodes et approches issus de l'IA peut être un atout majeur pour améliorer la qualité des soins en réduisant le risque d'erreur au niveau de l'étape de triage du SUA. Par ailleurs, une préparation efficace des données de santé (nettoyage, et étude et analyse) est primordiale l'orientation vers les outils et modèles adéquats. Dans le chapitre suivant, nous décrivons la solution proposée, c'est-à-dire la modélisation des ontologies, leurs composants et leurs fonctionnements. Précisément, nous définissons trois ontologie complémentaires : une ontologie de triage qui décrit le processus de triage, une ontologie de gestion de la tension qui identifie les situations de tensions et aide à les gérer et une ontologie de service d'urgence qui englobe les deux premières ontologies afin d'aider à anticiper les situations de tensions. Ainsi, nous montrons les raisonnements sémantiques définis dans chaque modèle.

# Proposition d'une approche hybride d'extraction des connaissances et de structuration des données : Vers une conception des ontologies de domaines et des ontologies rationnelles des urgences

## 4.1 Introduction

En se basant sur l'étude de la littérature réalisée dans le cadre de cette thèse et sur l'importance du domaine de la santé aujourd'hui, nous constatons que l'amélioration de ce domaine à travers l'IA est indispensable. Nous trouvons aussi que la représentation des connaissances peut surmonter les problèmes de données ambiguës, textuelles et non structurées. Ces données ne sont pas exploitables et leurs utilisations peuvent réduire la qualité des systèmes d'information hospitaliers. Dans ce contexte, nous pouvons traiter ces données et les transformer en des connaissances pertinentes afin d'améliorer l'efficacité de la prise de décision. Nous commençons ce chapitre par présenter l'architecture globale du système proposé. Puis, nous décrivons notre modèle de données et nous proposons trois ontologies (OntoTris, FOTS et EDOMO) qui définissent le domaine d'urgence afin d'optimiser le système de triage et pour gérer la tension.



## 4.2 Architecture globale du système proposé

L'objectif principal de la solution que nous proposons dans le cadre de cette thèse est l'optimisation de la qualité de soins en anticipant la tension dans les SUA. En se basant sur les travaux précédents et les difficultés du système d'urgence actuel, nous proposons un Système d'Aide au Triage et de Gestion de la Tension (SATGT) dont le but est de réduire le temps d'attente et le risque d'erreurs. L'architecture globale du modèle proposé est basée principalement sur les ontologies proposées de domaine (spécifique au SUA). Cette architecture est divisée en deux grandes parties :

1. Framework d'extraction et de prétraitement des données : Ce premier niveau permet le prétraitement et l'exploitation des données cliniques. Le **framework** endosse un processus capable d'extraire et de structurer les connaissances cliniques pertinentes sous forme de données textuelles et non structurées, en se basant sur une méta-ontologie de domaine spécifique aux urgences. Ce processus commence par l'extraction des données textuelles non structurées. Pour ce faire, un moteur d'inférence contenant toutes les instances de l'ontologie est lancé. Il permet d'identifier et classer les composants des attributs textuelles non structurés. Un algorithme de **Clustering** est ensuite déployé, permettant de calculer la symétrie lexicale pour affecter chaque concept dans l'ontologie. Ce processus est détaillé dans la section [4.5](#).
2. Algorithmes d'apprentissage et de raisonnement : Ce deuxième niveau, interconnecté au premier, génère des solutions d'aide à la décision au profit des personnels de santé afin de trier efficacement les patients et pour gérer les situations de tensions. En se basant sur les ontologies définies, ces algorithmes d'apprentissage automatique, conjointement avec les modèles flous, forment un système qui permet de prédire l'admission des patients dès leur arrivée au SUA. Ce système permet aussi de prédire les arrivées, d'aider au triage et à la gestion de la tension.

Le Système d'Aide au Triage et de Gestion de la Tension (SATGT) proposé, représenté par la figure [4.1](#), est donc basé sur deux types d'IA : IA Symbolique (Ontologie floue) et l'IA Subsymbolique (Apprentissage automatique). La figure [4.1](#) présente l'architecture du système SATGT proposé. À partir d'une base de données brutes, ce système commence par le prétraitement des données et des connaissances afin d'enrichir le modèle de données. Les données cliniques contiennent généralement des données textuelles non structurées dont l'exploitation pose un problème majeur dans l'apprentissage automatique. Dans ce contexte, nous décrivons les **ontologies de domaine** (Triage et tension) du SUA qui jouent un rôle primordial dans l'extraction des connaissances pertinentes des domaines concernés et la transformation des données brutes en des connaissances sémantiques.

Les ontologies utilisent les raisonneurs sémantiques et les règles **SWRL** (Semantic Web Rule Language). Ce dernier est un langage de règles pour le **web sémantique**, combinant le langage **OWL-DL** et **RuleML** (Rule Markup Language), qui présente l'IA symbolique dans notre système. Dans ce contexte, nous créons des règles qui sont capables d'identifier les situations de tension et de recommander aux personnels de santé les meilleures actions pour gérer ces situations. Les modèles de prédictions et d'aide à la décision basés sur la classification supervisée présentent l'IA Subsymbolique. Cette dernière est capable de raisonner en se basant sur les données et les connaissances exploitées par l'IA Symbolique en utilisant les algorithmes d'apprentissages

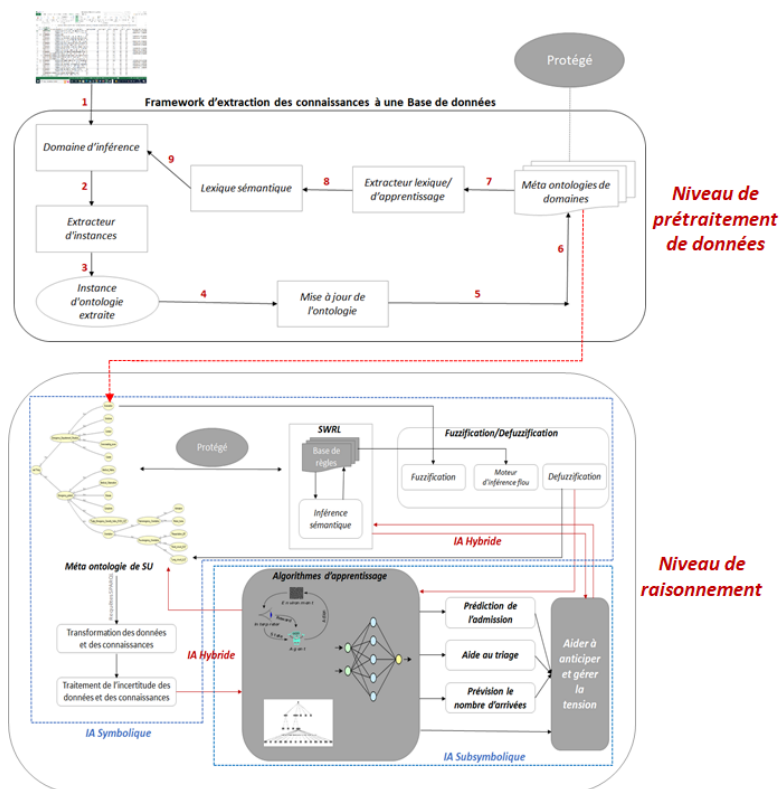


FIGURE 4.1 – Architecture globale de la solution proposée : Système d'Aide au Triage et de Gestion de la Tension (SATGT)

MDC: Dyspnée aiguë et palpitations. ATCDs: Appendicectomie. Intervention au niveau des ligaments croisés du genou D. Fracture du MG en 1998. Ponction articulaire du genou gauche. Anélasthésie des dents de sagesse. Familliaux: aucun. Allergies: NC. TAD: aucun. FORCV: Poids à 95 kg taille 174 cm. MDI: Fonctionnaire dans l'Éducation Nationale. Patient pratiquant régulièrement la course à pied. HDM: 2ème épisode dans l'année de crise paroxystique nocturne. Le 31/05/2016 vers 23-30, 45 minutes après s'être couché, dyspnée aiguë insomniante avec sensation de mort imminente puis palpitations (battements réguliers rapides), signes neurovégétatifs, douleurs abdominales. Régression des symptômes à l'arrivée du SAMU (20 minutes après début de la crise). Examen physique: Pas de défaillance respiratoire, hémodynamique ou neurologique. Appréhension. Cardio: bdc: réguliers sans bruits surajoutés. pouls tibiaux post percus. Pneumo: MV symétrique et bilatéral sans foyer à l'auscultation. Gastro: abdomen souple dépressible sensible en fosse iliaque gauche. examen neurologique sans particularité. ECG: RS à environ 55 bpm, espace PR normal, QRS fins, axe normal, pas de séquelle de nécrose, pas d'HVG, pas de troubles de la repolarisation, QT non allongé. Biologie normale. RP: pas d'anomalies. Au total, très probable crise d'angorose aiguë sans arguments pour une origine cardio-vasculaire, pulmonaire ou hématologique menaçante pouvant expliquer la dyspnée. Prise en charge ambulatoire avec réassurance.

	Q	R	S	T	U	V	W	X	Y
1	Localisation	IAO-observation	Examens complétés	Examens complétés	Examens	Examens	Examens	Examens	Examens complétés
2	1 (Attente pré)	01/06/2016 01:06:30 réassurance.	oui	oui	non	non	non	non	01/06/2016 01:30
3	2 (Attente pré)	01/06/2016 01:32 vient pour hyperthermie ATCD: DID retard me	oui	non	non	non	non	non	01/06/2016 01:34
4	21	01/06/2016 02:41	non	non	non	non	non	oui	
5	1 (Attente pré)	01/06/2016 01:36 patient de 58 ans appelle le SAMU pour épisode	oui	non	non	non	non	non	01/06/2016 01:40
6	2 (Attente pré)	01/06/2016 01:36 Patiente de 69 ans amenée pour douleur mem	oui	non	non	non	non	oui	01/06/2016 01:34
7	1 (Attente pré)	01/06/2016 01:55 tit : levothyrox 75µg/ valartan 40 mg matin	c non	non	non	non	non	oui	
8	2 (Attente pré)	01/06/2016 02:02 Patient de 24ans consulte pour douleur thoraciq	oui	non	non	non	non	non	01/06/2016 02:17
9	2 (Attente pré)	01/06/2016 02:13 ATCD D patient actuellement en garde à vue , au	oui	oui	non	non	non	non	01/06/2016 02:26

FIGURE 4.2 – Observation médicale pour un patient dans la base de données

automatique (Comme les Réseaux de neurones). Notre système SATGT est donc basé sur l'IA Hybride, qui représente la combinaison entre l'IA symbolique et l'IA Subsymbolique.

### 4.3 Les données médicales et ses structurations

Dans le cadre de cette thèse, notre terrain d'expérimentation est le service des urgences adultes (SUA) du CHU de Lille. Ce service nous fournit une base de données de l'ensemble des prises en charge effectuées entre l'année 2016 et l'année 2020. Cette base contient 386.460 patients. Elle est anonyme et présente les informations médicales présentées dans le Tableau 4.1 ci-dessous.

Cette base contient 39 attributs. Dans le cadre de cette thèse, nous utilisons 26 attributs (des 39 existants) dont 6 attributs correspondant à des données textuelles non structurées car il y'a des données qui n'ont pas aucun impact ni sur l'état de santé des patient ni sur la situation de tension de SUA (comme le code postale des patients). L'exploitation de ces données nécessite leur transformation en des connaissances sémantiques afin d'extraire les informations utiles qui vont permettre d'alimenter notre modèle. Par exemple, l'attribut « Anamnèse » contient la plupart des informations cliniques saisies par le médecin telles que les observations, les antécédents, les symptômes et le traitement recommandé (figure 4.2). Un modèle de connaissance doit donc être structuré et modélisé afin de pouvoir classer les informations pertinentes dans leurs classes adéquates sémantiquement. Nous présentons dans la suite les ontologies qui définissent et représentent notre base de connaissances et les techniques d'extraction et de raisonnement sémantique qui assure la structuration de ces informations.

### 4.4 Les ontologies proposées du domaine de SUA

Dans cette partie, nous soulignons l'avantage de se baser sur les ontologies dans plusieurs domaines d'application et notamment en santé. Au cours des dernières décennies, les processus de soin deviennent de plus en plus encadrés scientifiquement en raison des progrès techniques et de l'augmentation des connaissances dans le domaine de la santé. Ces connaissances accrues nécessitent un système pour stocker, gérer et transférer les informations entre les plateformes

Attributs		Types de données
Num dossier		Numérique
Informations du passage	Date et heure d'arrivée	Date et heure
	CAC <sup>a</sup> d'arrivée	Textuelle structurée
	CAC d'admission	Textuelle structurée
	CAC du séjour	Numérique
	Date et heure de sortie	Numérique
	heure de 1ère prise en charge médicale	Numérique
IAO	Motif d'entrée	Textuelle non structurée
	Motif de venue	Textuelle structurée
	Observation	Textuelle non structurée
Patient	Age en année	Numérique
	code postal de la ville	Textuelle
	nom de la ville	Numérique
Antécédent	Antécédents médicaux	Textuelle non structurée
	Antécédents chirurgicaux	Textuelle non structurée
Constante (Surveillances)	PAS/PAD adultes	Réel
	FC <sup>b</sup> adultes	Réel
	Température adultes	Réel
	SaO <sub>2</sub> <sup>c</sup> adultes	Réel
	Fréquence Respiratoire	Réel
Diagnostic	Code CCMU	Numérique
Diagnostic (diagnostic principal)	code diagnostic	Textuelle
	intitulé	Textuelle structurée
Localisation	Salles <sup>d</sup>	Textuelle + date et heure
	date d'entrée en box	Date et heure
Anamnèse	texte	Textuelle non structurée
Examens complémentaires	des examens de biologie	Booléenne
	des examens de radiologie	Booléenne
	des examens d'échographie	Booléenne
	des examens de scanner	Booléenne
	des examens d'IRM	Booléenne
	des avis de spécialistes	Booléenne
	date et heure 1ère prescription biologique	Date et heure
	date et heure 1er prélèvement biologique	Date et heure
Orientation	Type d'orientation	Textuelle structurée
	destination	Textuelle non structurée
	transfert vers le service	Textuelle non structurée
	transfert vers l'hôpital	Textuelle non structurée

TABLEAU 4.1 – Structure de la base de données du CHU

a. Centre de d'Accueil et de Crise

b. Fréquence cardiaque

c. Saturation d'oxygène

d. Salle d'attente ou salle d'examen ou salle de consultation

médicales. Les ontologies offrent un moyen permettant de créer un langage commun pour partager ces informations avec un transfert transparent des données entre les différents systèmes. La santé a été l'un des premiers domaines à intégrer des ontologies dans la recherche, afin de faire face à l'évolution des connaissances avec des données volumineuses et une terminologie incohérente. Cependant, l'utilisation des ontologies dans les applications proches des environnements cliniques est encore faible (ZENUNI et al. 2015; KOLIAS et al. 2014). Nous présentons dans ce qui suit les ontologies proposées et ses applications.

#### 4.4.1 L'ontologie OntoTriS proposée

Dans cette partie, nous définissons l'ontologie de domaine classique OntoTriS. Dans le cadre de cette ontologie, nous proposons un score pour évaluer l'état de sévérité des patients à leur arrivée aux urgences. L'ontologie OntoTriS permet de décrire le domaine du triage afin d'aider les infirmiers concernés par cette mission de bien trier les patients et les orienter vers le circuit adéquat. Ainsi, elle permet de catégoriser le temps d'attente pour ne pas dépasser la limite supérieure d'intervention pour chaque patient.

##### 4.4.1.1 Développement de l'ontologie OntoTriS

L'ontologie OntoTriS est développée en utilisant la méthode Methontology (FERNÁNDEZ-LÓPEZ, GÓMEZ-PÉREZ et JURISTO 1997) parce qu'elle fournit un support technique détaillé et facilite la création de modèles connaissances par en assurant un processus de modélisation détaillé pour construire une ontologie dans le domaine médical. Les étapes de développement sont la spécification, la conceptualisation, la formalisation, l'implémentation (correspondant au modèle physique) et la maintenance. Ces étapes sont détaillées dans ce qui suit :

1. **Spécification** : A ce niveau, l'objectif de l'ontologie OntoTriS ainsi que ses utilisateurs doivent être fixés. Concernant l'objectif, il s'agit ici de la description du domaine de triage en mettant l'accent sur l'évaluation de l'état de sévérité des patients au moment de leurs arrivée aux urgences. Les utilisateurs de cette ontologie sont des personnels des urgences et précisément les infirmiers de triage.
2. **Conceptualisation** : A ce niveau, nous modélisons les connaissances du domaine de triage et de son environnement (concepts, propriétés, relations et instances) à travers le diagramme de classe UML qui décrit les classes, les instances, les acteurs et les relations entre ces éléments (cf. figure 4.3). Toutes les informations qui peuvent aider à trier un patient sont présentées dans le modèle conceptuel. Par exemple, la classe "Emergency-patient-files" définit les données cliniques de chaque patient dans le SUA (comme symptômes et antécédents). Tous ces éléments sont détaillés dans la partie qui décrit finement la structure de l'ontologie (cf. section 4.4.1.2).
3. **Formalisation** : Afin de formaliser une ontologie complète, nous décrivons les classes formellement en utilisant le langage de description logique (DL) et nous modélisons les connaissances en élaborant un graphe de connaissances. Dans cette étape, nous transformons le diagramme de classe en une ontologie :

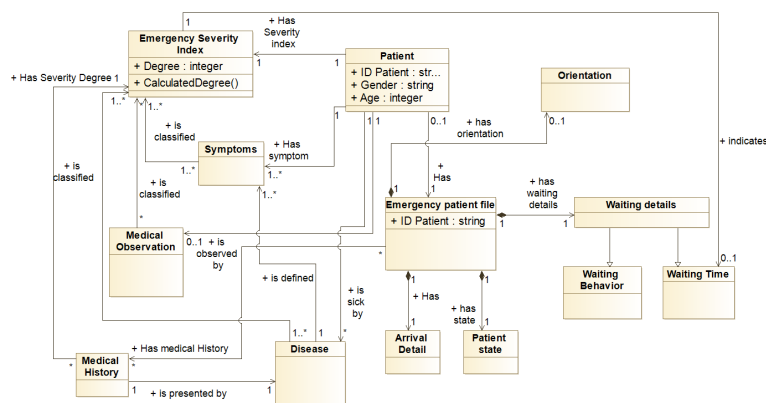


FIGURE 4.3 – Le diagramme de classe de l'ontologie OntoTriS

- les classes en des classes ontologiques,
- les relations en des propriétés de données et des propriétés d'objets,
- les instances en des instances ontologiques.

Ensuite, les concepts doivent être décrits formellement en utilisant le langage DL.

4. **Implémentation** : Il s'agit ici de l'implémentation physique de l'ontologie qui dépend du langage adopté. Nous avons fait le choix d'implémenter notre ontologie (décrit dans ). Nous interprétons ici l'expression du modèle ontologique formel à l'aide d'un langage d'implémentation pour créer une ontologie complète et fonctionnelle.
5. **Maintenance** : Il s'agit ici d'une phase récurrente pendant laquelle l'ontologie doit être améliorée et raffinée en continue en enrichissant le vocabulaire défini et en le rendant plus performant.

#### 4.4.1.2 La structure de l'ontologie OntoTriS

L'ontologie proposée fournit la normalisation nécessaire pour les urgences hospitalières, offrant une gamme de possibilités permettant d'enregistrer les observations et les événements rencontrés par le personnel de santé et en utilisant un vocabulaire médical issu du dictionnaire scientifique de médecine [38]. En se basant sur le travail de (FAKHFAKH, MAALEL et FARHAT 2019), l'ontologie de domaine proposée OntoTriS (dont les étapes de développement ont été présentées dans la section 4.4.1.1), contient trois niveaux de base. Dans cette partie, nous nous focalisons sur la structure de cette ontologie, composée donc de ces 3 niveaux (Figure 4.4) : **Niveau n° 1** : le niveau générique du domaine, **Niveau n° 2** : le niveau du domaine et **Niveau n° 3** : le niveau des cas.

Dans le cadre de cette thèse, nous avons développé l'ontologie OntoTriS en collaboration avec le personnel de santé des urgences du CHU de Lille. OntoTriS définit les concepts de triage en utilisant la documentation scientifique ainsi que des ontologies de standardisations telles que la « *Systematized Nomenclature of Medicine Clinical Terms (SNOMEDCT)* », la *Classification internationale des maladies* (CIM) et la *Disease Ontology (DO)*. Les classes OWL sont représentent

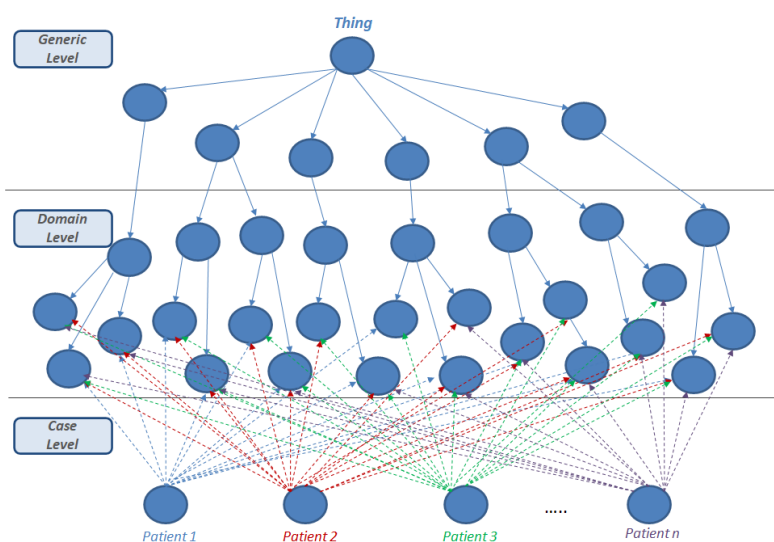


FIGURE 4.4 – La structure de l'ontologie OntoTriS

les ensembles d'individus (ou ensembles d'objets) et la classe « Thing » représente l'ensemble contenant tous les individus (ABEYSIRIWARDANA et KODITUWAKKU 2012). Cette structuration est représentée par la figure 4.4 ci-dessous qui affiche clairement les trois niveaux d'abstraction des connaissances et leurs liens :

- **Le niveau générique du domaine :** contient les concepts génériques de haut niveau du domaine de soins. La description de ce niveau doit être générale pour permettre sa réutilisation dans d'autres contextes du même domaine (définis dans le tableau 4.2).
- **Le niveau domaine :** décrit précisément le domaine de triage en mettant l'accent sur l'évaluation de l'état de sévérité du patient au moment de son arrivée aux urgences (défini par des propriétés et des concepts de domaine).
- **Le niveau des cas :** il s'agit ici de la définition des cas concrets des patients qui sont arrivés aux urgences et leurs données cliniques.

**4.4.1.2.1 Niveau générique de OntoTris** Le niveau générique représente les connaissances principales du domaine sous la forme d'une ontologie. Ce niveau permet de représenter le domaine de soins d'une façon générale. Par conséquent, la réutilisation de ce niveau est possible pour d'autres sous-domaines du domaine de soins. La figure 4.5 ci-dessous représente ce niveau générique qui contient 6 classes principales (ou concepts fondamentaux) expliqués dans le tableau 4.2. Ces concepts fondamentaux sont : **Emergency Patients** (patients du SU), **Chief complaint** (motifs de venues), **Emergency Severity Index** (CCMU), **Primary Medical Observation** (observations médicales), **Symptoms** (symptômes) et **Antecedents** (antécédents médicaux). La classe racine de ces six classes est la classe Thing.

**4.4.1.2.2 Niveau de domaine de OntoTris** Ce niveau définit le domaine d'une manière concise et pour un objectif bien déterminé. Pour définir les concepts du domaine, nous utilisons des ontologies de standardisation telles que les ontologies SYMP et ICD pour construire une ontologie de domaine médical selon le dictionnaire médical de santé. Une fois que les propriétés,

Classes générique	Description
Emergency patient	Définit toutes les données spécifiques d'un patient telles que les données démographiques, le mode d'arrivée et le temps d'attente
Chief complaint	Définit les motifs de venue des patients
Emergency Severity Index	Présente l'indice de gravité de l'urgence (ESI) qui permet l'évaluation de l'état de sévérité du patient à l'aide d'un score bien déterminé
Primary Medical Observation	Décrit les signes vitaux et les observations médicales issus des infirmiers de triage pour chaque patient
Symptoms	Définit les symptômes chez les patients qui arrivent aux urgences
Antecedents	Décrit les antécédents médicaux chez les patients aux urgences.

TABLEAU 4.2 – Déclaration des classes principales de l'ontologie OntoTris

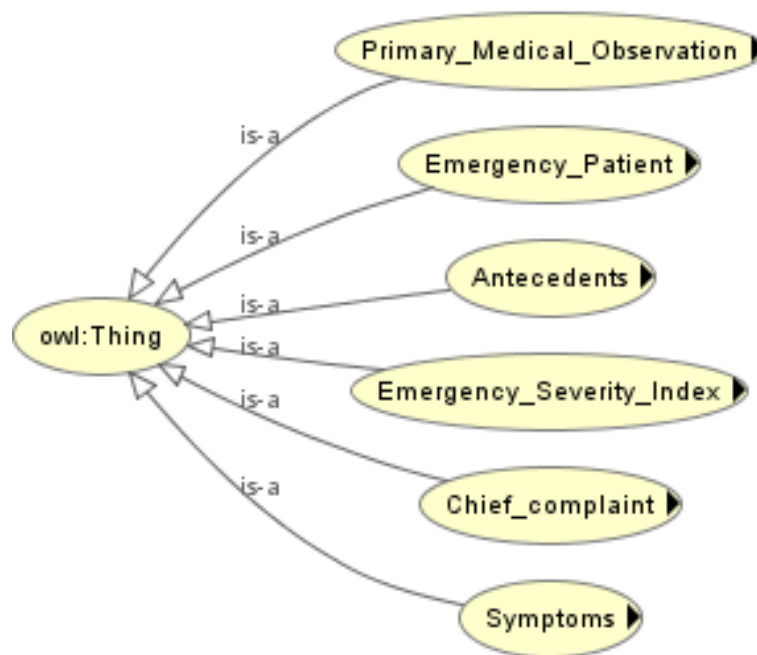


FIGURE 4.5 – Les classes génériques de l'ontologie OntoTris



Propriétés des objets	Domaine	Range
has symptoms	Emergency patient	Symptoms
has arrival mode	Emergency patient	Arrival mode
Has severity index	Emergency patient	ESI
has chief complaint	Emergency patient	Chief complaint
has state	Emergency patient	Patient state
has wait time	Emergency patient	Waiting time

TABLEAU 4.3 – Aperçu des propriétés d'objets définis dans OntoTriS

Propriétés des données	Domaine	Range
has age	age	Integer
has temperature	temperature	Real
has MRI exam	MRI exam	Boolean
has cardiac rate	cardiac rate	Real
has saturation	saturation	Real
has biology exam	biology exam	Boolean

TABLEAU 4.4 – Aperçu des propriétés des données définies dans OntoTriS

les classes et les relations définies dans notre ontologie du domaine de triage sont validées par des médecins urgentistes, nous pouvons décrire tous ces éléments à l'aide du langage OWL. Les tableaux 4.3 et 4.4 présentent un aperçu des propriétés des objets et des propriétés des données définies dans l'ontologie proposée :

- Les propriétés des données sont chargées de décrire les relations entre les instances (individus) et les valeurs des données.
- Les propriétés d'objets, quant à elles, sont chargées de décrire les relations entre les classes.

Chaque propriété est chargée de définir les relations entre les concepts du domaine afin de créer des scénarios de cas de patients dans le processus de triage (cf. section ??). Nous définissons ainsi les connaissances dans le domaine du triage hospitalier par des concepts et leurs relations, tels que les observations médicales, les symptômes et le motif de venue. Chaque concept définit l'information médicale. En outre, grâce à la description de chaque concept, nous pouvons gérer l'imprécision, standardiser et traiter les données textuelles non structurées pour formuler des résultats plus précis et pertinents.

Ces propriétés sont créées pour définir les relations sémantiques et les données. Afin d'exploiter ces concepts dans un système d'aide à la décision et d'obtenir des résultats adéquats, nous définissons le vocabulaire des urgences en utilisant des règles sémantiques et en assurant une description détaillée de scénarios de cas réels de prises en charges de patients. Cette partie fonctionnelle de l'ontologie est définie dans la sous-section suivante.

**4.4.1.2.3 Niveau des cas de OntoTriS** Le niveau des cas présente la base de données des urgences sous une forme ontologique. Chaque cas est décrit par un scénario de prise en charge d'un patient aux urgences. En effet, le système proposé définit chaque cas de patient arrivant aux urgences comme un couple (Patient/Décision). Selon ce modèle, le patient, la plainte principale, les symptômes, l'observation médicale et les antécédents présentent la partie « Patient » et la partie « Décision » est représentée par le degré de sévérité des patients. Notre base de données

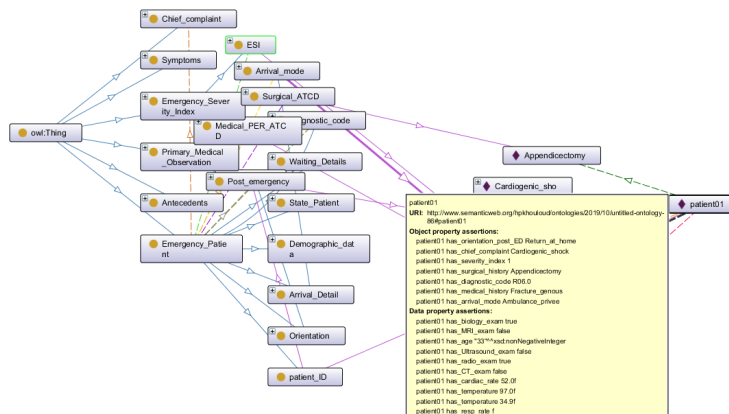


FIGURE 4.6 – Niveau de cas d’OntoTriS

médicale est transformée en une base de données ontologique en conservant les mêmes données et attributs et en les représentant comme des connaissances. La base de cas ontologique présente le niveau le plus bas de l’ontologie où chaque scénario de cas est décrit en utilisant les propriétés et les classes du modèle de domaine (cf. section 4.4.1.2.2). La Figure 4.6 représente la structure correspondante, qui est inspirée de l’approche utilisée dans (FAKHFAKH, MAALEL et FARHAT 2019).

#### 4.4.1.3 Le fonctionnement de l’ontologie OntoTris

La partie fonctionnelle de l’ontologie permet de faire le lien avec le modèle de données. Chaque concept médical est représenté par une description logique dans l’ontologie. En effet, la logique descriptive (DL), est une famille de langage de représentation des connaissances qui peut être utilisée pour représenter les connaissances terminologiques d’un domaine d’application de manière formelle et structurée. Le nom de logique descriptive fait référence, d’une part, à la description des concepts utilisés pour décrire un domaine et, d’autre part, à la sémantique basée sur la logique qui peut être donnée par une transcription en logique des prédicats du premier ordre.

Les définitions des concepts médicaux sont validées par les médecins urgentistes. Ainsi, les données textuelles non structurées telles que les symptômes, les antécédents médicaux, la plainte principale et les observations médicales seront présentés avec la DL pour automatiser sa compréhension et son traitement par la machine. Nous définissons donc les concepts de l’ontologie avec des expressions logiques. Dans le tableau 4.5, nous définissons pour chaque axiome correspondant à un concept, sa description en langage naturel, les attributs utilisés dans l’axiome, le nom du concept auquel l’axiome fait référence et l’expression logique.

L’ontologie OntoTriS contient un vocabulaire scientifique qui définit le système de triage dans le cadre d’une prise en charge au service des urgences. Cette dernière englobe donc toutes les données cliniques, démographiques et historiques des patients qui ont déjà été pris en charge aux urgences et sont donc déjà passé par le processus de triage. La figure 4.7 ci-dessous illustre le schéma ontologique global qui présente les classes et les sous-classes d’OntoTriS.

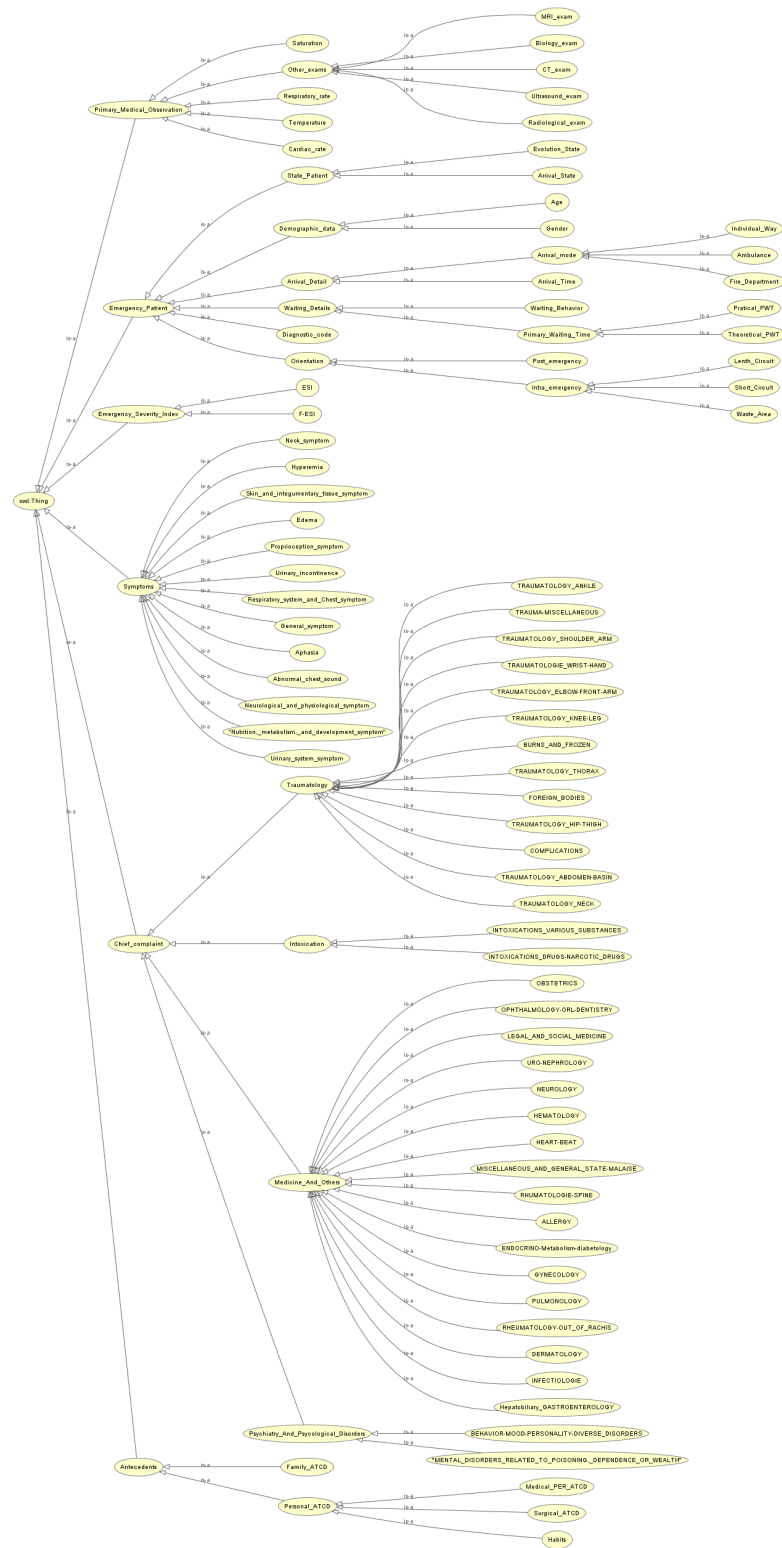


FIGURE 4.7 – Le schéma global d'OntoTriS

Concepts	Description	Expression logique
Vital signs	Les indicateurs de santé des patients tels que : La pression artérielle systolique, la fréquence cardiaque et la fréquence respiratoire	$\forall(X), \text{Vital signs}(X) \Rightarrow \text{Systolic Blood pressure}(X) \vee \text{Heart Frequency}(X) \vee \text{Respiratory Frequency}(X) \vee \text{Body Temperature}(X) \vee \text{Pain Level}(X) \vee \text{Electrocardiogram}(X) \vee \text{Glasgow\_Score}(X) \vee \text{Peripheral\_O2\_saturation}(X)$
Antecedents	Représente l'historique médical d'un patient qui regroupe les antécédents familiaux et les antécédents personnels.	$\forall(X), \text{Antecedents}(X) \Rightarrow \text{Family ATCD}(X) \vee \text{Personal ATCD}(X)$
Systolic Blood pressure	Correspond à la pression du sang dans les artères. Elle est exprimée par la mesure systolique	$\forall(X), \text{Systolic Blood pressure}(X) \Rightarrow \text{Systolic}(X)$
Heart frequency	Représente le nombre de battements cardiaques (ou pulsations) par unité de temps. Elle peut-être : Bradycardie, tachycardie ou fréquence cardiaque normale	$\forall(X), \text{Heart frequency}(X) \Rightarrow \text{Bradycardia}(X) \vee \text{Tachycardia}(X) \vee \text{HF\_Normal}(X)$
Respiratory frequency	C'est le nombre de cycles respiratoires par minute. Il s'agit soit d'une Bradypnée, soit d'une Tachypnée, soit d'une fréquence respiratoire normale	$\forall(X), \text{Respiratory frequency}(X) \Rightarrow \text{Bradypnea}(X) \vee \text{Tachypnea}(X) \vee \text{RF-Normal?}(X)$

TABLEAU 4.5 – Aperçu des axiomes et concepts définis dans OntoTriS

Comme précisé précédemment, cette ontologie permet structurer les informations liées au processus de triage aux urgences dans le but de l'optimiser. Elle est basée sur l'évaluation de l'état de sévérité d'un patient au moment de son arrivée en se basant sur un score. Plusieurs scores existent dans la littérature et chaque pays peut utiliser un modèle de score différent, mais le principe de triage reste quasiment le même. Dans le cadre de cette étude, nous nous basons sur le score ESI (l'équivalent du CCMU utilisé en France) pour proposer une version plus fine de ce score basée sur la logique floue (cf. section ??), que nous baptisons F-ESI 1.0 pour Fuzzy-ESI 1.0. Nous détaillons ce score dans ce qui suit.

#### 4.4.1.4 Le score F-ESI 1.0 proposé

Le score F-ESI-1.0 (Fuzzy-ESI 1.0) est une extension du score ESI. Il représente un score plus précis en considérant conjointement 4 éléments : l'âge, la plainte principale ou le motif

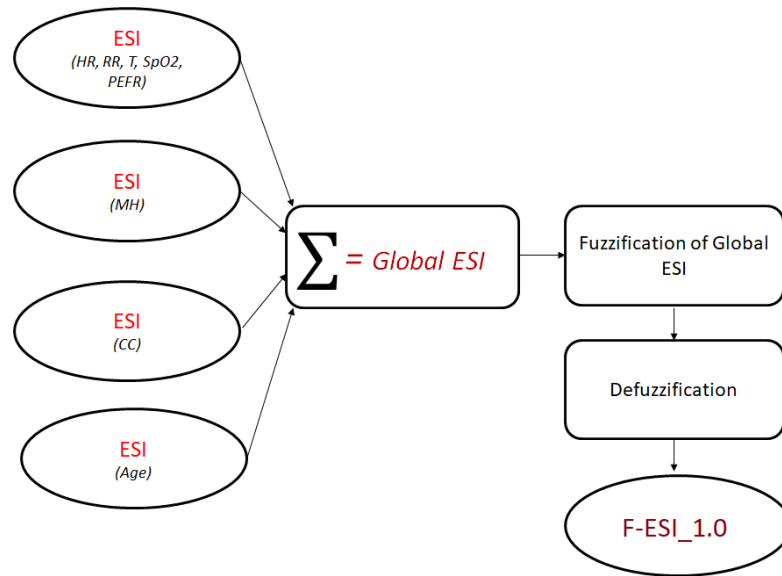


FIGURE 4.8 – Processus de génération du score F-ESI 1.0

de venue (CC), les antécédents médicaux (MH) et l'ESI (eq. CCMU). Le score ESI est utilisé à l'échelle internationale par plusieurs pays dans le cadre de la prise en charge des patients au service des urgences. Ce score permet de mesurer l'état du patient au moment du triage. Il est calculé avec un algorithme basé sur la fréquence cardiaque (FC); la fréquence respiratoire (RR); la température (T); l'oxymétrie de pouls (SpO2) et le débit expiratoire de pointe (PEFR) (WUERZ et al. 2001).

Le F-ESI-1.0 proposé est défini par la fuzzification de l'ESI global des quatre éléments sus-indiqués, c'est-à-dire l'âge, le motif de venue, les antécédents médicaux et l'ESI classique. Toutes ces données médicales sont les références nécessaires pour définir l'état de santé d'un patient lors du triage selon les médecins des urgences. Cependant, les scores utilisés jusqu'aujourd'hui ne tiennent pas en compte tous ces éléments. Par conséquent, en collaboration avec le personnel soignant du CHU de Lille, médecins urgentistes et infirmiers de triage, nous proposons un nouvel indicateur ESI, basé sur l'ESI global ESIG (cf. figure 4.8), plus précis que l'original puisqu'il prend en compte d'autres informations primordiales à la décision au niveau du triage aux urgences. Ces informations sont stockées dans l'ontologie pour être utilisées par le raisonneur sémantique. L'ESI global (ESIG) de chaque patient est élaboré en 3 étapes (cf. figure 4.8) :

- **Étape 1** : identifier l'ESI de chaque information médicale spécifique pour un patient  $i$  en utilisant l'ontologie et les requêtes SPARQL. Pour l'âge (l'élément A) : nous formalisons la requête SPARQL suivante :

```

PREFIX OntoTriS: <http://www.w3.org/2002/07/owl#>
SELECT ?PatientX ?age
WHERE {?PatientX OntoTriS:has_age ?age.}
  
```

Puis, nous identifions le  $ESI_A^i$  (Tableau 4.6) comme suit : L'ontologie OntoTriS nous permet d'identifier le score  $ESI_A^i$  en utilisant la règle SWRL suivante :

ESI <sub>A</sub> <sup>i</sup>	1	2	3	4	5
Age	>80	[66,80]	[50,65]	[36,49]	[18,35]

TABLEAU 4.6 – Identification d'ESI<sub>A</sub><sup>i</sup>

OntoTriS:Patient(?X) ∧ OntoTriS:age(?Y) ∧ OntoTriS:has\_age(?X,?Y) ∧ swrlb:greaterThan(?Y,?80) ⇒ OntoTriS:ESI(?1) ∧ OntoTriS:has\_severity\_index(?X,?1).

**Pour le Motif de venue (l'élément CC) :** nous formalisons la requête SPARQL suivante :

```
PREFIX OntoTriS: <http://www.w3.org/2002/07/owl#>
SELECT ?PatientX ?Chief_complaint
WHERE {?PatientX OntoTriS:has_chief_complaint ?chief_complaint.}
```

Puis, nous identifions le ESI<sub>cc</sub><sup>i</sup> selon la catégorie de spécialité médicale de la maladie (Tableau 4.7)

ESI <sub>cc</sub> <sup>i</sup>	1	2	2	4	5
CC	(unconscious +cardiac +neuro +pneuma+...)	(conscious +cardiac +neuro+...)	(neuro or cardiac+ trauma+...)	(Cardiac+...)	autre mala- die

TABLEAU 4.7 – Identification d'ESI<sub>cc</sub><sup>i</sup>

L'ontologie OntoTriS nous permet d'identifier l'indice ESI<sub>cc</sub><sup>i</sup> en utilisant la règle SWRL suivante :

OntoTriS:Patient(?X) ∧ OntoTriS:Chief\_complaint(?Y) ∧ OntoTriS:has\_Chief\_complaint(?X,?Y) ∧ swrlb:equal(?Y,?cardiac) ∧ swrlb:equal(?Y,?neurologic) ∧ swrlb:equal(?Y,?pneumologic) ∧ swrlb:equal(?Y,?unconscious) ⇒ OntoTriS:ESI(?1) ∧ OntoTriS:has\_severity\_index(?X,?1).

**Pour les antécédents (l'élément MH) :** nous formalisons la requête SPARQL suivante :


```
PREFIX OntoTriS: <http://www.w3.org/2002/07/owl#>
SELECT ?PatientX ?Antecedents
WHERE {?PatientX OntoTriS:has_antecedent ?Antecedents.}
```

Puis, nous identifions le ESI<sub>MH</sub><sup>i</sup> en se basant sur la classification infirmière des malades aux urgences (CIMU<sup>1</sup>) (Annexe 1).

**Pour l'ESI classique (l'élément CCMU) :** nous trouvons le score en utilisant la requête SPARQL suivante pour extraire ce score établi par les personnels de santé comme l'âge et les autres éléments.

```
PREFIX OntoTriS: <http://www.w3.org/2002/07/owl#>
SELECT ?PatientX ?ESI
WHERE {?PatientX OntoTriS:has_severity_index ?ESI.}
```

1. Classification infirmière des malades aux urgences

FIGURE 4.9 – Fuzzification de F-ESI 1.0 (l'axe des abscisses est  $ESI_g$ )

- **Étape 2 :** Calculer la somme de toutes les ESI identifiés pour un patient  $i$  de chaque élément, c'est-à-dire : l'âge ( $ESI_A^i$ ), le motif de venue ( $ESI_{cc}^i$ ), les antécédents ( $ESI_{MH}^i$ ) et l'ESI ( $ESI_{ccmu}^i$ ), pour trouver l'ESI global  $ESI_g^i$  (tableau 4.8).

$$ESI_g^i = ESI_A^i + ESI_{cc}^i + ESI_{MH}^i + ESI_{CCMU}^i$$

- **Étape 3 :** Fuzzifier l'ESI global trouvé ( $ESI_g^i$ , c'est-à-dire calculer le degré d'appartenance selon la classe trouvée et défuzzifier pour trouver le nouveau F-ESI\_1.0 correspondant dans le tableau 4.8 (Figure 4.9).

ESI global	$[0, 6[$	$]4,9[$	$]7, 12[$	$]10,15[$	$13<$
F-ESI_1.0	1	2	3	4	5
ESI Level	Réanimation	Emergent	Urgent	Moins Urgent	Non urgent
Fonction de fuzzification	Left shoulder function	Trapezoidal function	Trapezoidal function	Trapezoidal function	Right shoulder function

TABLEAU 4.8 – Le calcul du score F-ESI 1.0

Le choix des fonctions de fuzzification est basé principalement sur le type de l'ensemble flou pour chaque classe. Par exemple, si l'ESI global appartient à l'intervalle  $]7, 12[$ , donc la fonction de fuzzification est Trapezoidal. En collaboration avec des médecins urgentistes, nous avons défini les intervalles des classes floues qui présentent les classes d'ESI global ( $ESI_g$ ). Nous avons ensuite généré le nouveau score F-ESI 1.0 après avoir appliqué les processus de fuzzification et de défuzzification.

Les algorithmes de prédiction des admissions ou de triage (cf. chapitre 5) sont basés sur des connaissances cliniques, comme la température, la fréquence cardiaque et des observations médicales définies par le personnel de soin et les patients comme le degré de la douleur, le degré de conscience et les symptômes. Toutes ses informations sont parfois imprécises et incertaines.

Pour cela, nous proposons dans la section suivante une ontologie floue FOTS qui est basée sur des concepts flous afin de pouvoir gérer les connaissances imparfaites et améliorer leur qualité.

## 4.4.2 L'ontologie FOTS proposée

Dans cette section, nous proposons une nouvelle méthode pour développer une ontologie floue puis nous définissons l'ontologie FOTS « *Fuzzy Ontology for Triage System* » et son fonctionnement.

### 4.4.2.1 La méthode FOnToM proposée pour le développement des ontologies Floues

Comme évoqué précédemment, nous proposons dans la cadre d'une thèse des ontologies informatiques qui correspondent à des outils permettant de représenter, d'une manière précise, un corpus de connaissances, sous une forme utilisable par la machine. Les ontologies floues sont destinées à représenter aussi bien des notions précises que des notions floues. Etant d'un grand intérêt pour divers domaines, elles traitent les connaissances imprécises et incertaines en définissant les concepts flous. Il existe plusieurs techniques pour développer de telles ontologies (EL-SAPPAGH et al. 2014) mais qui restent basiques car elles ne sont pas suffisantes pour construire des ontologies floues (ZHANG et al. 2013).

De nombreuses méthodes sont disponibles pour générer des ontologies floues telles que map fuzzy model (ZHANG et al. 2013), FuzzyOntoMethodology (MAÂLEJ et al. 2010), FONTO (Fuzzy for ONTOlogy) (AKREMI et al. 2016), FOGA (Fuzzy Ontology Generation FrAme-work) (QUAN, HUI et CAO 2004). La différence entre ces approches réside principalement dans les aspects de l'ontologie classique (ontologie non floue) qui sont fuzzifiés, et ces aspects dépendent des besoins du domaine. Cependant, les approches mentionnées ne garantissent pas l'encodage des concepts flous et la construction d'ontologies de domaine flou en intégrant ces concepts. Pour cela, nous proposons une nouvelle méthode qui consiste à fuzzifier une ontologie en se basant sur la théorie des sous-ensembles flous de manière automatique. Cette méthode permet de définir tous les concepts précis et flous du domaine. Dans ce contexte, la fuzzification est un processus de transformation d'une ontologie précise en une ontologie floue dans le but de modéliser des formes d'incertitude.

Dans le cadre de cette thèse, la méthode proposée **FOnToM** permet de répondre aux besoins du domaine médical qui contient un vocabulaire et des connaissances très complexes. Elle est inspirée de la méthode **Methontology** (FERNÁNDEZ-LÓPEZ, GÓMEZ-PÉREZ et JURISTO 1997) en y ajoutant la méthode de fuzzification **FONTO** (AKREMI et al. 2016) pour définir les concepts flous de l'ontologie. Cette méthode est basée sur la modélisation de trois parties principales : **le modèle conceptuel**, **le modèle de domaine flou** et **le modèle de cas et de raisonnement** (cf. Figure 4.10).

La Figure 4.10 présente les différentes étapes de la méthode FOnToM proposée :

1. La spécification : cette étape a pour objectif de fournir une description claire du glossaire cible, en définissant les concepts principaux.
2. La conceptualisation : permet l'organisation et la structuration des connaissances acquises au niveau de l'étape précédente en développant un modèle conceptuel.
3. La formalisation : permet la création du modèle conceptuel développé au niveau de l'étape précédente, en utilisant un langage ontologique formel.



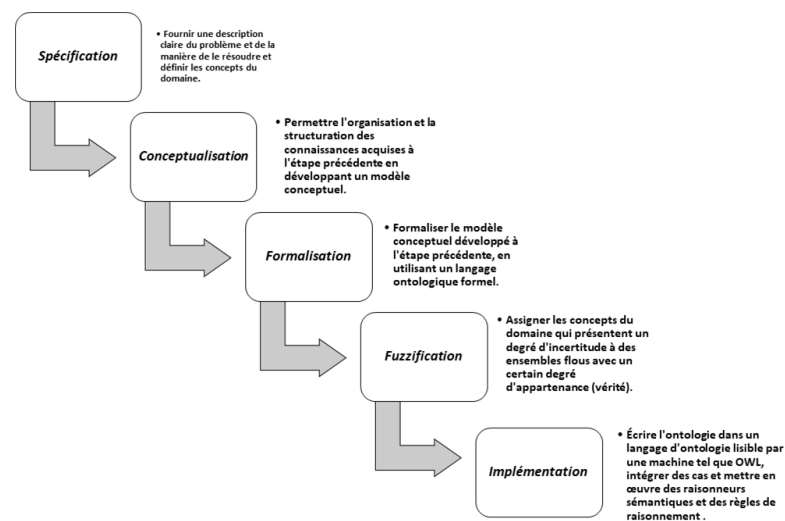


FIGURE 4.10 – La méthode FOntoM proposée pour le développement d'ontologies floues (FAKHFAKH et al. 2021a)

4. La fuzzification : assigne les concepts du domaine qui présentent un degré d'incertitude à des ensembles flous avec un certain degré d'appartenance (Vérité).
5. L'implémentation : permet d'écrire l'ontologie dans un langage ontologique compréhensible par une machine tel que OWL 2 ; intégrer les cas et implémenter les raisonneurs sémantiques et les règles de raisonnement.

La méthode **FOntoM** proposée permet la création à la fois des concepts flous et précis, comme le montre la Figure 14. La spécificité de cette méthode est qu'une boucle itérative est réalisée entre les étapes de **formalisation** et de **fuzzification**, de manière à ce que la sortie de cette boucle ne soit validée que si tous les concepts du domaine flou sont définis. Comme sus-indiqué, nous avons choisi la méthode FONTO (AKREMI et al. 2016) pour la fuzzification. Cette dernière est composée de trois phases successives : l'**extraction des concepts flous**, la **détermination des classes floues de l'ontologie** et le **calcul des degrés d'appartenance**. Cette méthode permet de traiter les connaissances imprécises et vagues grâce à des valeurs seuils représentant les différentes modalités possibles, d'assurer une modélisation quantitative des connaissances et de codifier et affiner les connaissances mal définies. Le processus de fuzzification consistedonc à modéliser un ensemble de concepts flous en se basant sur la théorie de la logique floue (cf. section 2.6.4.1).

#### 4.4.2.2 Ontologie proposée FOTS « Fuzzy Ontology for Triage System »

Dans cette section, nous commençons par présenter l'ontologie FOTS et ses fonctionnements avant de définir le nouveau score que nous proposons : le score F-ESI 2.0. Il s'agit d'une extension du score F-ESI 1.0 (cf. section 4.4.1.4). En effet, nous intégrons des concepts non flous pour calculer l'ESI global puis nous effectuons la fuzzification de  $ESI_g$ . Par contre, F-ESI 2.0 prend en

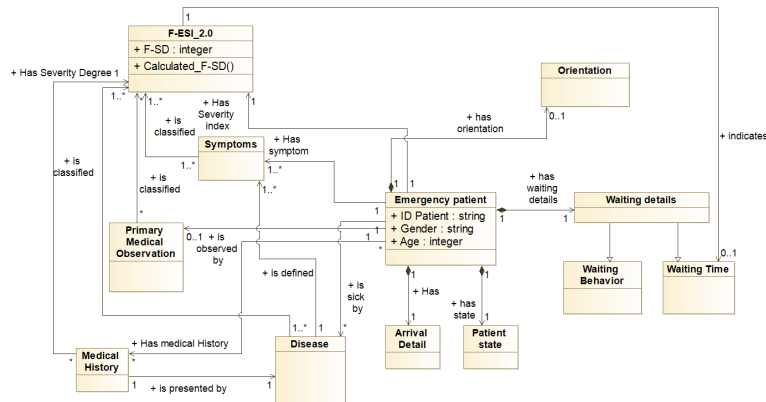


FIGURE 4.11 – Le diagramme de classe de l'ontologie FOTS

considération des concepts flous dans le calcul degré de sévérité.

**4.4.2.2.1 La structure de l'ontologie FOTS** Comme évoqué précédemment, afin de contre-carrer les limites l'ontologie OntoTriS (cf. section 4.4.1), nous faisons évoluer cette dernière en proposant l'ontologie FOTS qui est une ontologie floue qui se présente donc comme une extension de l'ontologie OntoTriS. Pour développer FOTS, nous utilisons la méthode FOntoM (cf. section 4.4.2.1). L'ontologie FOTS possède donc des concepts précis qui sont les mêmes concepts définis dans OntoTriS. Cette ontologie est ainsi composée de trois modèles : un **modèle conceptuel**, un **modèle de domaine flou** et un **modèle de raisonnement et de cas**. Nous détaillons chaque modèle dans ce qui suit.

**4.4.2.2.1.1 Le modèle conceptuel** La figure 4.11 représente le modèle conceptuel proposé par un diagramme de classes UML (EL-SAPPAGH et ELMOGY 2017). Ce modèle conceptuel permet d'exprimer le processus de triage en définissant ses différents acteurs et les relations entre ces derniers. Les classes de ce schéma (cf. figure 4.11) définissent les principaux éléments dont dépend l'état de santé des patients et qui influencent la gestion de l'hôpital et la prise de décision clinique ultérieure. Les classes génériques de ce modèle sont présentées dans la suivante (cf. Tableau 4.9).

Chaque concept dans ce diagramme de classe présente une classe dans le modèle de domaine flou de FOTS. Nous détaillons ce modèle dans ce qui suit.

**4.4.2.2.1.2 Le modèle de domaine flou** Ce modèle représente les connaissances floues du domaine selon le modèle conceptuel défini dans la section précédente. Nous décrivons notre ontologie FOTS en langage OWL2 et la développons en collaboration avec le personnel du CHU. Le modèle générique de FOTS contient 7 classes ou concepts principaux présentés dans le tableau 4.9 ci-dessous : **Emergency patient**, **Chief complaint**, **Disease**, **Fuzzy Emergency Severity Index** (cf. section 4.4.2.2), **Medical Observation**, **Symptoms** et **Medical History**. La classe racine de ces sept classes est la classe Thing. En effet, le domaine flou de FOTS contient

Classes générique	Description
Emergency patient	Toutes les données spécifiques d'un patient telles que les données démographiques, le mode d'arrivée, le temps d'attente et le mode d'attente
Chief complaint	Définit les motifs de venue des patients
Disease	La liste de toutes les maladies des patients qui arrivent au SUA.
Fuzzy Emergency Severity Index	Un indice de gravité flou qui indique l'état de sévérité d'un patient au moment de son arrivée au SUA.
Primary Medical Observation	Les signes vitaux et cliniques observés et révélés par le personnel soignant.
Symptoms	La liste des symptômes liés aux patients des SUA.
Medical History	Les antécédents médicaux pour chaque patient du SUA.

TABLEAU 4.9 – Une description détaillée des classes génériques (ontologie FOTS)

Propriétés des objets	Domaine	Range
has symptoms	Emergency patient	Symptoms
Is sick by	Emergency patient	Disease
Has severity index	Emergency patient	F-ESI 2.0
Has defined by	Symptoms	Disease, Vital signs
has severity degree	Vital signs	Severity degree
has medical history	Emergency patient	Medical History

TABLEAU 4.10 – Aperçu des propriétés d'objets définis dans FOTS

deux niveaux d'abstraction des connaissances que nous pouvons qualifier par des connaissances de haut niveau et des connaissances profondes :

- Le niveau générique (connaissances haut niveau) : contient les concepts génériques du domaine ED (tableau 4.9).
- Le niveau du domaine flou (connaissances profondes) : décrit le champ de triage lié à la gravité du patient définie par les propriétés et concepts de FOTS dans la sous-section suivante.

Dans le niveau du domaine flou, nous utilisons des ontologies médicales standard telles que les ontologies SYMP et ICD (cf. section 2.5.1) pour construire une ontologie du domaine médical selon le dictionnaire « **Medical Dictionary of Health**<sup>2</sup> » pour définir les concepts du domaine. Bien évidemment, les médecins urgentistes ont validé tous les concepts intégrés et les relations entre ces derniers. Le tableau 4.10 présente un aperçu des propriétés d'objets définis dans FOTS permettant de faire les liens entre les objets. Tous ces éléments sont ensuite définis avec le langage OWL 2 sous forme d'une ontologie physique. Chaque propriété est chargée de définir les relations entre les concepts du domaine afin de créer des scénarios de cas de patients dans le processus de triage. La Figure 4.12 représente la structure complète de l'ontologie FOTS. Cette dernière inclut les concepts et les relations flous, tels que les observations médicales, les symptômes et les maladies, qui sont initialement définis par des données incertaines et des connaissances imprécises dans le domaine du triage hospitalier.

En effet, chaque concept flou décrit des informations médicales incertaines en définissant des fonctions d'appartenance (SBPN) pour identifier les limites inférieures et supérieures de chaque concept et ses intervalles de confiances. Grâce à la description floue, nous pouvons gérer cette incertitude et formuler des résultats plus précis et corrects. Dans ce contexte, les axiomes logiques définissent les concepts en se basant les expressions logiques. Le tableau 4.11 ci-dessous contient un aperçu des axiomes flous pour la description formelle des concepts flous qui sont définis dans

2. <https://www.health.harvard.edu/a-through-c>

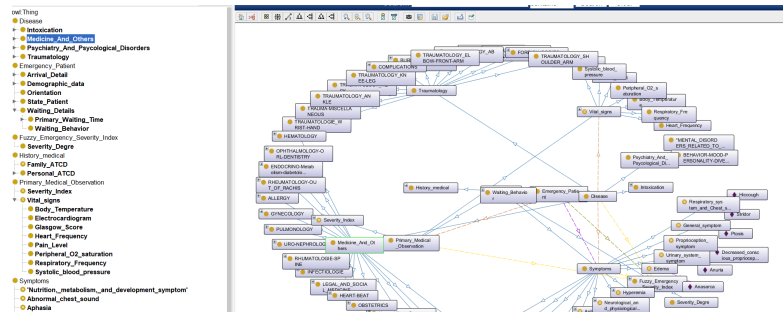


FIGURE 4.12 – La structure de l’ontologie FOTS

le cadre de l’ontologie FOTS. Il s’agit des expressions mathématiques qui permettent de calculer le degré d’appartenance des instances aux concepts et aux relations floues. Afin de définir les concepts flous, trois éléments sont créés pour chacune des caractéristiques numériques : **un rôle abstrait** (c’est-à-dire une propriété de données), **un type de données flou** pour chaque terme linguistique (concept flou) et **un rôle concret flou** (c’est-à-dire une propriété d’objet) pour chaque terme linguistique.

Concepts flous	Description	Expression logique
Systolic_BP_Normal	La pression maximale au moment de la contraction du cœur. Sa fonction d’appartenance est : SBPN (90, 100, 120, 130)	$SBPN(Value) = 1$ if $Value \in [100 - 120[$ ou $SBPN(Value) = \frac{(Value-90)}{(100-90)}$ if $Value \in [90 - 100 [$ ou $SBPN(Value) = \frac{(130-Value)}{(130-120)}$ if $Value \in [120 - 130 [$ ou $SBPN(Value) = 0$ elsewhere
Hyper-Systolic_BP	Lorsque la pression maximale au moment de la contraction cardiaque est comprise entre : ]140 - 180[ la fonction d’appartenance est : SBPN (120, 130, 180)	$SBPN(Value) = 1$ if $Value \in [130 - 180[$ ou $SBPN(Value) = \frac{(Value-120)}{(130-120)}$ if $Value \in [120 - 130 [$ ou $SBPN(Value) = 0$ elsewhere
Heart frequency_Normal	Le nombre de battements cardiaques (ou pulsations) par unité de temps (généralement une minute). Sa fonction d’appartenance est : SBPN (60, 70, 90, 100)	$SBPN(Value) = 1$ if $Value \in [70 - 90[$ ou $SBPN(Value) = \frac{(Value-60)}{(70-60)}$ if $Value \in [60 - 70 [$ ou $SBPN(Value) = \frac{(100-Value)}{(100-90)}$ if $Value \in [90 - 100 [$ ou $SBPN(Value) = 0$ elsewhere

TABLEAU 4.11 – Aperçu des axiomes et concepts définis dans OntoTriS

Par exemple, si nous considérons le concept de la saturation périphérique en oxygène, la plage des valeurs acceptables est de [0,99], les termes linguistiques applicables sont les suivants : Très sévère [VSS (0, 86)], Sévère [SS (85, 86, 91)], Peu fatigué [LTS (90, 91, 95)], et Normal [NS (94, 99)].

Tout d’abord, nous créons un rôle abstrait nommé PSatO2. Ensuite, un type de données floues est créé pour chacun de ces termes flous et enfin, nous définissons des rôles concrets flous :




FIGURE 4.13 – Exemple d'un type de donnée flou

Propriété floue	Domaine	Range	Terme linguistique	Syntaxe DL	Type FA	FA
Has Systolic_BP_Normal	Emergency patient	Systolic_BP_Normal	Normal	Blood pressure $\sqcap \sup$ Normal_max pressure	Trapezoidal	SBPN (90, 100, 120, 130)

TABLEAU 4.12 – Exemple d'une propriété floue dans FOTS

hasVSS\_PSatO2, hasSS\_PSatO2, hasLTS\_PSatO2 et hasNS\_PSatO2. Les types de données floues définis précédemment sont utilisés comme plages pour ces rôles. Comme le montre la figure 4.13 ci-dessous, un plugin "Fuzzy Protégé" a été utilisé pour créer le type de données floues VSS\_PSatO2.

Le tableau 4.12 montre un exemple de propriété floue. Ce tableau donne un aperçu des propriétés signalées pour chaque concept flou non numérique. Ces propriétés sont créées afin de définir des relations sémantiques et des données. Afin d'exploiter ces concepts flous dans un système d'aide à la décision et d'obtenir des résultats pertinents, nous définissons des raisonneurs flous et des règles sémantiques assurant une description détaillée des scénarios de cas réels. Ainsi, nous définissons le modèle de raisonnement et de cas FOTS dans ce qui suit.

**4.4.2.2.1.3 Le modèle de raisonnement et de cas** Après la création du modèle de domaine flou (cf. section 4.4.2.2.1.2), nous définissons les raisonneurs pour transformer le modèle en une ontologie fonctionnelle et l'intégrer dans un système d'aide à la décision. Ce modèle fournit une description détaillée pour chaque scénario de cas de patient du service des urgences contenant toutes les données liées à la prise en charge.

Nous décrivons les différentes relations entre les concepts médicaux flous et précis dans notre ontologie FOTS et mettons en place le modèle de cas en définissant des scénarios de cas réels de patients. En fait, les descriptions logiques floues sont des extensions des logiques de description classiques (STRACCIA 2001). Elles ont été proposées comme des langages capables de représenter et de raisonner sur des connaissances vagues ou imprécises. Ainsi, nous utilisons le raisonneur de logique de description floue (DL flou) pour définir l'indice de gravité de chaque cas de patient sur la base des concepts définis. Dans ce contexte, nous appliquons la règle de disjonction floue pour définir et fusionner les concepts pour chaque symptôme et nous identifions les extrémités de degré de sévérité (la valeur minimale et la valeur maximale) afin de trouver un indice précis.

**4.4.2.2.2 Le score F-ESI 2.0 de l'ontologie FOTS** L'indice de gravité F-ESI\_2.0 proposé est basé sur un indice de degré de sévérité (SD) qui mesure le niveau de gravité de chaque donnée

Degré de sévérité (SD)/ état patient	État stable	État modéré	État urgent	État très urgent
$SD_{age}$	0	1	2	3
$SD_{MH}$	0	1	2	3
$SD_{Symptoms}$	0	2	4	8
$SD_{MO}$	0	2	4	8

TABLEAU 4.13 – le SD calculé pour le F-ESI 2.0

Age	[18,40]	[38,55]	[54,76]	>75
$SD_{age}$	0	1	2	3

TABLEAU 4.14 – Le calcul du  $SD_{age}$  (ontologie FOTS)

clinique (les symptômes, les motifs de venue, l'âge et les antécédents médicaux). Ce score présente un concept primordial et l'output de notre ontologie FOTS. Il est défini par la fuzzification du SD total de quatre concepts médicaux qui sont l'âge, les symptômes, les antécédents médicaux et les observations médicales. Ces concepts sont les références primaires pour définir l'état de santé d'un patient lors du triage selon les experts de santé. En se basant sur le score CCMU et en collaboration avec le personnel de santé, nous proposons donc le nouveau score flou F-ESI 2.0 qui calcule l'état de sévérité des patients arrivant en urgence comme indiqué dans le tableau 4.13. Ce score présente une extension du score F-ESI 1.0 (cf. section 4.4.1.4). Ce dernier n'exploite les capacités de la logique floue qu'à la fin du processus mais dans F-ESI 2.0, tous les concepts exploités sont flous issus d'une ontologie floue.

Les 3 étapes suivantes permettent de générer le F-ESI\_2.0 pour chaque patient :

- **Étape 1** : Calculer le SD pour chaque concept médical en fonction des données cliniques existantes. Le  $SD_x$  définit le niveau de degré de sévérité pour chaque concept médical  $x$ . Nous détaillons le calcul du SD pour chaque concept comme suit :

Pour l'âge : Le  $SD_{age}$  définit le SD lié à l'âge du patient. Pour le calculer, nous utilisons le Tableau 4.14 suivant.

En se basant sur le tableau 4.14, FOTS identifie le  $SD_{age}$  en utilisant la requête SPARQL suivante :

```
PREFIX FOTS: <http://www.w3.org/2002/07/owl#>
SELECT ?SD,
WHERE {? PatientX FOTS:has_age ?age ,
      ?Age FOTS:has_severity_degre ?Severity_Degre .}
```

Pour les symptômes : L'ontologie FOTS contient une liste des symptômes. Toujours en collaboration avec le personnel de santé, nous proposons de les classer en 4 catégories selon le niveau de degré de sévérité. Le tableau 4.15 présente un aperçu de cette classification que nous utilisons pour identifier le SD des symptômes ( $SD_{symptoms}$ ).

En basant sur le tableau 4.15, FOTS identifie le  $SD_{symptoms}$  en utilisant la requête suivante :

```
PREFIX FOTS: <http://www.w3.org/2002/07/owl#>
SELECT ?SD,
WHERE {? PatientX FOTS:has_symptoms ?symptoms ,
      ?Symptoms FOTS:has_severity_degre .
      ?Severity_Degre (SD==(max(SDsymptom)) .)}
```

$SD_{symptoms}$	0	2	4	8
Symptômes	Douleur aux dents, constipation, touse, mal à la gorge, ..	Fièvre, Apathie, Aftes, Douleurs abdominales, Diarrhée, ...	Abcès, Amnésie, Acidocétose, Arythmie cardiaque, Dyspnée, ...	Céphalée, Inconscient, Hypoglycémie, Difficulté respiratoires, Herpès, ...

TABLEAU 4.15 – la classification des symptômes et leurs degrés de sévérité

$SD_{MH}$	0	1	2	3
Antécédents	1 et 2	3	4	5

TABLEAU 4.16 – Le calcul de  $SD_{MH}$ 

La fonction  $\max(SD_{symptoms})$  est nécessaire car un patient peut avoir plusieurs symptômes. Antécédents médicaux : L'identification du SD des antécédents ( $SD_{MH}$ ) suit le même principe du calcul de  $ESI_{MH}^i$  (4.4.1.4). Ce dernier est basé sur la classification infirmière des malades aux urgences (CIMU) (Annexe 1). La seule différence entre les deux indices est que le calcul du  $SD_{MH}$  est établi selon 4 niveaux et le  $ESI_{MH}^i$  est sur 5 catégories. Pour cela, nous proposons de fusionner le 1er et le 2ème niveau de CIMU et nous gardons les autres niveaux (Tableau 4.16).

En se basant sur le tableau 4.16 ci-dessus, l'ontologie FOTS identifie le  $SD_{MH}$  en utilisant la requête suivante :

```
PREFIX FOTS: <http://www.w3.org/2002/07/owl#>
SELECT ?SD,
WHERE {?PatientX FOTS:has_antecedent ?Antecedents ,
      ?Antecedents FOTS:has_severity_degre .
      ?Severity_Degre (SD==(max(SDMH)) . }
```

La fonction  $\max(SD_{MH})$  est déployée puisqu'un même patient peut avoir plusieurs antécédents. Le SD qui correspond à l'antécédent le plus dangereux est donc choisi.

Observations médicales : Les observations médicales correspondent aux données cliniques telles que : la température, la fréquence cardiaque, la fréquence respiratoire, la pression artérielle systolique et la saturation d'oxygène O<sub>2</sub>. Donc l'identification du SD des observations médicales ( $SD_{MO}$ ) est basée sur ces signes cliniques.

FOTS identifie le  $SD_{MO}$  en utilisant des requêtes SPARQL et des règles SWRL (Tableau 4.17). En effet, la requête suivante est capable d'extraire la listes des observations en identifiant le SD maximal.

```
PREFIX FOTS: <http://www.w3.org/2002/07/owl#>
SELECT ?SD,
WHERE {?PatientX FOTS:has_medical_observation ?Medical_Observation ,
      ?Medical_Observation FOTS:has_severity_degre .
      ?Severity_Degre (SD==(max(SDMo)) . }
```

Par contre le calcul de  $SD_{MO}$  est basé principalement sur les règles SWRL.

Par exemple, pour calculer le SD de fréquence respiratoire, nous utilisons la règle suivante :  
 $FOTS:Patient(?X) \wedge FOTS:Respiratory\_Rate(?Y) \wedge OntoTriS:has\_respiratory\_rate(?X,?Y) \wedge swrlb:greaterThan(?Y,?50) \Rightarrow FOTS:SDMO(?8) \wedge OntoTriS:has\_SDMO(?X,?8)$ .

$SD_{MO}$	0	2	4	8
Température	[36, 38.4]	[38, 38.9] ou [34, 35.9]	[39, 40.9] ou [32, 33.9]	$T > 41$ ou $T < 32$
Fréquence cardiaque	[70, 109]	[55, 69] ou [110, 139]	[40, 54] ou [140, 179]	$FC < 40$ ou $FC > 180$
Fréquence respiratoire	[12, 34]	[10, 11] ou [25, 34]	[35, 49] ou [6, 9]	$FR < 6$ ou $FR > 50$
Pression artérielle systolique	[80, 149]		[55, 79] ou [150, 189]	$PAS < 55$ ou $PAS > 190$
Saturation O2	[94, 98]	[90, 93]	[85, 90]	$SaO_2 < 84$

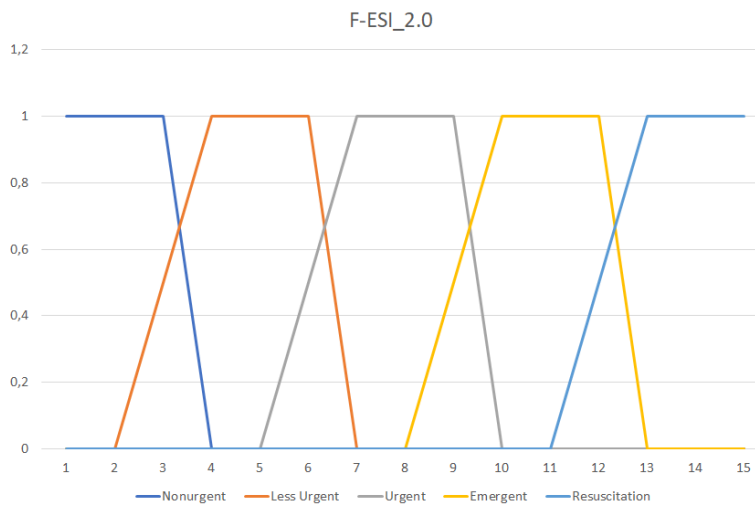
TABLEAU 4.17 – Le calcul de  $SD_{MO}$  (ontologie FOTS)

FIGURE 4.14 – Le modèle flou de F-ESI 2.0

Pour la règle ci-dessus, la fréquence respiratoire est prise comme exemple. Le SD est donc calculé pour tous les éléments médicaux de cette observation médicale (mentionnés dans le tableau 4.17). Puis, nous retenons que Le SD maximal de toute les observations médicales pour le modèle F-ESI 2.0.

- **Étape 2** : Calculer la somme des degrés de sévérité flous (F-SD). Ce score est calculé en appliquant la formule suivante où  $i$  définit un patient :

$$F-SD = SD_{age}^i + SD_{cc}^i + SD_{MH}^i + SD_{CCMU}^i$$

- **Étape 3** : En utilisant les concepts flous, nous trouvons le degré d'appartenance en fonction de la classe trouvée et le F-ESI\_2.0 correspondant (cf. Figure 4.14). Les fonctions floues sont sélectionnées en fonction de l'intervalle des données floues. Les classes floues correspondantes sont présentées dans le tableau 4.18. Pour le calcul de la gravité concernant les symptômes et les observations médicales, nous nous appuyons sur des documents médicaux scientifiques (GAZZAH-URGENTISTE s. d.) qui sont ensuite validés par les médecins urgentistes. Comme indiqué précédemment, en collaboration avec le



F-SD	[0, 4[	]2,7[	]5, 10[	]8,13[	11<
F-ESI_2.0	5	4	3	2	1
ESI Level	Réanimation	Emergent	Urgent	Moins Urgent	Non urgent
Fonction de fuzzification	Left shoulder function	Trapezoidal function	Trapezoidal function	Trapezoidal function	Right shoulder function

TABLEAU 4.18 – Le calcul du score F-ESI 2.0

personnel de santé, nous sélectionnons des classes floues qui présentent le F-SD total pour les éléments qui influencent l'état du patient. Nous avons donc sélectionné l'âge, la raison de la venue ou symptômes, les antécédents et les observations médicales des infirmier(ère)s. Ainsi, le F-ESI 2.0 peut être un outil puissant pour mesurer l'état de gravité des patients, nous pourrions évaluer son efficacité en le testant avec un système d'aide au triage basé sur l'ontologie FOTS.

Théoriquement, ce score proposé peut donner des résultats plus performants que les scores existants car il correspond à un modèle flou qui prend en considération les données imprécises et incertaines, contrairement au score actuel utilisé aujourd'hui dans les hôpitaux. De plus, ce nouveau score proposé prend en compte tous les éléments médicaux dont les antécédents médicaux qui ne sont pas considérés dans les scores existants. Afin de rendre l'ontologie FOTS fonctionnelle, nous devons l'intégrer dans un système d'aide à la décision au triage (SADT).

#### 4.4.3 L'ontologie EDOMO proposée

Dans cette partie, nous présentons d'abord l'ontologie EDOMO qui sert à définir et anticiper les situations de tension dans les SUs et aider le personnel de soins à bien les gérer. Puis, nous définissons le score proposé pour évaluer précisément les situations d'urgence. Comme c'est le cas de l'ontologie OntoTriS (cf. section 4.4.1), l'implémentation d'EDOMO est également basée la méthode « Methontology » (FERNÁNDEZ-LÓPEZ, GÓMEZ-PÉREZ et JURISTO 1997). Nous détaillons chaque partie de cette nouvelle ontologie proposée dans ce qui suit.

##### 4.4.3.1 Méthodologie de développement de l'ontologie

En se basant sur la méthodologie « Methontology » [8], les quatre étapes suivantes ont été nécessaires pour le développement de l'ontologie EDOMO :

- **Spécification** : Fournir une description claire du vocabulaire cible, en identifiant les concepts du domaine tels que patients, les indicateurs de performances du SU et le score ESI.
- **Conceptualisation** : Organiser et structurer les connaissances acquises dans l'étape de spécification en créant un modèle conceptuel et un glossaire du domaine.
- **Formalisation** : Traduire le modèle conceptuel et le glossaire développés dans l'étape de conceptualisation en utilisant un langage ontologique formel.
- **Implémentation et validation** : Construire l'ontologie en utilisant le langage OWL 2 et le plugin « Protégé », intégrer la base de données et des scénarios de situations de tension,

Classes	Description
Situation	Présente la classe générique de l'ontologie et définit les scénarios de différentes situations normales ou d'encombrement aux urgences.
Causes	Définit les facteurs qui peuvent augmenter le risque des situations de tension aux urgences.
Patients	Présente des données spécifiques sur les patients qui arrivent aux urgences .
Overcrowding classes	Classifie les différentes situations en fonction de leur niveau de tension.
Solution	Propose des mesures préventives ou correctives pour aider le personnel soignant à bien gérer les situations de tension.
Evaluation	Permet l'évaluation précise d'une situation de tension à un moment donné selon des indicateurs de performance (cf. section 4.4.3.3) bien définis.
Context	Définit l'environnement interne et externe du service des urgences.

TABLEAU 4.19 – Les concepts principaux d'EDOMO

créer des raisonneurs sémantiques et la base des règles SWRL.

#### 4.4.3.2 Les modèles de l'ontologie EDOMO

L'ontologie EDOMO est composée de trois modèles : **modèle de domaine**, **modèle de cas** et **modèle de raisonnement**. Nous décrivons chaque modèle dans les sous-sections suivantes.

**4.4.3.2.1 Modèle de domaine** L'ontologie EDOMO contient un seul concept générique qui correspond à la classe « Situation » avec ses six sous-classes principales qui définissent les différentes situations d'urgence : « Patients », « Causes », « Overcrowding Classes » (les classes de tension), « Context », « Solution » et « Evaluation ». La classe racine de ces classes est la classe « Thing » (Tableau 4.18). Les classes OWL2 sont réalisées comme des ensembles d'individus (ou ensembles d'objets) et la classe Thing représente la classe racine contenant tous les individus (ABEYSIRIWARDANA et KODITUWAKKU 2012). Dans ce contexte, EDOMO contient deux niveaux d'abstraction des connaissances que nous pouvons qualifier de **connaissances générales** et de **connaissances profondes** :

- Le niveau générique : contient les principaux concepts qui décrivent les différentes situations de tension dans le SUA (Tableau 4.19).
- Le niveau du domaine : décrit le SUA, ses acteurs, les causes et conséquences de la tension et les indicateurs qui aident à évaluer l'encombrement. Ce niveau est défini par des propriétés et des concepts médicaux et non médicaux (Figure 4.15).

Pour définir les concepts du domaine, nous nous sommes appuyés sur le dictionnaire médical standard des urgences ainsi que sur le dictionnaire médical de la santé en collaboration avec le personnel médical du CHU. Ces derniers ont pu valider l'ontologie avant son implémentation avec le langage OWL 2. Le tableau 4.20 présente un aperçu des propriétés définies dans EDOMO. Chaque propriété dans EDOMO est chargée de définir les relations entre les classes afin de créer des scénarios réels de situations de tension aux urgences. Ainsi, les données et connaissances dans le domaine des urgences, telles que le contexte, l'évaluation de la tension et les patients, sont définies par des concepts de domaine et des relations entre ces derniers. La Figure 4.16 présente le schéma global de l'ontologie où chaque concept de domaine définit les informations qui peuvent influencer l'environnement des urgences. Comme le montre cette figure, l'ontologie EDOMO considère des combinaisons d'indicateurs exacts ou estimé ; exacts comme la capacité du service des urgences à un instant  $t$ , et estimés, comme les prévisions climatiques.



FIGURE 4.15 – Les classes de l'ontologie proposée EDOMO

Les propriétés de EDOMO	Types	Domaine	Ranges
has_performance_indicator	Object property	Situation	Performance indicators
is_defined_by	Object property	Overcrowding_classes	Overcrowding_score
is_evaluated_by	Object property	Situation	Evaluation
has_temperature	Data property	temperature	float
has_patient_admitted number	Data property	Patients_admitted	int
has_doctors_number	Data property	Doctors	int

TABEAU 4.20 – Aperçu des propriétés définies dans EDOMO



FIGURE 4.16 – Schéma global de l'ontologie EDOMO

**4.4.3.2 Modèle de cas** En suivant la même structure de l'ontologie OntoTriS (cf. section 4.4.1), nous développons l'ontologie EDOMO qui définit les situations de tensions aux urgences et les solutions qui peuvent être déployées par le personnel de santé pour gérer ces situations. En effet, EDOMO fournit un modèle de cas qui présente une description détaillée pour chaque scénario identifié de situation de tension aux urgences. Il s'agit ici de scénarios contenant les données d'arrivées des patients, les ressources matérielles du service et les données climatiques et environnementales. Comme décrit précédemment, nous modélisons les différentes relations entre les concepts du domaine dans notre ontologie EDOMO et mettons en place le modèle de cas en définissant des scénarios de situations réelles issues de l'historique de l'urgence. Pour améliorer la communication entre le modèle de cas et le modèle de domaine, nous intégrons ces situations dans l'ontologie par le biais des propriétés des données et des objets (Figure 4.17).

**4.4.3.2.3 Modèle de raisonnement** Après avoir créé le modèle de domaine et le modèle de cas, nous définissons le modèle de raisonnement pour réaliser une ontologie fonctionnelle et l'intégrer dans un système d'aide à la décision. Nous créons les règles SWRL pour décrire tous les scénarios possibles des situations de tension dans SU. Ceux-ci sont intégrés dans l'ontologie résultante pour raisonner sémantiquement sur la base de règles, par exemple :  $EDOMO:Situation(?S) \wedge EDOMO:Overcrowding\_score(?Y) \wedge EDOMO:is\_evaluated\_by(?S,?Y) \wedge swrlb:lessThanOrEqual(?Y, "25") \wedge swrlb:greaterThanOrEqual(?Y, "15") \Rightarrow EDOMO:Overcrowding\_classes(EDOMO:Critical\_state)$  En effet cette règle prédit la situation de tension en se basant sur les indicateurs de performances définis dans l'ontologie EDOMO.

De plus, ce modèle fournit des règles qui évaluent et règlent les situations de tension en proposant des solutions pour aider le personnel soignant à bien les gérer. Ainsi, chaque règle est décrite avec les propriétés et les instances définies dans l'ontologie proposée. Elle est basée sur des

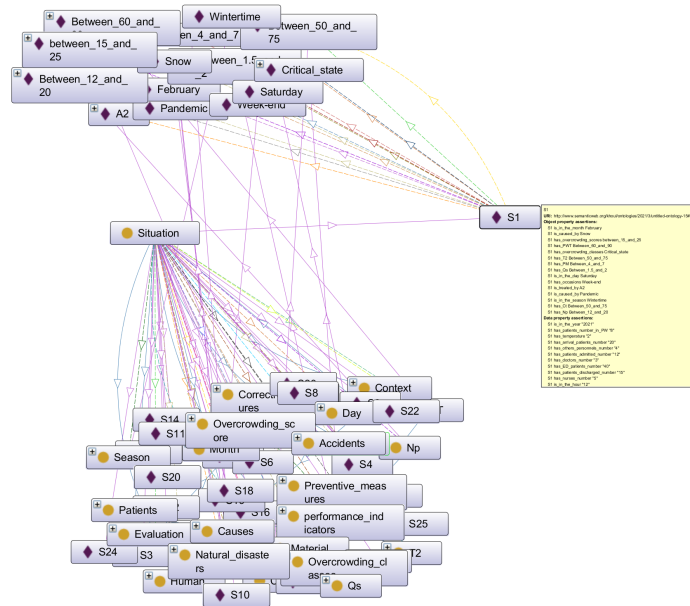


FIGURE 4.17 – Un aperçu du modèle de cas et son lien avec le modèle de domaine

indicateurs de performance pour donner une évaluation précise. La base de règles ainsi définie a été validée par le personnel de santé du CHU avec lequel nous collaborons. L'exploitation des règles sémantiques peut également être utilisée pour gérer les données manquantes.

#### 4.4.3.3 Identification des IPC pertinents basée sur EDOMO

Les indicateurs de performance clés (IPC) définis dans EDOMO sont des indicateurs de performance qui assurent l'évaluation des SUA en se basant sur des données cliniques et réelles. Ces indicateurs présentent un élément essentiel pour évaluer la situation du service à l'instant  $t$  et donc prévoir la situation à l'instant  $t+1$ . Le calcul de chaque indicateur se fait grâce à l'ontologie EDOMO en utilisant les règles SWRL pour le calcul et les requêtes SPARQL pour l'extraction des informations pertinentes nécessaires. Les indicateurs de performance mesurables que nous avons sélectionnés et validés avec les personnel soignant sont présentés ci-dessous, ils sont basés sur les travaux de Kadri (KADRI [2014](#)) :

- **PWT** : il s'agit du temps d'attente entre la prise en charge par l'hôtesse d'accueil ( $T_e$ ) et le premier examen médical ( $T_c$ ). Cet indicateur est très important car l'augmentation du temps d'attente (de plus que 5 heures) provoque une situation de tension. Nous calculons le PWT comme suite :

$$PWT = T_c - T_e$$

L'extraction et le calcul de cet indicateur est établi à travers la règle SWRL suivante :

```
EDOMO :Patient(?P) ∧ EDOMO :Te(?Y) ∧ EDOMO :Tc(?W) ∧ EDOMO :has_arrived_in
(?P,?Y) ∧ EDOMO :has_arrived_in (?P,?W) ∧ swrlb:subtractDayTimeDurations (?T,?Y,?W)
```

⇒ EDOMO :PWT (?T) Cette règle assure le calcul du temps de la prise en charge PWT en se basant sur EDOMO.

- **T2** : cet indicateur présente le temps d'attente entre la prise en charge par l'hôtesse d'accueil (Te) et la consultation infirmière de triage (Tnc).

$$T_2 = T_e - T_{nc}$$

Cet indicateur est calculé par la règle SWRL suivante :

EDOMO :Patient(?P) ∧ EDOMO :Te(?Y) ∧ EDOMO :Tnc(?W) ∧ EDOMO :has\_arrived\_in(?P,?Y) ∧ EDOMO :has\_arrived\_in(?P,?W) ∧ swrlb :subtractDayTimeDurations(?T,?Y,?W)  
 ⇒ EDOMO :T2 (?T) Cette règle assure le calcul du temps d'attente en se basant sur EDOMO.

- **Np** : C'est le nombre de patients déjà présents au SUA lors de l'arrivée d'un nouveau patient. Cet indicateur est calculé par la requête suivante :

```
PREFIX EDOMO: <http://www.w3.org/2002/07/owl#>
SELECT ?Np
WHERE {? ED_Patient EDOMO: has_in_ED Count(? ED_Patient) ,
      And ?Np == Count(? ED_Patient) .}
```

- **PM** : C'est le rapport entre le nombre de patients présents au SUA et le nombre de médecins (Nd) potentiellement disponibles à l'instant t. Puisque Nd évolue en fonction de la période de la journée, alors, PM est mis à jour à chaque variation de période. L'indicateur PM est donc calculé comme suit :

$$PM = \frac{N_d}{N_d}$$

Le calcul de PM est basé sur l'ontologie EDOMO et la règle SWRL suivante :

EDOMO :Np(?N) ∧ EDOMO :Nd(?d) ∧ swrlb :divide(?M,?N,?d) ⇒ EDOMO :PM (?M)

- **Qs** : c'est le rapport entre le temps de séjour réel à l'hôpital d'un patient ayant un état non-urgent (LOSactuel) et le temps de séjour théorique LOSth. En effet, le LOSth à l'hôpital correspond à une référence fixée à 210 minutes pour un patient ayant un état non-urgent.

$$Q_s = \frac{LOS_{actuel}}{LOS_{th}}$$

La règle SWRL suivante nous permet de calculer l'indicateur Qs :

EDOMO :LOSactuel(?X) ∧ EDOMO :LOSth(?Y) ∧ swrlb :divideDayTimeDurations(?T,?X,?Y)  
 ⇒ EDOMO :Qs (?T)

- **Ct** : c'est le pourcentage de la charge actuelle à l'instant t. Cet indicateur est défini par le rapport entre le nombre de patients présents dans le service des urgences et la capacité maximale de ce dernier (N), compte tenu des entrées et des sorties.

$$C_t = \frac{(N_e + N_e \sim N_e) * 100}{N}$$

Où pour un instant  $t$  :  $N_{at}$  est le nombre de patients arrivant aux urgences,  $N_{et}$  est le nombre de patients présents aux urgences et  $N_{st}$  le nombre de patients sortant. L'indicateur  $C_t$  est calculé par la génération de la règle SWRL suivante :

$$\text{EDOMO :Ne} (?e) \wedge \text{EDOMO :Na} (?a) \wedge \text{EDOMO :Ns} (?s) \wedge \text{EDOMO :N} (?a) \wedge \text{swrlb :add} (?k, ?e, ?a) \wedge \text{swrlb :subtract} (?l, ?k, ?s) \wedge \text{swrlb :divide} (?q, ?l, ?N) \wedge \text{swrlb :multiple} (?C, ?q, 100) \Rightarrow \text{EDOMO :Ct} (?C)$$

Tous ces indicateurs sont très importants pour identifier les situations de tension mais ils ne peuvent pas seulement donner des renseignements exacts de la situation à l'instant  $t$ .

De plus, les mesures préventives et correctives de tension sont créées suivant des niveaux de tensions, c'est-à-dire, plus la situation est critique, plus les mesures sont importantes et différentes en comparant avec le niveau précédent. Nous détaillons dans la suite la méthode proposée pour évaluer et gérer les situations de tension

#### 4.4.3.4 La gestion de la tension basée sur EDOMO

Dans cette partie, nous présentons notre nouveau score OES (Overcrowding Estimation Score) issu de l'ontologie EDOMO. Cet indicateur permet d'évaluer la situation de tension du SUA. La stratégie de gestion des situations de tension en se basant sur l'ontologie EDOMO, sera décrite par la suite.

**4.4.3.4.1 Le score OES proposé** Le score OES « Overcrowding Estimation Score » est proposé pour évaluer avec précision le niveau d'encombrement dans SUA. Ce score est calculé à partir des indicateurs de performance mentionnés précédemment (cf. section [4.4.3.3](#)). Nous calculons le score OES comme suit :

$$\text{OES} = \sum \text{RS}_k$$

Où  $K$  est le nombre d'indicateurs de performance pris en compte et  $\text{RS}_k$  (Score de risque) correspond à un indicateur qui évalue au fur et à mesure le degré et le niveau de risque d'un  $\text{IPC}_k$  ( $k \in [1, K]$ ). Dans ce contexte, nous proposons quatre classes pour décrire une situation de tension au SU à l'instant  $t$  selon le  $\text{RS}_k$  trouvé. Une situation peut être : normale, dégradée, critique ou très critique. Pour identifier chaque classe, nous nous basons sur des valeurs seuils de chaque IPC qui sont présentées dans le tableau ?? c-dessous.

Pour trouver le score OES, nous identifions d'abord le score de risque  $\text{RS}_k$  pour chaque indicateur de performance  $k$  présenté dans le tableau ?. Puis, en se basant sur le tableau ??, nous calculons les classes floues d'OES. Le  $\text{RS}_k$  est donné pour chaque indicateur de performance  $\text{IPC}_k$  en fonction de l'état du SUA à l'instant  $t$ .

L'OES est déduit en utilisant les règles SWRL en se basant sur l'ontologie EDOMO comme suit :

$$\text{EDOMO :Situation} (?H) \wedge \text{EDOMO :PM} (?X) \wedge \text{EDOMO :has\_risk\_score} (?X, ?t) \wedge \text{EDOMO :Ct} (?Y) \wedge \text{EDOMO :has\_risk\_score} (?Y, ?S) \wedge \text{EDOMO :Np} (?N) \wedge \text{EDOMO :has\_risk\_score} (?N, ?M) \wedge \text{EDOMO :PWT} (?F) \wedge \text{EDOMO :has\_risk\_score} (?F, ?D) \wedge \text{EDOMO :Qs} (?R) \wedge \text{EDOMO :has\_risk\_score} (?R, ?C)$$

K	IPC <sub>k</sub>	L'état de SUA			
		Normal	Degradé	Critiqué	Très critique
1	PWT	PWT<60	60<PWT<90	90<PWT<180	PWT>180
2	T2	T2<25	25<T2<50	50<T2<70	T2>70
3	Np	Np<12	12<Np<20	20<Np<40	Np>40
4	PM	PM<4	4<PM<7	7<PM<10	PM>10
5	Qs	Qs<0.8	0.8<Qs<1.5	1.5<Qs<2	Qs>2
6	Ct	Ct<50	50<Ct<75	75<Ct<120	Ct>120

TABLEAU 4.21 – Les valeurs seuils de chaque IPC

$\wedge$  EDOMO :T2(?P)  $\wedge$  EDOMO :has\_risk\_score(?P,?B)  $\wedge$  swrlb :add(?Z,?t,?S,?M,?D,?C,?B)  $\Rightarrow$  EDOMO :Overcrowding\_score(?Z)  $\wedge$  EDOMO :has\_overcrowding\_score(?H,?Z).

Nous présentons dans la suite les actions nécessaires pour gérer les situations de tension selon OES identifié.

L'état de SUA	Normal	Degradé	Critiqué	Très Critiqué
RS <sub>k</sub>	1	2	4	5
OES	]0, 7[	]6,15[	]14, 25[	]24,30[

TABLEAU 4.22 – L'identification du score OES

**4.4.3.4.2 Actions de gestion de la tension** Les actions de gestion de la tension sont décrites dans le (cf. section 1.3.3.5). La figure 4.18 ci-dessous représente les actions qui sont définies et identifiées par l'ontologie EDOMO et les règles SWRL.

De plus, les règles SWRL créées par les outils SWRLTAB et Protégé, sont générées avec le moteur d'inférence JESS. La base de règles qui définit les situations de tension et les actions recommandées contient 50 règles sémantiques (Figure 4.18).

Les règles SWRL sont proposées afin de recommander et aider le personnel de santé à bien gérer les situations de tension selon son niveau d'encombrement. Si la situation du SUA est normale, le système ne recommande aucune action sinon il propose des solutions pour éviter que la situation s'aggrave. Par exemple, nous présentons une règle SWRL qui recommande des actions correctives suite à une situation très critique : De plus, les règles SWRL créées par les outils SWRLTAB et Protégé, sont générées avec le moteur d'inférence JESS. La base de règles qui définit les situations de tension et les actions recommandées contient 50 règles sémantiques (Figure 13). Les règles SWRL sont proposées afin de recommander et aider le personnel de santé à bien gérer les situations de tension selon son niveau d'encombrement. Si la situation du SUA est normale, le système ne recommande aucune action sinon il propose des solutions pour éviter que la situation s'aggrave. Par exemple, nous présentons une règle SWRL qui recommande des actions correctives suite à une situation très critique :

EDOMO :Situation(?X)  $\wedge$  EDOMO :has\_overcrowding\_classes(?X,?Y)  $\wedge$  EDOMO :Overcrowding\_classes(EDOMO :Very\_critical\_state)  $\wedge$  EDOMO :is\_caused\_by(?X, EDOMO :Lack\_of\_staff)  $\wedge$  EDOMO :is\_caused\_by(?X, EDOMO :Massive\_increase\_in\_arrivals)  $\wedge$  EDOMO :is\_caused\_by(?X, EDOMO :Lack\_of\_hospital\_beds)  $\Rightarrow$  EDOMO :Corrective\_measures(EDOMO :A4)  $\wedge$  EDOMO :Corrective\_measures(EDOMO :Add\_a\_nurse\_for\_a\_given\_time)  $\wedge$  EDOMO :Corrective\_measures



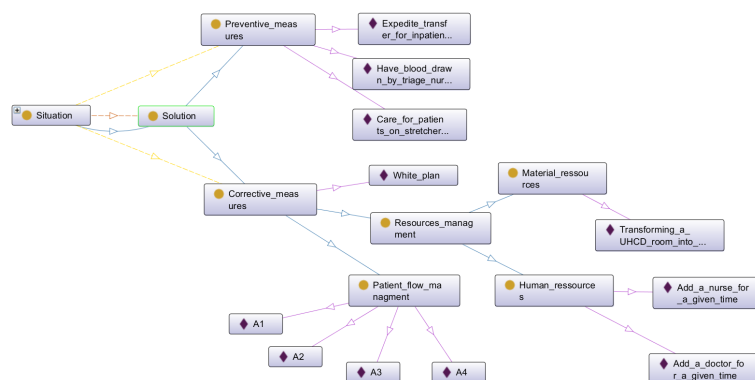


FIGURE 4.18 – Les actions de gestion de la tension définies par EDOMO

(EDOMO :Add\_a\_doctor\_for\_a\_given\_time) Cette règle définit les conditions de recommandations des actions pour gérer la tension. Notre base de règle de gestion de la tension est basée sur le score OES et sur d'autres indicateurs comme le nombre d'arrivées des patients, le temps d'attente et le nombre de personnel disponible à l'instant  $t$ . Comme indiqué précédemment, toutes ces informations sont extraites à travers notre ontologie EDOMO. En outre, à l'instant  $t+1$ , les informations sont prédites en se basant sur des algorithmes de ML présentés dans le chapitre suivant. Ces informations sont très utiles non seulement pour prédire le nombre d'arrivées au SUA, mais aussi l'admission des patients à l'instant  $t+1$ . La coordination entre EDOMO et ces algorithmes est basée sur la méta-ontologie OntoED que nous allons la présenter dans la suite. Les algorithmes de prédiction des admissions ou de triage sont basés sur des connaissances cliniques, comme la température, la fréquence cardiaque et des observations médicales définies par le personnel de soin et les patients comme le degré de la douleur, le degré de conscience et les symptômes. Toutes ses informations sont parfois imprécises et incertaines. Pour cela, nous proposons dans la section suivante une ontologie floue FOTS qui est basée sur des concepts flous afin de pouvoir gérer les connaissances imparfaites et améliorer leur qualité.

## 4.5 L'extraction des connaissances et Le pré-traitement des données médicales

L'architecture de notre modèle d'extraction d'information basé sur les ontologies proposées (cf. Figure 4.19) ci-dessous : A partir d'un fichier tableur représentant notre base de données, ce modèle proposé se base sur une procédure d'extraction des connaissances pour assimiler un ensemble d'attributs correspondant à des données textuelles, à partir desquelles il extrait les instances d'ontologie. Nous nous basons sur le concept du lexique sémantique pour identifier un sous-domaine sémantique pour le texte traité. Un lexique sémantique est essentiellement un ensemble de mots spécifiques à un domaine. Cet ensemble fait partie intégrante du vocabulaire du domaine. En revanche, un lexique usuel demeure un ensemble de mots qui n'est généralement pas spécifique à un domaine particulier. Par contre, un lexique sémantique est constitué de

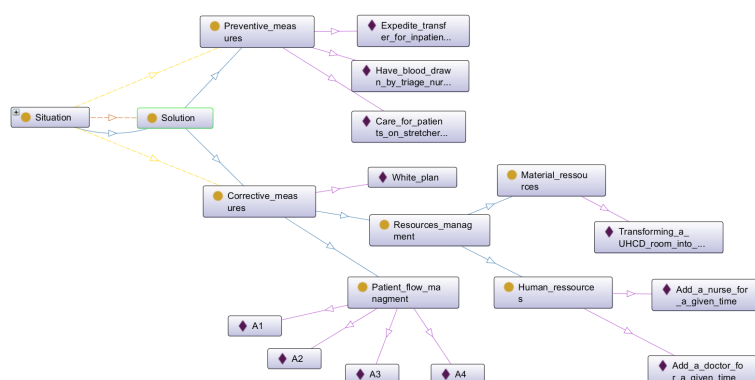


FIGURE 4.19 – Framework d'extraction des connaissances et d'informations cliniques basé sur OntoED

mots qui identifient un domaine de manière unique. C'est pour cette raison que nous avons déployé un lexique sémantique pour notre domaine particulier des urgences médicales. Ce dernier comprend des termes spécifiques comme ATCD pour les antécédents, symptômes, motifs de venue, etc.

Exemple d'un attribut textuel non structuré : : *Dyspnée aiguë et palpitations ATCDS : Appendicectomie Intervention au niveau des ligaments croisés du genou D Fracture du MIG en 1998 Ponction articulaire du genou gauche Avulsion des dents de sagesse Familiaux : aucun Allergies : NC TAD : aucun FDRCV : Poids à 95 kg taille 174 cm MDV : Fonctionnaire dans l'Education Nationale. Patient pratiquant régulièrement la course à pied. HDM : 2ème épisode dans l'année de crise paroxystique nocturne. Le 31/05/2016 vers 23 :30, 45 minutes après s'être couché, dyspnée aiguë insomniante avec sensation de mort imminente puis palpitations (battements réguliers rapides), signes neurovégétatifs, douleurs abdominales. Régression des symptômes à l'arrivée du SAMU (20 minutes après début de la crise).*...

Cet attribut textuel est fait partie de notre base de données clinique qui contient des informations très importantes pour le système proposé. Ce dernier nécessite donc un Framework d'Extraction des Connaissances (FEC) qui permet de extraire les informations pertinentes des données textuelles non structurées et les modéliser. Dans ce cadre, nous proposons une approche qui démarre par la lecture des attributs textuels et le déploiement d'un module d'inférence de domaine qui incorpore un lexique sémantique, pour identifier les concepts génériques et ses sous-concepts. La définition de ce lexique sémantique est bien entendu élaborée en collaboration avec le personnel de santé. Une fois les concepts identifiés pour un attribut donné, le module d'extraction extrait les informations de l'instance concernée, et crée un nœud RDF puis il assure la mise à jour de notre ontologie. L'API Jena est capable de générer des inférences sémantiques. Le lexique contient des règles pour apprendre de nouveaux symboles de lexique à partir du texte et les ajouter au lexique sémantique. Le module d'apprentissage du lexique utilise un ensemble d'heuristiques pour identifier les éléments lexicaux qui sont liés au lexique sémantique existant.

## 4.6 Conclusion

Dans ce chapitre, nous définissons l'architecture globale de la solution proposée (SATGT) dans le cadre de cette thèse qui est basée sur une approche d'IA hybride. Puis, nous décrivons la structure des trois ontologies proposées (OntoTriS, FOTS, EDOMO), les raisonneurs sémantiques utilisés qui aide au triage et à la prédiction de tension. Finalement, nous présentons le framework proposé pour l'extraction et le prétraitement des connaissances cliniques pertinentes en sa basant sur les ontologies. De plus, nous détaillons les scores de triage proposés qui permettent d'améliorer le processus de tri et rendre ainsi la classification des patients plus précise en réduisant le risque d'erreur. Aussi, nous proposons un nouveau score pour faciliter l'identification des situations de tension. Dans le chapitre suivant, nous présentons les algorithmes d'apprentissages qui décrivent le niveau de raisonnement de notre architecture et qui assurent l'aide à la décision clinique en appliquant l'IA hybride. Nous décrivons aussi dans cette partie les méthodes proposées pour améliorer la qualité des données et gérer leurs incertitudes.

# Approches et algorithmes d'apprentissage automatique appliqués aux urgences

## 5.1 Introduction

Dans le chapitre précédent, nous avons proposé l'architecture globale d'un système d'aide au triage et de gestion de tension au profit du personnel soignant. Cette architecture se base sur deux approches : symboliques et subsymboliques. Les approches symboliques permettent la représentation des connaissances et le raisonnement sémantique humain. Elles correspondent aux ontologies définies (cf. section 4.4) au niveau de la 1ère couche de l'architecture proposée (cf. section 4.2). Ce niveau est basé sur une base de règles et de connaissances qui sont capables d'extraire des informations pertinentes. Les approches subsymboliques correspondent aux techniques d'apprentissage automatique (ML) qui sont indispensables pour créer des modèles rationnels de prédiction et de prévision. De ce fait, nous devons maintenant décrire les algorithmes IA qui définissent la partie subsymbolique du niveau de raisonnement de l'architecture proposée. Dans ce chapitre, nous commençons d'abord par une étude statistique en analysant une base de données réelle (336254 patients) fournie par notre partenaire le CHU Lille. Nous nous focalisons sur les flux d'arrivées, le temps d'attente et l'admission post urgence afin d'identifier les principaux problèmes liés au fonctionnement du SUA. En se basant sur cette étude, nous proposons deux modèles de prédiction : un modèle pour l'admission à l'hôpital (dès l'arrivée du patient) et un autre modèle d'orientation post triage qui aide à déterminer le circuit adéquat pour un patient au SUA. De plus, nous proposons un modèle de prédiction du nombre d'arrivée à l'instant  $t + 1$  afin d'anticiper la tension. Tous ces modèles sont basés sur des techniques de ML afin de fournir un système intelligent qui optimise les SUA.

Num d'ordre	Date	Heure	Informations du passage	Informations du passage	IAO -> motif d'entrée	IAO -> motif de venue	Patient -> a	Antécéd
79310	79309	11/05/2017	10:46:00	jeudi 11 mai 2017 MOYENS PERSONNELS	Suspicion d'allergie avec oedème des bras Allergies: oedème de Quir			42
79311	79310	11/05/2017	10:50:00	jeudi 11 mai 2017 MOYENS PERSONNELS	IA zone dir avec oedème et rougeur m Cardologie: Pilsébate			27
79312	79311	11/05/2017	10:56:00	jeudi 11 mai 2017 AMBULANCE PRIVEE	Malaise sans PCI. Sensation de chaud-froid Cardologie: Malaise			71
79313	79312	11/05/2017	10:57:00	jeudi 11 mai 2017 MOYENS PERSONNELS	DA assis C. dir + paresthésie cuisse dite d Neurologie: Déficit neurop			66
79314	79313	11/05/2017	11:00:00	jeudi 11 mai 2017 AMBULANCE PRIVEE				55
79315	79314	11/05/2017	11:00:00	jeudi 11 mai 2017 MOYENS PERSONNELS	Dir lombaires ce matin en s'habillant. EVA Rhumatologie non traum			15
79316	79315	11/05/2017	11:02:00	jeudi 11 mai 2017 MOYENS PERSONNELS	Décompensation respi, toux grasse, AEG, Divers: AEG - Altération di			50 - BPCO
79317	79316	11/05/2017	11:03:00	jeudi 11 mai 2017 AMBULANCE PRIVEE				82
79318	79317	11/05/2017	11:05:00	jeudi 11 mai 2017 AMBULANCE PRIVEE	IA. zone AEG. dir. mbr inf ralentissement Divers: AEG - Altération di			53 cancer
79319	79318	11/05/2017	11:07:00	jeudi 11 mai 2017 AMBULANCE PRIVEE	DA zone déséquilibre diabète avec suspic Endocrin-métabolisme: I			55 HTA. Di
79320	79319	11/05/2017	11:16:00	jeudi 11 mai 2017 MOYENS PERSONNELS	Dir dorsales et lombaires chez patiente ay Rhumatologie non traum:			49 Lombalg
79321	79320	11/05/2017	11:18:00	jeudi 11 mai 2017 MOYENS PERSONNELS	IA CC. lésion dermato mains et pieds déj Dermatologie: Urticair			63
79322	79321	11/05/2017	11:20:00	jeudi 11 mai 2017 MOYENS PERSONNELS	Calaque néphrétique. Gastro-entérologie: Doule			28 RAS
79323	79322	11/05/2017	11:22:00	jeudi 11 mai 2017 MOYENS PERSONNELS	Poussée de psoriasis. EVA: 9 Dermatologie: Eruption bi			52 Arthrose
79324	79323	11/05/2017	11:30:00	jeudi 11 mai 2017 MOYENS PERSONNELS	IA. zone dir diffuses articulations synd rhumatologie non traum:			72
79325	79324	11/05/2017	11:36:00	jeudi 11 mai 2017 MOYENS PERSONNELS	Entorse de la cheville avec fracture polyfr Traumatologie: Traumat			49
79326	79325	11/05/2017	11:39:00	jeudi 11 mai 2017 AMBULANCE PRIVEE	DA ZONE malaise sy PCI Cardologie: Malaise			23
79327	79326	11/05/2017	11:40:00	jeudi 11 mai 2017 AMBULANCE PRIVEE				56
79328	79327	11/05/2017	11:47:00	jeudi 11 mai 2017 AMBULANCE PRIVEE	Dir jambe G sur Guillaïn barré. EVA: 8 Rhumatologie non traum:			19 syndrom
79329	79328	11/05/2017	12:01:00	jeudi 11 mai 2017 MOYENS PERSONNELS	AEG sur déséquilibre de diabète. EVA: mo Endocrin-métabolisme: I			61 DNID de
79330	79329	11/05/2017	12:02:00	jeudi 11 mai 2017 MOYENS PERSONNELS	Dir de les jambes avec instabilité à la mar Rhumatologie non traum:			23

FIGURE 5.1 – Aperçu de la base de données réelles (2016-2020) de CHU de Lille

## 5.2 Analyses statistiques des données cliniques

Dans cette section, nous présentons une étude statistique des données réelles sur quatre ans « juin 2016 - juin 2020 » (extraction par le logiciel ResUrgences<sup>1</sup>) (Figure 5.1). Cette étude permet de déterminer des indicateurs clés de tension aux urgences et définir les modèles de prédiction qui peuvent optimiser la gestion de la tension en s'appuyant sur quatre axes importants : l'affluence des patients, le temps d'attente, la classification CCMU et l'admission des patients.

### 5.2.1 Les flux d'arrivées au SUA

Les situations de tension sont fortement liées à l'affluence des patients. Afin d'analyser cette relation et ainsi identifier les facteurs de tension, nous mettons en évidence l'affluence des patients selon différentes échelles (l'heure, le jour et le mois) (Figures 5.2, 5.3 et 5.4). Les trois courbes présentent la moyenne de l'affluence des patients sur les quatre ans (2016-2020). La figure 5.2 montre une alternance jour et nuit avec des pics journaliers à midi, à 15 heures et à 20 heures. Ensuite nous pouvons constater dans la figure 5.3 la présence de deux pics, le premier est en début de semaine et le deuxième en début de weekend. Cette représentation reflète également une baisse du nombre des patients au SUA au cours de la semaine et le dimanche. En somme, il existe bien une fluctuation du nombre des patients présents au SUA en fonction du jour de la semaine. Ces pics entraînent une hausse de la pression et du rythme au SUA. Concernant l'affluence des patients par mois, la figure 5.4 indique que la période critique d'arrivée des patients se situe globalement pendant la période hivernale (entre décembre et février) et une stabilité et baisse de la fréquentation pendant le reste de l'année. En effet, l'hiver aide à générer d'avantages de maladies (comme la grippe saisonnière) et des accidents. Par conséquent, nous pouvons conclure que l'heure, le jour et le mois de l'arrivée des patients au SUA sont des facteurs à prendre en considération. Néanmoins, l'utilisation de l'indicateur d'affluence des patients tout seul ne peut pas prouver l'existence d'une situation de tension sur une période. Pour cela, nous intégrons dans notre étude d'autres indicateurs pour pouvoir cerner les périodes d'encombrement dans le SUA comme la classification CCMU (Triage), le temps d'attente et l'hospitalisation post urgence.

1. L'éditeur de ce logiciel est Berger Levraut qui est notre partenaire industriel dans le projet ANR OIILH.




FIGURE 5.2 – l’affluence des patients par heure




FIGURE 5.3 – l’affluence des patients par jour




FIGURE 5.4 – l’affluence des patients par mois

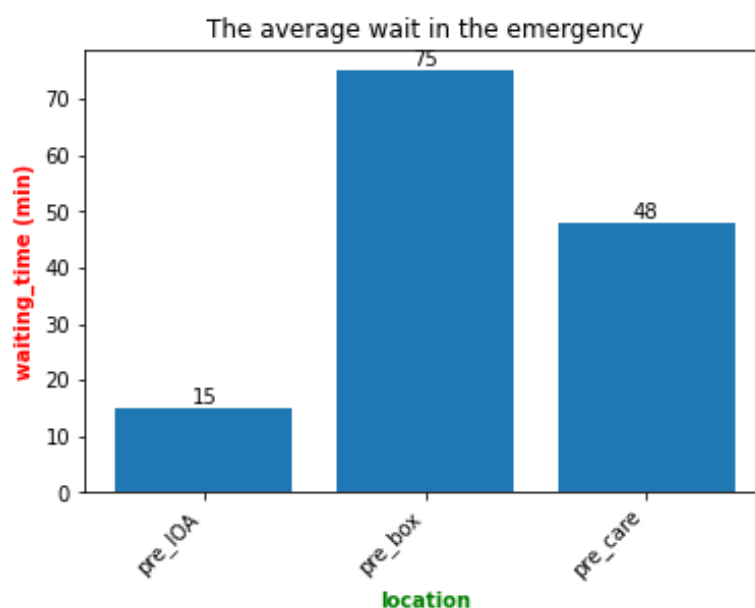


FIGURE 5.5 – La moyenne du temps d'attente par localisation

## 5.2.2 Le temps d'attente au SUA

En analysant notre base de données, nous observons que le temps d'attente entre le moment d'entrée au SUA et le moment de triage est en moyenne de 15 minutes (figure 5.5). Ensuite, un patient doit attendre en moyenne 75 minutes pour pouvoir entrer en box. Enfin, la moyenne d'attente après l'entrée dans un box pour pouvoir bénéficier d'un acte médical est de 48 minutes. Ce qui nous permet de conclure que le temps d'attente primaire (avant la 1<sup>ère</sup> consultation) présente la durée la plus longue. De plus, selon (AJMI 2021), 40% des patients attendent moins d'une heure et le reste dépasse une heure d'attente avant la 1<sup>ère</sup> consultation. La moyenne du temps d'attente primaire étant de deux heures. Pour mieux analyser le temps d'attente, nous nous attardons sur un autre facteur qui est l'heure d'admission. En effet, la figure 5.6 nous montre que le temps d'attente est élevé entre midi et minuit. Pendant cette période, le nombre d'admission est important. Le SUA doit donc faire face à une saturation du service due à l'augmentation de l'affluence des patients. Cette augmentation provoque l'allongement du temps d'attente pour les patients.

## 5.2.3 Classification CCMU

Dans cette étude, nous constatons que le score CCMU<sup>2</sup> (cf.section 1.3.2) prédominant est le 2 (figure 5.7). Le score 2 regroupe les patients non urgents qui ont une situation clinique qui ne nécessite pas forcément l'établissement d'examen médicaux complémentaires tels que les IRM et scanners. Ce qui peut impliquer une durée de séjour (DTS) plus courte. La figure 5.8 décrit la relation entre la durée de séjour et le score CCMU. En effet, cette relation montre que le niveau de gravité clinique de patient influence l'indicateur DTS; plus le patient est dans un état urgent

2. Classification clinique des malades aux urgences qui est l'échelle informatisée du triage des patients aux urgences




FIGURE 5.6 – Temps d'attente selon l'heure d'admission

et critique, plus la prise en charge est longue. La figure 5.8 montre également qu'un patient ayant un score de CCMU égal à 5 passe près de trente heures au SUA contre trois heures pour un patient de score 1. Sachant que 80% des patients qui arrivent au SUA ne dépassent pas une durée de séjour de 10 heures, nous pouvons conclure une corrélation entre la durée de séjour du patient et la CCMU. De plus, la répartition de l'indicateur CCMU montre aussi que ce score n'est pas précis. Donc, un modèle de classification pertinent peut être une solution pour obtenir un score qui reflète d'une manière plus pertinente l'état du patient, ce qui permettra une prise en charge plus coordonnée et de meilleure qualité et donc un temps d'attente plus court.

#### 5.2.4 L'admission post urgences

Concernant l'orientation des patients post urgence, la figure 5.9 montre que la plupart des patients (environ 68%) rentre chez eux après la prise en charge. En revanche, 21% des patients doivent être hospitalisés, que ce soit dans le même centre hospitalier (transfert interne) ou dans un autre hôpital (transfert externe). Ce chiffre représente un nombre important de patients. Nous pouvons donc conclure qu'une prédiction précoce de l'admission au moment d'arrivée peut aider le personnel de santé à bien gérer les capacités de lits. Cette prédiction peut se faire par l'usage d'une méthode de ML. Nous détaillons cette partie dans la suite de ce chapitre. L'analyse statistique réalisée permet une compréhension progressive et une meilleure connaissance du fonctionnement des urgences comme par exemple connaître la fréquentation moyenne des patients par jour, par heure et par mois ou bien la durée de séjour des patients dans le SUA selon le score CCMU. Suite à nos visites au SUA de Lille et aux diverses réunions avec le personnel médical, nous avons conclu que la prédiction de l'admission ainsi la prédiction du nombre des arrivées et la classification des patients selon leur degré de sévérité permettent d'assurer une anticipation précoce à la situation de tension. Nous disposons justement de données sous forme de séries temporelles qui conviennent parfaitement pour la réalisation des analyses prédictives. Dans le cadre de cette thèse, l'idée de déployer l'apprentissage automatique (ML) est intéressante car elle permet d'anticiper les moments de tension et de réduire le risque d'erreur au niveau du triage. Ceci peut être un facteur d'amélioration de plusieurs indicateurs de performance



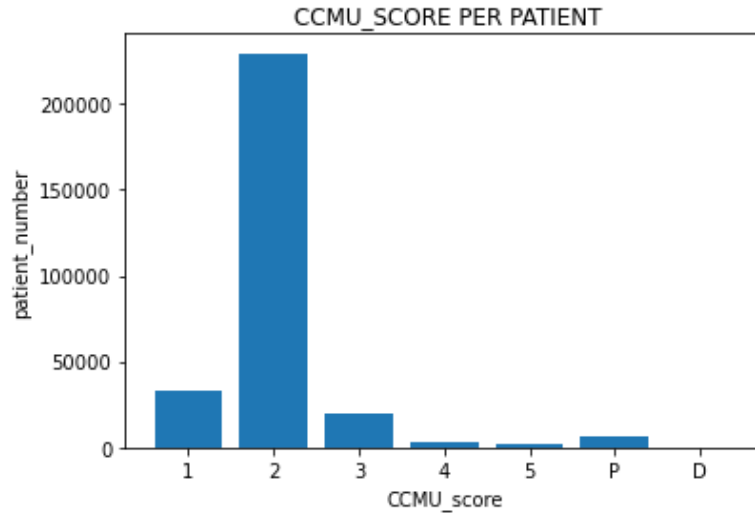


FIGURE 5.7 – score CCMU par nombre de patients




FIGURE 5.8 – La durée de séjour selon CCMU




FIGURE 5.9 – Orientation post urgence par patient

aux urgences. Par exemple, le temps d'attente, la durée totale de séjour, la charge du personnel soignant, l'orientation post urgence, le triage, etc.

Au cours de nos échanges avec le personnel soignant, nous avons identifié quelques indicateurs susceptibles d'être prédits. Par exemple :

- L'admission des patients au moment de l'arrivée. Cette prédiction permet d'anticiper les besoins en hospitalisation en aval des urgences, d'aider les infirmiers de triage à identifier les cas urgents et d'améliorer la qualité des soins.
- L'affluence des patients aux urgences. La prédiction de cet indicateur fournit au personnel soignant un outil précieux pour anticiper les ressources humaines et matérielles nécessaires au jour le jour et permet également d'anticiper les moments de tension afin de les gérer de la manière la plus efficace possible.
- L'orientation des patients post triage. Cette étape désigne le circuit adéquat (circuit court, circuit long, déchochage) d'un patient dans le SUA. La prédiction de l'orientation (triage) peut aider les infirmier(e)s de triage à éviter les erreurs qui peuvent rallonger la durée de séjour des patients au service des urgences, dégrader leur état de santé et augmenter le risque d'encombrement.
- Le temps d'attente primaire. La prédiction de cet indicateur améliore la satisfaction du patient et la qualité des soins et permet aussi d'anticiper les situations de crise aux urgences.
- Les examens complémentaires. Cet indicateur aide à prédire le temps d'attente par patient et par unité afin d'optimiser le parcours de soins et donc améliorer la qualité de prise en charge.

Dans le cadre de cette thèse et après avoir échangé avec nos collaborateurs sur ce sujet, nous avons choisi de travailler sur les trois premiers indicateurs à savoir l'admission, l'affluence des patients et le triage. En effet, la prédiction de ces trois indicateurs permet l'anticipation de la tension en améliorant à la fois la satisfaction des prestataires de soins (i.e. prédire l'affluence des patients) et la qualité de soins (i.e. prédire l'admission au moment de l'arrivée et aider au triage).

### 5.3 Modèle de prédiction de l'admission hospitalière du patient dès son arrivée

Dans cette partie, nous proposons une adaptation de l'algorithme usuel Perceptron Multicouche (MLP) (MINSKY et PAPERT 1969) selon notre modèle de données. Cette adaptation donne un nouvel algorithme baptisé DDMLP (Dynamic Dempster Multi Layers Perceptron) qui est donc basé sur le MLP et permettant d'améliorer ses performances techniques de classification. Ces modèles sont créés pour prédire l'admission hospitalière des patients dès leur d'arrivée au SUA.

#### 5.3.1 L'algorithme Perceptron Multicouche (MLP)

?? Un réseau de neurones est un ensemble de processeurs élémentaires. Ces derniers sont connectés les uns aux autres et sont capables d'échanger des informations au moyen des connexions qui les relient (Figure ??). Les connexions sont directionnelles et à chacune d'elle est associé un nombre réel appelé poids de la connexion (GHANI, DIHMANE, MANSOURI et al. 2017). L'information est ainsi transmise de manière unidirectionnelle du neurone  $j$  vers le neurone  $i$ , multipliée par le coefficient pondérateur  $w_{ij}$ . Un neurone calcule son état en utilisant des informations venues de l'extérieur, ou bien il détermine son entrée à partir des neurones auxquels il est connecté et calcule son état comme une transformation souvent non linéaire de son entrée. Il transmet à son tour son état vers d'autres neurones ou vers l'environnement extérieur.

L'apprentissage est une phase du développement d'un réseau de neurones durant laquelle le comportement du réseau est modifié jusqu'à l'obtention du comportement désiré (HEUDIN 2016; GERSTNER et al. 2006). L'ajustement des poids correspondants aux liens entre les neurones peut s'effectuer selon diverses équations mathématiques, dont la plus usuelle est sans aucun doute la loi de Hebb. Le choix de l'équation d'adaptation des poids dépend en grande partie de la topologie du réseau de neurones utilisé (Connexion Locale, connexion complète ou connexion récurrente).

En effet, le perceptron multicouche (MLP) est l'exemple le plus répandu des classificateurs neuronaux employés dans le domaine de la reconnaissance. Un MLP est composé d'une couche d'entrée dont la taille est égale à la taille des données d'entrée, une ou plusieurs couches cachées dont la taille est déterminée par essai et la couche de sortie dont la taille est égale au nombre de classes du problème à résoudre (NØRGAARD et al. 2001). Dans les réseaux MLP, chaque neurone est relié à un certain nombre d'entrées qui peuvent correspondre aux données d'entrée ou aux sorties des couches précédentes (Figure 5.10). Chacune de ces entrées est pondérée par un poids synaptique ; le poids total d'un neurone est le produit scalaire entre les entrées et leur poids avec




FIGURE 5.10 – Structure d'un MLP,(GHANI, DIHMANE, MANSOURI et al. 2017)

l'addition d'un biais (b) :

$$Poidstotal = X_1 W_1 + \dots + X_n W_n + b \quad (5.1)$$

Un algorithme d'apprentissage tel que la Backpropagation de gradient est appliqué pour ajuster les poids en réduisant au minimum une fonction d'erreur qui est, en général, la somme des erreurs quadratiques entre la sortie du réseau de neurones et la sortie attendue.

### 5.3.1.1 La Backpropagation par Descente de Gradient

Cet algorithme évalue l'erreur du gradient pour chaque neurone dans le réseau depuis la dernière couche jusqu'à la première. Les poids produisant une erreur significative seront modifiés en grande valeur par rapport aux poids produisant une erreur marginale. La Backpropagation (BP) par descente de gradient a été efficacement employée pour l'apprentissage d'un MLP ; son principe est de converger de manière itérative vers un ensemble optimal des poids synaptiques. Dans le cas de l'apprentissage supervisé, les sorties sont fournies à l'avance ; la différence entre ces sorties et les sorties du réseau (après propagation de l'information par une fonction d'activation) constitue l'erreur à réduire au minimum par BP tout en ajustant les poids (RENDERS 1995). Cette étape est répétée plusieurs fois jusqu'à ce que le réseau puisse offrir la meilleure prévision. Dans certains cas, l'algorithme de la BP de gradient ne peut pas échapper aux optimums locaux. Pour cette raison, un poids a été ajouté à la formule de la BP permettant à l'algorithme d'échapper aux optimums locaux. Ce processus de recherche est représenté par la figure 5.11 qui résume les étapes principales de l'algorithme de la BP de gradient :

L'implémentation du modèle MLP est basée sur notre base de données issue du CHU de Lille qui contient 386.460 patients. Pour assurer la phase d'apprentissage, nous entraînons notre modèle sur 66% des données (255064 patients). Le reste des données est dédié à la phase de test qui est responsable de la validation du modèle et qui permet son évaluation. Nous détaillons cette partie d'expérimentation dans le chapitre suivant. Le modèle usuel du MLP est un réseau de neurones avec trois couches simples. La couche entrante peut absorber les données cliniques telles que l'Age, le sexe, le motif de venue, la température, la pression artérielle systolique et la saturation O2. Néanmoins, les données manquantes et incertaines ne sont pas prises en charge dans ce modèle. Pour remédier à ce manque, nous proposons un nouveau modèle MLP dynamique basé

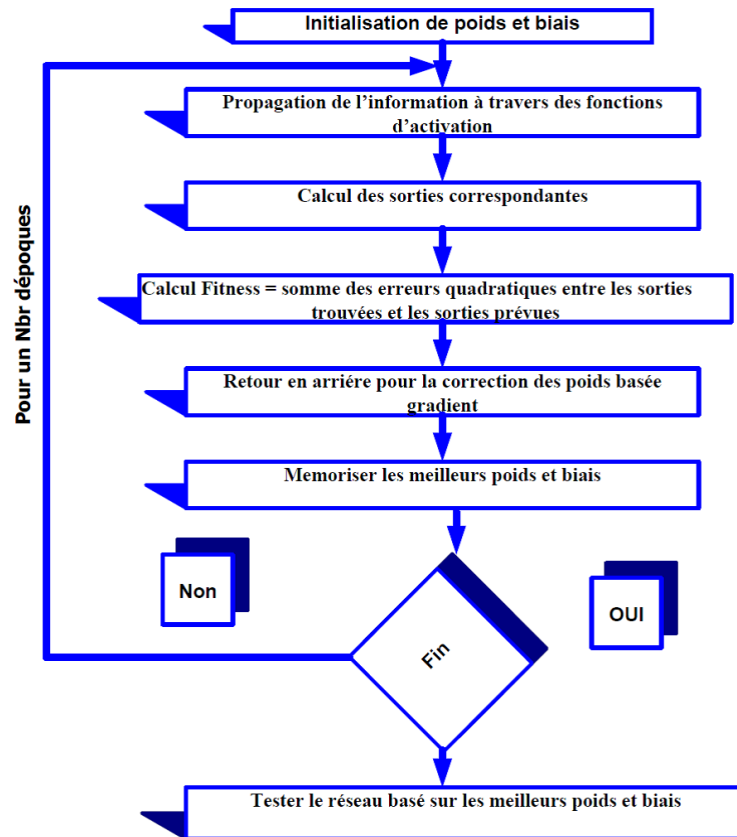


FIGURE 5.11 – L’algorithme de la rétro-propagation de gradient,(GHANI, DIHMANE, MANSOURI et al. 2017)

sur la théorie de Dempster (SHAFFER [1976]). Ce dernier est détaillé ce qui suit.

### 5.3.2 L'algorithme DDMLP (Dynamic Dempster Multi Layers Perceptron)

Dans cette partie, nous présentons notre algorithme DDMLP qui est un modèle de classification dynamique basé sur la théorie de Dempster Shafer D-S (cf.section 2.6.4.3). Dans ce contexte, nous nous basons sur l'algorithme de réseau de neurones usuel MLP qui nécessite un nombre statique de neurones d'entrées. En général, le réseau est censé traiter un ensemble de vecteurs d'entrées avec un nombre maximal choisi de paramètres d'entrées. Cependant, les calculs supplémentaires requis pour les entrées non utilisées augmentent le temps de traitement et diminuent la vitesse d'apprentissage. Dans ce cadre, Mustapha (MUSTAFA, ALLEN et APPIAH [2019]) propose d'ignorer les neurones d'entrées inutilisés pour réduire la taille du vecteur d'entrée. De cette façon, ces neurones inutilisés qui présentent des données manquantes n'affectent pas les calculs au sein du réseau. Ainsi, en se basant sur les travaux de Mustapha (MUSTAFA, ALLEN et APPIAH [2019]), nous proposons le **DDMLP** qui correspond à un réseau neuronal composé d'une couche d'entrée avec un nombre flexible de neurones et d'une couche cachée avec un nombre de neurones calculés en fonction du nombre de neurones d'entrées. Si nous considérons que  $N_{i,t}$  est le nombre de neurones de la couche  $t$  correspondant au patient  $P_i$ , notre réseau est donc composé de deux couches dynamiques avec :

- $N_{i,1}$  neurones d'entrées correspondant au nombre de paramètres médicaux non vides pour le patient  $P_i$  et
- $N_{i,2}$  neurones cachés calculés en utilisant l'équation [5.2].

$$N_{i,2} = \lfloor \frac{N_{i,1} + 1}{2} \rfloor \quad (5.2)$$

L'équation [5.2] est proposée afin que la 2ème couche soit basée sur la fusion des données de la 1ère couche. Donc, nous combinons chaque deux paramètres successifs dans la couche cachée pour calculer les poids. Nous avons mis en place cette méthode pour combiner les sources de données en se basant sur la théorie de D-S expliquée dans ce qui suit. Dans des travaux futurs, nous pouvons améliorer cette méthode proposée en étudiant les corrélations entre les variables de données. Dans le cadre de la méthode proposée, la fusion des données permet de trouver la masse de la source d'information entre deux variables successives. De cette manière, nous n'utilisons que les neurones actifs contenant des données dans le calcul des poids. Pour chaque patient  $P_i$ , une instance de DDMLP est créée. Ainsi, chaque instance est composée d'une couche d'entrée ( $N_{i,1}$  neurones), d'une couche cachée ( $N_{i,2}$  neurones) et d'une couche de sortie. Le nombre de neurones de la couche de sortie est noté par  $N_s$  avec  $N_s = 1$  puisque la couche de sortie contient un seul neurone. Notre modèle construit les neurones sur la base des données valides pour chaque cas de patient  $P_i$ . Cependant, en comparant avec le travail de (MUSTAFA, ALLEN et APPIAH [2019]), les neurones de la couche cachée sont dynamiques dans notre réseau neuronal. Nous montrons dans la section suivante comment calculer les poids des neurones, en considérant les sources d'information en fonction de leur pertinence et donc de l'incertitude des données. Les poids sont appelés **poids de croyances pondérées (Weight Belief Assignment, WBA)**, par analogie avec la BBA de la théorie D-S. Nous détaillons ce concept dans ce qui suit.

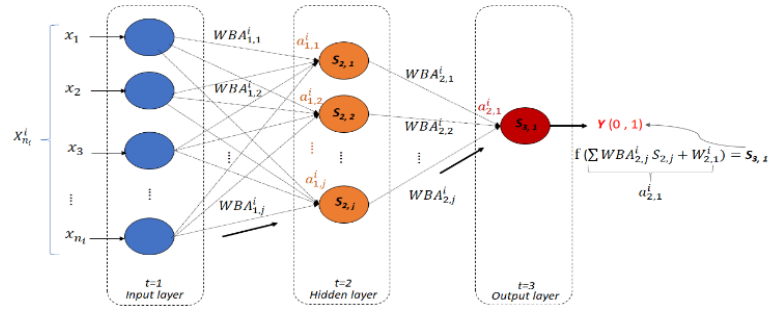


FIGURE 5.12 – Schéma global de l'approche proposée : phase de forward du DDMLP

### 5.3.2.1 Poids de croyances pondérées (WBA)

L'idée principale de ce travail est de considérer l'incertitude des données lors des phases de traitement et d'apprentissage. Dans ce contexte, le poids (représenté par WBA) correspond à la quantité de gain d'information qui continue à se propager jusqu'à ce que l'algorithme soit optimisé. La figure 5.12 ci-dessous correspond à une représentation graphique de l'approche que nous proposons dans le cadre de cette thèse. On note par  $WBA_{t,j}^i$  le poids associé au patient  $P_i$  au niveau de la couche  $t$  en fonction de la source (ou combinaison de sources)  $j$ . Ainsi, les poids du réseau sont transformés en fonction de l'incertitude puis propagés dans le réseau par la règle de combinaison de Dempster (cf. section 2.6.4.3). L'objectif de notre algorithme proposé DDMLP est de prévoir le résultat du patient (s'il va être hospitalisé ou pas, et donc s'il faut prévoir un lit) en fonction des données correspondantes disponibles. Puisque notre cadre de discernement  $\Omega$  correspond à toutes les possibilités d'orientation  $d_z$  d'un patient après la prise en charge aux urgences où dans notre cas d'étude  $z \in \{1, 2\}$ , nous prenons une instance de ces possibilités  $\Omega = \{d_1, d_2\}$  avec  $d_1$  correspond à la sortie du patient et  $d_2$  à son entrée à l'hôpital. Ces prévisions sont primordiales pour aider à réduire les erreurs médicales, sauver des vies et gérer l'engorgement des urgences. Chaque paramètre médical (tel que les symptômes et les antécédents) est considéré comme une source d'information  $j$  pour calculer la masse d'information pour chaque cas de patient  $P_i$ . Ces données aident à formuler les réponses liées à notre problème d'aide à la décision en gérant l'incertitude de chaque variable donnée.

- La variable  $a_{t,j}^i$  représente la sortie des neurones de la couche  $t$ , permettant le calcul des entrées de la couche suivante  $t + 1$  et
- $S_{t,j}$  définit les variables d'entrée des neurones de la couche suivante  $t$ .
- Le résultat  $y$  de notre approche est une valeur booléenne, soit 0 ( $d_1$  qui désigne la sortie) ou 1 ( $d_2$  qui désigne l'hospitalisation).

La décision de faire sortir un patient est complexe car l'état de santé de ce dernier peut se détériorer soudainement, ce qui peut provoquer une mort subite et prématurée. D'où l'importance de proposer un système intelligent d'aide à la décision au niveau du triage.

**5.3.2.1.1 WBA de la couche d'entrée** Comme expliqué précédemment,  $WBA_{1,j}^i$  correspond au poids associé au patient  $P_i$  au niveau de la couche  $t$  en fonction de la source (ou combinaison de sources)  $j$ . Ainsi, le poids  $WBA_{1,j}^i$  au niveau de la couche d'entrée est défini dans notre réseau

par l'équation [5.3](#) ci-dessous.

$$WBA_{1,j}^i = \frac{m_j^i(d_2) - m_j^i(d_1)}{m_j^i(d_\Omega)} \quad (5.3)$$

Où :  $m_j^i$  correspond à la fonction de masse (définie par l'équation [2.7](#)) liée à la source d'information  $j$  (paramètre médical) du patient  $P_i$  (cas médical). Ainsi,  $m_j^i(d_z)$  mesure l'évidence de la décision  $dz$  avec la source d'information  $j$  pour le patient  $P_i$  ( $z \in \{1, 2\}$ ). Plus la probabilité (liée au patient  $P_i$ ) d'être hospitalisé est élevée (selon la source  $j$ ), plus le poids  $WBA_{1,j}^i$  de la source  $j$  est important. D'un autre côté, plus l'incertitude globale est élevée, plus ce poids est faible. L'incertitude de la source d'information  $j$  concernant le patient  $P_i$  par rapport à la décision  $d_z$  est obtenue avec l'équation [5.4](#) ci-dessous.

$$m_j^i(\Omega) = \prod_z m_{j,z}^i(\Omega) \text{ avec } m_{j,z}^i(\Omega) = 1 - m_{j,z}^i(d_z); z \in \{1, 2\} \quad (5.4)$$

**5.3.2.1.2 WBA de la couche cachée** Nous définissons les poids  $WBA_{2,j}^i$  au niveau de la couche cachée de notre réseau par l'équation [5.5](#). Le seul élément qui change ici est la source des données.

$$WBA_{2,j}^i = \frac{m_j^i(d_2) - m_j^i(d_1)}{m_j^i(d_\Omega)} \quad (5.5)$$

Où  $j = j' \oplus j''$  et  $m_{j',j''}^i = m_{j'}^i \oplus m_{j''}^i$ , selon la règle de combinaison de Dempster (Equation [2.7](#)). Contrairement au calcul du poids de l'équation [5.3](#), nous n'utilisons pas les sources des données mais la combinaison de deux sources  $j'$  et  $j''$  (sélectionnées de manière aléatoire ou en se basant sur une heuristique). Donc, ici,  $j$  représente la combinaison d'un couple de sources  $j'$  et  $j''$ . Nous appliquons les mêmes règles pour calculer les poids de la couche cachée mais, dans cette étape, nous considérons l'évidence combinée de l'union de deux sources d'information au lieu d'une seule source car cette combinaison peut donner une relation sémantique entre les sources permettant de réduire l'incertitude. Par exemple, un homme de 70 ans présentant des symptômes cardiologiques, il y a donc une forte probabilité qu'il soit hospitalisé.

### 5.3.2.2 La description de l'algorithme DDMLP

Nous proposons dans le cadre de cette thèse l'algorithme DDMLP (Algorithme ??) qui calcule le poids de chaque neurone à l'aide des équations ([5.3](#)) et ([5.5](#)) selon la position du neurone dans le réseau (1ère couche d'entrée ou 2ème couche cachée). Le DDMLP déploie ensuite la fonction d'activation usuelle Sigmoïde dédiée à une classification binaire pour obtenir les sorties de ce réseau (1 pour l'hospitalisation et 0 sinon). Le tableau [5.1](#) présente les variables utilisées dans l'algorithme DDMLP que nous proposons. Cet algorithme proposé, que nous avons baptisé le DDMLP, récupère en entrée le vecteur des  $n_i$  données médicales de chaque patient  $P_i$  et comme expliqué précédemment, les poids sont calculés en fonction de l'incertitude liée aux sources de données et la mesure de la croyance de ces données utilisées selon la décision  $d_z$  ( $z \in \{1, 2\}$ ). Ces poids calculés sont cruciaux pour le calcul des entrées/sorties des neurones et aussi pour garder la relation et la propagation de l'information entre les couches. Le DDMLP commence par calculer le nombre de neurones de la couche d'entrée et de la couche cachée, la dernière couche (sortie) ne contenant qu'un seul neurone. Puis couche par couche (en commençant par



**Algorithme 1 : DDMLP algorithm (forward Pass)**


---

```

1 Input
2  $X_{n_i}^i$  : les données de patient  $P_i$ ;
3 Output
4  $d_z$  : Le résultat de prédiction où  $z \in \{1, 2\}$  ( $d_1$  les patients prédits pour le processus de sortie du SUA et  $d_2$  les patients prédits
   pour le processus d'hospitalisation post-urgence);
5 initialization,  $\forall t \in \{1, 2, 3\}$ 
6  $N_{1,t} \leftarrow 0$ ;
7  $A_t \leftarrow 0$ ;
8  $S_{j,t} \leftarrow 0$ ;
9 for chaque  $x_j^i$  de  $X_{n_i}^i$  do
10   if  $x_j^i \neq 0$  then
11      $N_{i,1} \leftarrow N_{i,1} + 1$  (Calculer le nombre de neurone de la couche entrée);
12   end
13 end
14  $N_{2,1} \leftarrow \frac{N_{i,1} + 1}{2}$  (Calculer le nombre de neurone de la couche cachée);
15 for  $t = 1$  to 3 do
16   if  $t = 1$  then
17     for  $j = 1$  to  $N_{i,1}$  do
18        $WBA_{1,j}^i \leftarrow \frac{m_j^i(d_2) - m_j^i(d_1)}{m_j^i(d_\Omega)}$  (Calculer le vecteur des poids de la 1ere couche);
19        $A_t \leftarrow A_t + x_j^i * WBA_{1,j}^i$ ;
20     end
21   end
22    $j \leftarrow 1$  if  $t = 2$  then
23     for  $j = 1$  to  $N_{i,2}$  do
24        $W_{t-1,i}^j \leftarrow Random$  (Initialiser le biais dynamique);
25        $a_{t-1,i}^j \leftarrow A_t + W_{t-1,i}^j$  (Calculer les outputs de la couche entrée);
26        $S_{t,j} \leftarrow \frac{1}{1 + \exp^{-a_{t-1,i}^j}}$  (Calculer les inputs de la couche cachée);
27        $WBA_{2,j}^i \leftarrow \frac{m_j^i(d_2) - m_j^i(d_1)}{m_j^i(d_\Omega)}$  (Calculer le vecteur des poids de la couche cachée);
28        $A_t \leftarrow A_t + S_{t,j} * WBA_{2,j}^i$ ;
29     end
30   end
31    $j \leftarrow 1$  if  $t = 3$  then
32      $W_{t-1,i}^j \leftarrow Random$ ;
33      $a_{t-1,i}^j \leftarrow A_t + W_{t-1,i}^j$  (Calculer les outputs de la couche cachée);
34      $S_{3,j} \leftarrow \frac{1}{1 + \exp^{-a_{t-1,i}^j}}$  (Calculer les résultats);
35   end
36 end
37 if  $S_{3,j} \leq 0,5$  then
38   return  $d_1$  (Retour à domicile);
39 else
40   return  $d_2$  (Hospitalisé);
41 end
42 end

```

---

Variables	Description
$j$	Indice d'une source d'information liée aux données médicales telles que l'âge et la pression sanguine
$x_j^i$	Données médicales $j$ du patient $P_i$
$X_i^{n_i}$	Vecteur de $x_j^i$ avec $1 < j < n_i$ ou $n_i$ le nombre des données médicales disponibles pour chaque patient $P_i$ .
$t$	Indice de la couche ( $t \in \{1, 2, 3\}$ )
$N_{i,t}$	Nombre de neurones de la couche $t$ pour un patient $P_i$
$a_{t,j}^i$	Sortie de la couche $t$ qui correspond à la source (ou combinaison sources) $j$ d'un patient $P_i$ .
$At$	Variable de sortie de la couche $t$ pour calculer $a_{t,j}^i$ .
$WBA_{t,j}^i$	Poids associé au patient $P_i$ au niveau de la couche $t$ en fonction de la source (ou combinaison de sources) $j$ .
$S_{j,t}$	Variable sigmoïde correspondant à la couche $t$ et à la source (ou combinaison de sources) d'information $j$ .
$m_j^i(d_z)$	La masse d'information de la décision $d_z$ avec la source (ou combinaison de sources) d'information $j$ pour le patient $P_i$ .
$w_{t,j}^i$	Biais dynamique DDMLP dans la couche $t$ en fonction de la source (ou combinaison de sources) $j$ du patient $P_i$ .

TABLEAU 5.1 – Description des variables utilisées dans l'algorithme DDMLP

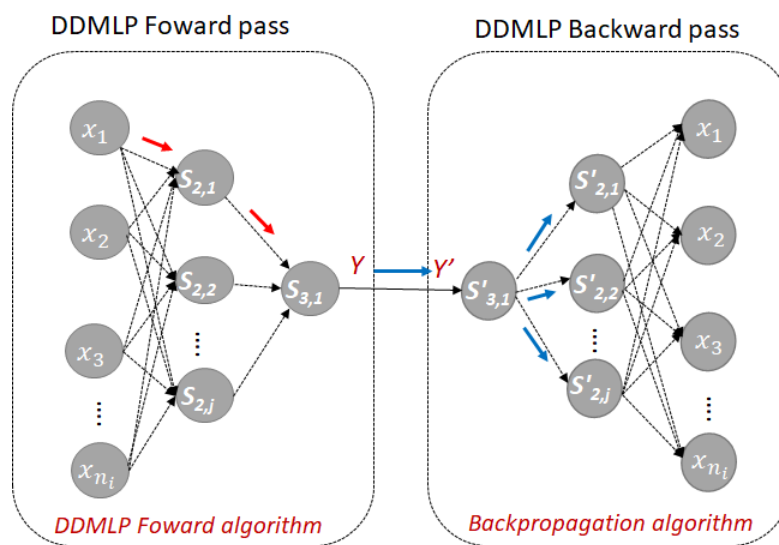


FIGURE 5.13 – Illustration de l'approche DDMLP

la première couche), il calcule les poids et les sorties de chaque neurone, et enfin les entrées de la couche suivante en utilisant la fonction sigmoïde pour l'activation. Pour le calcul de la sortie, nous proposons d'initialiser aléatoirement le biais dynamique  $w_{t,j}^i$  qui est équivalent au biais fixe de l'algorithme MLP. Ainsi,  $w_{t,j}^i$  est dynamique et joue un rôle très important dans la phase BP qui permet de corriger les erreurs (Différence entre les variables réelles et les variables prédites). Dans la phase BP, le passage en arrière commence par la comparaison du résultat  $y$  de l'algorithme avec le résultat réel  $y'$ , ici il applique l'algorithme BP pour mesurer l'erreur et modifier le biais  $w_{t,j}^i$  jusqu'à optimiser les paramètres de l'algorithme (Figure 5.14). Le biais  $w_{t,j}^i$  (entre -0,1 et 0,1) du réseau est initialement choisi d'une manière aléatoire. L'algorithme de Backpropagation permet ensuite de calculer les corrections nécessaires. Cet algorithme peut être décomposé en quatre étapes :

1. Calcul par rétro-propagation.
2. Backpropagation vers la couche de sortie

3. Backpropagation vers la couche cachée
4. Mise à jour du biais.

Cet algorithme est arrêté lorsque la valeur de la fonction d'erreur (Equation 5.6) devenue suffisamment petite.

$$E = \frac{1}{2} \sum_{i=1}^{\rho} |y'_i - y_i|^2 \quad (5.6)$$

Où la variable  $y_i$  représente la sortie qu'on devrait avoir pour chaque ensemble de données entrantes présentées dans ce réseau. Ce dernier produit un résultat  $y'_i$  généralement différent de la cible  $y_i$ . Pour tout  $i = 1 \dots \rho$ , l'algorithme BP répète le processus de correction jusqu'à ce que  $y'$  tende vers  $y$ . Nous détaillons la partie expérimentale dans le chapitre suivant.

La prédiction de l'admission peut aider le personnel soignant à trier les patients, à bien gérer le nombre de lits d'hospitalisation et à anticiper les situations de tension. En outre, il faut prédire le nombre des arrivées pour pouvoir estimer l'hospitalisation. Dans ce contexte, un modèle de prédiction des arrivées est proposé dans la section suivante.

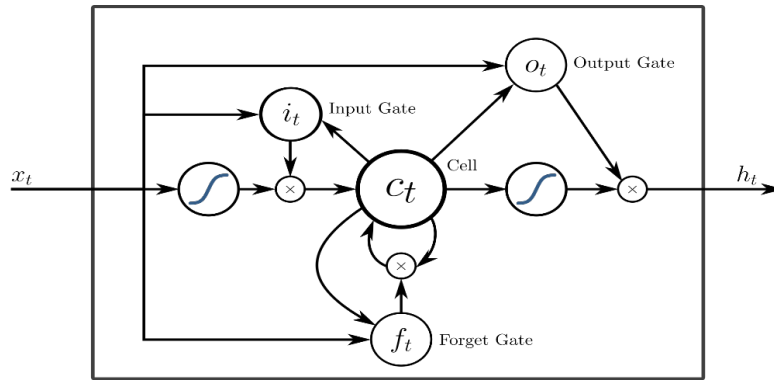
## 5.4 Modèle de prévision du nombre d'arrivées aux urgences

Le nombre des arrivées au SUA présente un facteur important de tension, un modèle de prévision de l'affluence peut aider le personnel de santé à bien gérer les situations de tension. Dans ce contexte, les réseaux de neurones récurrents (RNN) sont largement utilisés en intelligence artificielle dès lors qu'une notion temporelle intervient dans les données. Nous intégrons donc notre base de données dans un modèle de série temporelle LSTM (Long Short-Term Memory). D'un autre côté, nous définissons un modèle d'apprentissage par renforcement basé sur l'algorithme Deep Q-Learning. Le but est de comparer deux différentes catégories de technique d'apprentissage pour identifier celle qui s'adapte le mieux à notre cas d'étude. Nous comparons donc ces deux modèles sélectionnés en présentant les résultats trouvés dans le chapitre suivant.

### 5.4.1 Modèle LTSM (Long Short-Term Memory)

Depuis sa première introduction en 1997 (HOCHREITER et SCHMIDHUBER 1997), il a été démontré que le LSTM a la capacité d'apprendre les dépendances à long terme existant dans les séries temporelles (EVERMANN, REHSE et FETTEKE 2017). La structure du modèle correspond à une catégorie spécifique de réseau neuronal récurrent (RNN). Le RNN traditionnel n'a pas la capacité d'apprendre les actions à long terme existant dans les séries temporelles (FISCHER et KRAUSS 2018). Ce modèle a été utilisé avec succès pour la prédiction de séries temporelles pour le marché financier (FISCHER et KRAUSS 2018), la reconnaissance vocale, l'irradiance solaire (QING et NIU 2018), le prix de l'électricité (PENG et al. 2018), la modélisation du ruissellement des pluies (HU et CHEN 2018), etc.

La structure principale du modèle LSTM est présentée par la figure 5.14. Il s'agit d'un bloc mémoire, d'une porte d'entrée, d'une porte de sortie, d'une porte d'oubli et d'une ou plusieurs cellules de mémoire dans le bloc mémoire. L'ingrédient le plus important du bloc mémoire est la cellule mémoire, qui a la capacité de mémoriser l'état du modèle LSTM à l'instant  $t - 1$  (SAGHEER et KOTB 2019). Nous adaptons donc cet algorithme à notre modèle de données afin de prévoir le



Source : LSTM

FIGURE 5.14 – La structure du modèle LSTM

nombre des arrivées. Les données entrantes sont les informations statistiques et temporelles sur les arrivées comme le nombre des arrivées par heure, par jour et par mois. Les informations qui n'ont aucun rapport avec la prévision doivent être oubliées et celles qui ont un rapport avec la prévision doivent être réservées. La fonction d'activation de la porte d'oubli est exprimée par l'équation 5.7 suivante :

$$f_t = \sigma(W_{xf}X_t + W_{hf}H_{t-1} + b_f) \quad (5.7)$$

Où  $W_{xf}$  et  $W_{hf}$  sont les paramètres de poids de la porte d'oubli,  $b_f$  est le paramètre de biais de la porte d'oubli, et  $\sigma()$  est la fonction **Sigmoid** qui est définie dans l'intervalle  $[0,1]$ . La valeur « 1 » indique que l'information correspondante dans la cellule de mémoire doit être conservée. La valeur « 0 » indique que l'information correspondante dans la cellule de mémoire doit être oubliée (BAEK et KIM 2018). La porte d'entrée décide quelles informations de la série temporelle actuelle  $X_t$  et de la sortie du bloc de mémoire à la série temporelle précédente  $H_{t-1}$  doivent être entrées dans la cellule de mémoire et utilisées pour mettre à jour l'état de la cellule. Tout d'abord, la valeur candidate  $\tilde{C}_t$  est calculée par la fonction  $\tanh$  qui est définie dans l'intervalle  $[-1,1]$  (Equation 5.8). La valeur candidate est utilisée pour mettre à jour l'état de la cellule à l'instant  $t$ . Ensuite, la fonction d'activation de la porte d'entrée est formulée par l'équation suivante (Equation 5.9) :

$$\tilde{C}_t = \tanh(W_{xc}X_t + W_{hc}H_{t-1} + b_c) \quad (5.8)$$

$$i_t = \sigma(W_{xi}X_t + W_{hi}H_{t-1} + b_i) \quad (5.9)$$

où  $W_{xc}$  et  $W_{hc}$  sont les paramètres de poids de la cellule de mémoire,  $W_{xi}$  et  $W_{hi}$  sont les paramètres de poids de la porte d'entrée,  $b_c$  et  $b_i$  sont les paramètres de biais de la cellule de mémoire et de la porte d'entrée. Sur la base de l'état précédent  $C_{t-1}$  de la cellule de mémoire et de la valeur candidate  $\tilde{C}_t$  à l'instant  $t$ , l'étape suivante consiste à mettre à jour l'état de la cellule de mémoire à l'instant  $t$  par la multiplication par points. La fonction de mise à jour de l'état de la cellule de mémoire est définie par l'équation 5.10 suivante :

$$C_t = f_t * C_{t-1} + i_t * \tilde{C}_t \quad (5.10)$$

Lorsque l'état de la cellule mémoire est complété récemment, alors il faut sortir le résultat par la porte de sortie. L'information de contrôle de la porte de sortie dans la cellule de mémoire doit

être utilisée pour trouver le résultat souhaité. La valeur de la porte de sortie  $o_t$  est calculée par l'équation 5.11 :

$$o_t = \sigma(W_{x_o}X_t + W_{h_o}H_{t-1} + b_o) \quad (5.11)$$

Où  $W_{x_o}$  et  $W_{h_o}$  sont les paramètres de poids de la porte de sortie,  $b_o$  est le paramètre de biais de la porte de sortie. D'abord, l'état d'une couche cachée (LSTM) est calculé par l'équation 5.12 :

$$h_t = o_t * \tanh(C_t) \quad (5.12)$$

Si le nombre de couches et de neurones est important, la probabilité que les caractéristiques de l'ensemble de données soient apprises est plus élevée. Cependant, cela peut également conduire à un problème d'Overfitting (Sur-apprentissage). Dans ce processus, les principales variables d'ajustement sont le nombre de neurones et le nombre de couches cachées du modèle LSTM. De plus, un LSTM ne parvient pas à stocker les informations pendant une période plus longue. Il n'y a pas aussi de contrôle plus précis sur la partie du contexte qui doit être reportée et sur la part du passé qui doit être « oublié ». Néanmoins, l'aspect répétitif dans les algorithmes d'apprentissage par renforcement (RL) aide à construire une série de données temporelles plus proche de la réalité et qui prend en considération d'autres facteurs comme le facteur climatique, ce qui permet de prévoir les arrivées d'une manière plus précise. Pour cela, nous proposons dans la section suivante un modèle RL basé sur le modèle de Markov et l'apprentissage profond (Deep-Q Learning).

#### 5.4.2 Modèle d'apprentissage par renforcement proposé

Pour mener un modèle d'apprentissage par renforcement (RL), nous définissons d'abord l'environnement d'un service des urgences, avec ses deux parties interne et externe. Nous expliquons aussi certaines des hypothèses utilisées pour modéliser l'arrivée des patients. En général, le service des urgences prend en charge les patients quel que soit leur situation, pouvant être un cas inattendu, non planifié, etc. Les patients qui se présentent aux urgences sont classés selon trois types : programmés, non programmés urgents et non programmés non urgents (MILNER 1988). Les patients aux urgences sont triés pour recevoir un traitement spécifique à leur pathologie dans différentes zones. Leur degré de sévérité est identifié par la méthode de triage, et leur état clinique est évalué par un outil de classification orienté vers les symptômes (MOHAMMADI, GHOMI et ZEINALI 2014). Après le triage, le patient est affecté à un box pour la consultation. La priorité est donnée aux cas à forte acuité. Le processus de traitement se déroule en fonction de l'état clinique du patient, qui doit être orienté vers le parcours adéquat sachant qu'il y a de nombreux parcours possibles. Afin de modéliser l'environnement des urgences, nous faisons les hypothèses suivantes :

- Le mode d'arrivée du patient n'est pas pris en compte car le patient n'est pas catégorisé en fonction de son mode d'arrivée.
- Comme indiqué précédemment, si l'urgence est surchargée, les patients sont affectés à des box de consultations pour être traités et ceux dont le niveau d'acuité est faible sont traités sans être affectés à un box. Dans le cas contraire, un box peut être attribué à un patient dont le niveau d'acuité est faible.
- La prévision de l'arrivée est approximative et comporte 3 classes :  $[0, \frac{1}{2}]$ ,  $[\frac{1}{2}, N[$  et supérieur à  $N$  où  $N$  est la capacité des urgences.
- Les ressources matérielles et la durée de séjour des patients ne sont pas prises en compte.
- La capacité du personnel médical n'est pas évaluée. On considère que les différents membres du personnel médical ont la même capacité de prise en charge des patients.

Variables	Description
$D$	Date d'arrivée des patients ( $j$ : jour, $t$ : heure, $m$ : mois, $y$ : année)
$To$	La température à l'instant $t$
$c$	Période de crise (e.g. pandémie, accident) ou non (null)
$f$	Événement spécial (Oui, non)
$P_t$	Le nombre total des patients présents dans le SUA à l'instant $t$
$J_t$	Le nombre de patients qui quittent le SUA à l'instant $t$
$Q_t$	Le nombre de nouvelles arrivées à l'instant $t$

TABLEAU 5.2 – Les variables descriptives de l'état système

- Une ressource médicale ne peut traiter qu'un seul patient à un instant  $t$ . Le schéma du processus de traitement et le niveau d'acuité du patient sont connus après l'arrivée du patient.
- Les urgences sont surchargées (encombrées) quand le nombre de patients qui sont présents dans ce service plus le nombre de patients qui arrivent dépasse la capacité maximale des urgences.
- Tous les patients qui arrivent au service des urgences nécessite une prise en charge médicale.

Ces hypothèses ont été étudiées, proposées et validées en collaboration avec le personnel médical du CHU de Lille. L'objectif est double : représenter de la manière la plus simple possible l'environnement des urgences et d'obtenir, en même temps, un modèle aussi proche que possible de la réalité.

#### 5.4.2.1 Formulation du modèle ED-deepMDPRL

Dans cette partie, nous présentons les éléments clés de notre modèle de Markov (PUTERMAN 1990) :

- Époque de décision  $k$  : elle commence par le début de la journée (à minuit) et se termine par la fin de la journée (heure à 23 heures) sachant qu'à minuit, un nouveau jour commence. Par conséquent, notre modèle continue à fonctionner car les urgences travaillent 24/24.
- État du système  $s_k$  : A chaque époque de décision  $k$ , le vecteur d'état est défini comme suit :  $s_k = (D, To, c, f, B_t, J_t, Q_t)$  où  $Q_t$  est le nombre de nouvelles arrivées au SUA et  $J_t$  est le nombre de patients qui quittent les urgences à l'instant  $t$ . Le tableau 5.2 donne la définition de chacun des éléments de  $s_k$ . L'état du système dépend de quatre dimensions : les attributs temporels  $D(j, t, m, y)$ , les attributs climatiques  $To$ ,  $P_t$  le nombre total de patients présents dans SUA à l'instant  $t$  où  $P_t = P_{t-1} + Q_t - J_t$  et l'évènement spécial  $f$ .
- Observation  $o_t$  : A chaque instant  $t$  (toutes les heures), le système effectue une observation complète de l'état du système en obtenant des informations sur les arrivées et sur l'état de ses propres ressources (capacité maximale du SUA).
- Action  $a_t$  : L'objectif est de prévoir le nombre des arrivées  $Q_{t+1}$  au service des urgences à chaque  $t + 1$  en alertant en cas de dépassement de la capacité maximale de ce service (Equation 5.13).

$$a_t = \{a_1, \dots, a_k\} = \text{agent}(S_t) \quad (5.13)$$

Où  $a_t = (Q_t, R_t)$ ,  $Q_T \in [0, \frac{N}{2}]$  ou  $]\frac{N}{2}, N[$  ou  $[N, \infty[$  et  $R_t, S_{t+1} = \text{environnement}(S_t, a_t)$  Si le nombre de patients  $P_t$  à l'instant  $t$  dépasse la capacité  $N$ , le système émet une alerte et

calcule la probabilité de charge des urgences par rapport à sa capacité  $N$ . Si le nombre de patients  $P_t$  est inférieur à  $N$ , les récompenses sont positives.

- Récompense  $R$  : Une récompense positive est obtenue lorsque la capacité des urgences  $C_{kt}$  ne dépasse pas 100% et la récompense sera négative dans le cas contraire. La récompense  $R_t$  à l'instant  $t$ , est définie comme la charge des urgences  $C_{kt}$  à l'instant  $t$ . Cette charge  $C_{kt}$  est calculée comme suit ( $k$  le nombre d'époques) (Equation 5.14) :

$$C_{kt} = \left[ \frac{P_t + Q_t - J_t}{N} \right] * 100 \quad (5.14)$$

Où  $Q_t$  est le nombre de nouvelles arrivées au SUA,  $J_t$  est le nombre de patients sortis à l'instant  $t$ . La fonction  $R_t$  présente la somme pondérée de charge  $C_{kt}$  à l'instant  $t$  qui a comme objectif la minimisation la capacité globale de SUA où  $c_t$  est le poids de la charge des urgence à l'instant  $t$ , avec  $k$  le nombre d'époques (Equation 5.15). Selon la charge  $C_{kt}$ , nous définissons trois états du SUA : normal, risqué et surchargé.

$$r_t = \min \frac{\sum_{k=0}^t C_{kt}}{k} \quad (5.15)$$

- Transition d'état  $S_t$  : Au cours d'une observation ot à l'instant  $t$ , les informations de l'état  $s_k$  du SUA à l'instant  $t$  sont recueillies grâce au calcul de la charge  $C_{kt}$ . La transition d'état dépend d'une action  $a_t$ . Si at définit un  $C_{kt}$  inférieur à 75% (correspondant à la capacité du SUA), l'état est donc normal et les récompenses sont positives. Si at définit un  $C_{kt}$  entre 75% et 100%, l'état est donc risqué et si at définit un  $C_{kt}$  dépassant 100% la capacité du SUA, alors, l'état est surchargé et les récompenses sont négatives. La transition d'état se reproduit à  $t + 1$  (toutes les heures).

#### 5.4.2.2 Algorithme Deep Q-Learning pour la prévision des arrivées au SUA

Dans cette section, le Deep Q-Learning (DQN) est introduit sur la base du modèle Markovien (MDP) décrit ci-dessus (cf.section 3.4.2) en cherchant la politique optimale pour la prévision du nombre des arrivées à l'instant  $t + 1$ . Cet algorithme présente des performances plus stables et une meilleure efficacité d'échantillonnage que des autres méthodes de ML (ARULKUMARAN et al. 2017b). L'apprentissage Q, qui a été introduit par Watkins (WATKINS 1989) est largement utilisé, correspond à l'apprentissage de la politique optimale à l'aide d'une fonction, appelée la fonction Q. La fonction  $Q(s, a)$  prédit la valeur attendue de la récompense future avec la correspondance entre l'état  $s$  et l'action  $a$ , comme défini dans l'équation ci-dessous (Equation 5.16) :

$$Q(s, a) = \alpha[r(t) + \gamma \max_{a'} Q(s', a') - Q(s, a)] \quad (5.16)$$

Dans (MNIH et al. 2015), les auteurs proposent un DQN en combinant la fonction Q avec un réseau neuronal artificiel (ANN) (Figure 5.15). Pour l'approximation de la fonction Q optimale, le DQN est essentiellement identique au Q-learning. Mais, lorsqu'une fonction non linéaire approximative, telle que le ANN, est utilisée pour représenter la fonction Q, le RL ne peut pas converger en raison des corrélations entre la valeur Q et la valeur cible qui existent dans l'ordre des observations. Dans ce cas, les changements de politique sont impactés par la mise à jour. En effet, trois techniques sont nécessaires pour convertir le Q-network en Q-network profond. Premièrement, les réseaux neuronaux sont remplacés par des réseaux convolutifs profonds (Deep Learning), qui permettent d'extraire des caractéristiques de haute dimension de l'ensemble de données d'entrée. Deuxièmement, un relais d'expérience est introduit pour permettre à l'agent




FIGURE 5.15 – La structure du modèle Deep RL, (SARKER 2021)

d'apprentissage de rappeler et de réutiliser les interactions sociales des expériences passées. De plus, l'agent d'apprentissage stocke les expériences passées (sous la forme d'un n-uplet d'expériences à un instant "  $t$ ", c'est-à-dire <état, action, récompense, état suivant>) dans une mémoire de relecture. Enfin, un réseau neuronal profond prédit les valeurs  $Q$  cibles, qui sont utilisées pour déterminer la fonction de perte  $Loss(\theta)$  pour chaque action d'apprentissage. Par conséquent, dans DQN, les poids cibles  $\theta$  doivent être mis à jour périodiquement. Le modèle DQN est formé pour réduire la fonction de perte  $Loss(\theta)$  de la mémoire de relecture  $M$ , qui est donnée par l'équation (5.17). En outre, la mémoire de relecture  $M$  permet de supprimer les corrélations dans l'ordre des observations et rectifier les changements et une mise à jour itérative est réalisée pour rectifier la valeur  $Q$  où  $\gamma$  est un facteur d'actualisation qui réduit les corrélations avec la cible, c'est-à-dire que le poids  $\theta$  du réseau  $Q$  est mis à jour pendant les itérations.

$$Loss(\theta) = E[(y - Q(s, a_t; \theta))^2] \quad (5.17)$$

$$y = r + \gamma Q(s^*, \arg \max_{a^* \in \mathcal{A}_t^*} Q(s^* a_t^*; \theta^*)) \quad (5.18)$$

L'algorithme DQN est représenté par l'algorithme 2 et le tableau 5.3 ci-dessous. Sachant que  $Q_t$  est le nombre des arrivées à l'instant  $t$  et  $J_t$  celui des départs, lorsque  $Q_t$  et  $J_t$  existent simultanément, la prévision des patients est mise en œuvre sur la base de l'algorithme DQN.

Lors de la prévision, l'agent observe l'état  $s_t$  du système, ce qui lui permet d'obtenir des informations sur les variables de systèmes telles que la température, le nombre de patients  $J_t$ , et exécute une action  $a_t$  en identifiant le nombre des arrivées  $Q_{t+1}$  et la situation  $T_{t+1}$  du SUA à l'instant  $t$ .

Pour générer la valeur  $Q$  du réseau, les vecteurs de variables  $S_t$  présentent l'input de notre modèle d'ANN. En effet,  $S_t$  tient compte des facteurs externes de l'environnement des urgences à l'instant  $t$  tels que les jours fériés, les vacances ou bien les pandémies et représente les informations quantitatives sur le nombre des patients entrants et sortants du SUA. Le modèle proposé prend en considération les facteurs et les données qui influencent directement et indirectement sur le nombre des arrivées afin de fournir la prédiction. Nous définissons ces éléments par : la charge du service des urgences  $C_{kt}$ , les variables qui décrivent l'environnement extérieur du SUA, les informations sur les patients  $J_t$  sortants, les patients  $P_t$  et les nouvelles arrivées  $Q_t$  du



**Algorithme 2 : ED-Deep MDPRL (DQN)**

```

1 Input
2  $S_t$  : ( $D$  date d'arrivée [ $h$  : heure,  $j$  : jour,  $m$  : mois,  $y$  : année];  $T_o$  : Température extérieure [réel];  $C$  : période de crise [booléen];  $f$  :
   événement spécial [booléen];  $P_t, J_t, Q_t$  [entier]);
3 Output
4  $Q_{t+1}$  : le nombre des nouvelles arrivées;
5  $T_{t+1}$  : Situation de SUA à l'instant  $t + 1$  ;
6 initialization
7  $M \leftarrow 0$ ;
8  $Q(s_t, a_t, \theta) \leftarrow 0$ ;
9  $k \leftarrow 1$ ;
10 for each  $k = 1$  to  $W$  do
11   Observer  $s_t$  (Observer l'état  $S$  du SUA à l'instant  $t$ );
12   Sélectionner aléatoirement  $a_t$  ;
13   Calculer  $a_t \leftarrow \text{argmax}_a Q(s_t, a_t, \theta)$  ;
14   Exécuter  $a_t$  et observer  $r_t$  et  $s_{t+1}$ ;
15   Stocker la transition  $E(s_t, a_t, r_t, s_{t+1})$  dans  $M$  ;
16   calculer  $Q(s_t, a_t, \theta) \leftarrow (1 - \alpha)Q(s_t, a_t) + \alpha[r_t + \gamma Q(s_{t+1}, \text{argmax}_a [Q(s_{t+1}, a_t, a_{t+1}, \theta)])]$  ;
17   Calculer Q-value cible  $y \leftarrow r_t + \gamma Q(s_t, \text{argmax}_a [Q(s_{t+1}, a_t, a_{t+1}, \theta)]); \theta -$ ;
18    $Loss(\theta) \leftarrow E[(y - Q(s, a_t; \theta))^2]$  (DeepQ networks est mis à jour en réduisant la perte par la fonction Loss) ;
19    $\theta - \leftarrow \alpha \theta + (1 - \alpha) \theta -$  (DeepQ networks est mis à jour avec le paramètre  $\alpha$ )
20 end
21 Return  $Q_{t+1}$ ;
22  $P_{t+1} \leftarrow Q_{t+1} + P_t - J_t$  if  $P_{t+1} > N$  then
23   Return  $T_{t+1} \leftarrow T_{res\_critique}$  ;
24   else if  $\frac{M}{2} < P_{t+1} < N$  then
25     Return  $T_{t+1} \leftarrow critique$  ;
26   else
27     Return  $T_{t+1} \leftarrow normal$ 
28   end
29 end
30 end

```

Variables	Description
$\theta$	Poids du réseau DQN
$\alpha$	Le taux d'apprentissage
$\gamma$	Facteur d'actualisation.
$M$	Mémoire de répétition
$W$	Nombre d'itération des époques $k$
$Q_{t+1}$	le nombre des nouvelles arrivées à l'instant $t + 1$ .
$L$	La taille maximale de la mémoire de relecture.
$N$	Capacité de SUA.
$T_{t+1}$	Situation de SUA à l'instant $t + 1$ .

TABLEAU 5.3 – Description des variables utilisées dans l'algorithme ED-Deep MDPRL

SUA. En outre, la différence entre le nombre des patients qui quitte ce service et les nouvelles arrivées est sélectionnée comme un indicateur de tension en raison de la diversité des processus de traitement des patients et du manque de ressources. L'état  $s_{t+1}$  suivant de ce service est observé et enregistré au niveau de la mémoire du modèle, représentée par... Ainsi, la transition  $E(s_t, a_t, r_t, s_{t+1}, a_{t+1})$ . La variable  $L$  présente la taille maximale de la mémoire de relecture, dans laquelle la transition la plus ancienne est supprimée dès que le nombre de transitions atteint la taille maximale. Les résultats de ces modèles sont discutés dans le chapitre suivant. La prévision de l'affluence des arrivées est très utile pour améliorer la qualité de soins dans les SUA et aider le personnel de santé à bien prédire les moments de tension. Mais, parfois, l'anticipation doit être accompagnée par un système d'aide à la décision qui peut réduire la pression du personnel de santé en les aidant à prendre la décision adéquate en diminuant le risque d'erreur surtout au cours de triage qui peut être un facteur important de tension. Ce processus est très important car il permet de trier, organiser et orienter les patients selon leur état de santé. De plus, la moindre erreur au niveau de l'orientation peut rallonger la durée de prise en charge et augmenter le risque de complication médicale. Pour cela, un système de prédiction et d'orientation est proposé et détaillé dans la section suivante.

## 5.5 Modèle de prédiction et d'orientation post-triage (Circuit court/ Circuit long/ Déchocage)

Dans cette section, nous proposons un modèle pour aider les infirmier(e)s de triage à orienter les patients vers le circuit adéquat au moment du triage. En effet, le système de triage a deux rôles principaux : trier les patients selon leur état de santé et les orienter vers la 1ère consultation. Le processus de triage des patients est représenté par notre ontologie de triage définie dans le chapitre 4 (cf.section 4.4.2). Cette dernière est capable à définir un degré de sévérité très précis d'un patient.

Dans cette partie, nous définissons un algorithme basé sur le ML pour prédire l'orientation post triage. Le système d'urgence français est composé de 3 circuits différents : un circuit court pour les cas non urgents (pas d'examen médicaux complémentaires), un circuit long pour les cas qui ont une situation critique et le déchocage pour les cas urgents (urgence vitale) qui nécessitent une intervention médicale immédiate. Le modèle proposé vise à optimiser le parcours patient et réduire le taux d'erreurs au niveau du triage. Nous avons fait le choix de nous baser sur la technique de l'arbre de décision C4.5 car elle est adaptée au traitement des attributs numériques, ses valeurs manquantes et des données bruitées (RUGGIERI 2002). Nous proposons des améliorations à cette méthode adoptée afin de l'optimiser et d'avoir de meilleurs résultats. Nous détaillons cette technique dans ce qui suit.

### 5.5.1 Les arbres de décision et les critères de division

Les arbres de décision représentent une méthode très efficace d'apprentissage supervisé. Il s'agit de partitionner un ensemble de données en des groupes les plus homogènes possible du point de vue de la variable à prédire (cf.section 3.3.2.2). Fondamentalement, tous les algorithmes d'arbres de décision nécessitent des critères de division pour diviser un nœud afin de former un arbre. Dans la plupart des cas, les fonctions de division discrètes sont univariées, ce qui signifie qu'un nœud interne est divisé en fonction de la valeur d'un seul attribut (RUGGIERI 2002).

L'algorithme utilisé recherche le meilleur attribut pour le fractionnement. Il existe plusieurs critères de division basés sur l'impureté d'un nœud. L'objectif principal des critères de fractionnement est de réduire cette impureté. Il existe de nombreuses mesures de fractionnement qui peuvent être utilisées pour déterminer la meilleure façon de fractionner les enregistrements. Ces mesures de fractionnement sont définies en fonction de la distribution des classes des enregistrements avant et après le fractionnement (défini dans le chapitre 3 (section 3.3.2.2)). Les mesures d'impureté telles que l'entropie et l'indice de Gini ont tendance à favoriser les attributs qui ont un grand nombre de valeurs distinctes. C'est pourquoi on calcule le ratio de gain qui est utilisé pour déterminer la qualité d'un fractionnement. Chaque critère de fractionnement a sa propre signification et utilisation en fonction de ses caractéristiques et du type d'attributs (JIN, DE-LIN et FEN-XIANG 2009). L'algorithme C4.5 est basé sur l'entropie de Shanon, Info Gain et Ratio Gain (cf. section 3.3.2.2)).

## 5.5.2 L'algorithme C4.5

Cet algorithme a été proposé en 1993, par Ross Quinlan (QUINLAN 1996), pour améliorer l'algorithme ID3 (JIN, DE-LIN et FEN-XIANG 2009). L'une des limites d'ID3 est qu'il est trop sensible aux caractéristiques ayant un grand nombre de valeurs. Cette difficulté a été résolue avec l'algorithme C4.5, qui est donc une extension d'ID3. Pour surmonter ce problème, C4.5 permet de mesurer un ratio de gain. Comme pour ID3, les données sont triées à chaque nœud de l'arbre pour déterminer le meilleur attribut de division. Il utilise la méthode d'impureté du rapport de gain pour évaluer l'attribut de division (JIN, DE-LIN et FEN-XIANG 2009). Les arbres de décision sont construits dans C4.5 en manipulant un ou plusieurs ensembles de données d'apprentissage comme dans ID3. À chaque nœud de l'arbre, le C4.5 choisit l'attribut le plus efficace en termes de division de l'ensemble des échantillons en sous-ensembles enrichis dans chaque classe. Son critère est le gain normalisé d'information qui résulte du choix d'un attribut pour la division des données. L'attribut présentant le gain d'information normalisé le plus élevé est choisi pour la prise de décision.

### 5.5.2.1 Répartitions du C4.5

Dans un problème de classification, il faut trouver les critères de distribution nécessaires pour construire un arbre de décision où :

- $C$  présente la classe de variable,
- $\{x_1, x_2, \dots, x_n\}$  définit l'ensemble des critères et
- $X$  est le critère général.

En effet, le critère de fractionnement de l'info-gain (le critère de fractionnement ID3) est remplacé par un critère de ratio info-gain qui pénalise les variables multi-états. Le modèle C4.5 implique une procédure plus complète définie pour exploiter avec des variables continues et des données manquantes. Il implique un élagage ultérieur complexe. Ce dernier est introduit pour améliorer les résultats et obtenir des structures moins complexes. Le critère de division de ce modèle est appelé le ratio Info-Gain (IGR) (Equation 5.19).

$$IGR(C, X) = \frac{IG(C, X)}{H(x)} \quad (5.19)$$

Où  $H(X)$  est définie par l'équation (3.2) et  $IG(C, X)$  est définie par l'équation (3.5).

### 5.5.2.2 Attributs de valeur inconnue

La construction de l'arbre de décision permet de gérer des données pour lesquelles certains attributs ont une valeur inconnue en évaluant le gain ou le ratio de gain pour un tel attribut en ne considérant que les enregistrements pour lesquels cet attribut est défini (JIN, DE-LIN et FEN-XIANG 2009). En utilisant un arbre de décision, il est possible de classer les enregistrements dont la valeur est inconnue en estimant les probabilités des différents résultats.

### 5.5.2.3 Valeur des attributs sur un intervalle continu

Avec l'algorithme C4.5, la gestion des variables continues se fait comme suit : Tout d'abord, il faut supposer que l'attribut  $C_i$  appartient à un intervalle continu et examiner les valeurs de cet attribut dans les données d'apprentissage. Ensuite, on doit placer ces valeurs dans l'ordre croissant,  $A_1, A_2, \dots, A_m$ . Pour chaque valeur, il faut faire des partitions entre les enregistrements qui ont des valeurs inférieures ou égales à  $A_j$  et les valeurs supérieures. Pour chaque partition, on calcule le gain, ou le ratio de gain et on sélectionne la partition qui maximise le gain.

### 5.5.2.4 Élagage

L'élagage assure la génération d'un arbre de décision et son bon fonctionnement avec les données de formation créées. En effet, un arbre surchargé par des données est trop sensible au bruit. Par conséquent, le traitement de nouveaux échantillons invisibles n'est plus possible. L'arbre doit être construit de manière à réduire le taux d'erreur de prédiction. L'élagage (QUINLAN 1996) est une technique de ML qui permet de réduire la taille des arbres de décision en éliminant les sections de l'arbre qui ne permettent pas de classer les instances. Les objectifs de l'élagage sont la réduction de la complexité du classifieur final et de "l'over-fitting" pour avoir une meilleure précision de prédiction ainsi que l'élimination des sections qui peuvent être basées sur des données erronées.

### 5.5.2.5 C4.5 pour orienter les patients

En prenant en compte les notions mentionnées ci-dessus, nous adaptons l'algorithme C4.5 à notre modèle de prédiction d'orientation des patients. Ce dernier possède trois outputs (Circuit court, Circuit long, Déchocage) et les données entrantes sont les suivantes : heure d'arrivée, moyen d'arrivée, motif de venue, antécédents, âge, fréquence cardiaque, fréquence respiratoire, saturation O2, pression artérielle, température, code CCMU et orientation post triage. Pour la phase d'apprentissage, nous entraînons 221 927 cas et pour la phase de validation 110 964 cas. Les résultats, qui sont détaillés dans le chapitre 6, sont remarquables mais le modèle proposé a tout de même des limites :

- Ce modèle construit des branches vides ; c'est l'étape la plus cruciale pour la génération de règles dans le C4.5. Nous avons trouvé de nombreux nœuds avec des valeurs nulles ou proches de zéro. Ces valeurs ne contribuent pas à la génération de règles et n'aident pas

à construire une classe pour la tâche de classification. Au contraire, elles rendent l'arbre plus grand et plus complexe (JIN, DE-LIN et FEN-XIANG [2009]).

- Le phénomène du sur ajustement « Over fitting » se produit lorsque le modèle de l'algorithme capte des données présentant des caractéristiques inhabituelles. En général, l'algorithme C4.5 construit des arbres et fait croître ses branches "juste assez profondément pour classer parfaitement les exemples d'apprentissage". Cette stratégie donne de bons résultats lorsque les données sont exemptes de bruit. Mais la plupart du temps, cette approche surestime les exemples de formation avec des données bruitées comme dans notre cas puisque nous utilisons des données cliniques. Actuellement, il existe deux approches largement utilisées pour résoudre le problème de sur ajustement dans le cadre de l'apprentissage automatique par arbre de décision (JIN, DE-LIN et FEN-XIANG [2009]).
- Ce modèle est sensible au bruit.

Alors, pour traiter ce problème qui est essentiellement lié à la qualité des données, nous proposons une nouvelle méthode basée sur l'algorithme C4.5 et l'entropie de la théorie de Dempster Shafer afin d'améliorer la qualité des données et réduire le taux des faux positifs. Nous présentons cette méthode dans ce qui suit.

### 5.5.3 L'algorithme D-C4.5 proposé

Nous présentons dans cette partie une extension de l'algorithme C4.5, baptisée **D-C4.5**, basée sur l'entropie de Jirousek (Entropie basée sur la théorie de Dempster) et l'algorithme C4.5. Cette approche est une technique d'arbre de décision. Nous détaillons dans ce qui suit les spécificités de cet algorithme.

#### 5.5.3.1 Rapport de gain d'information sur l'incertitude UIGR

La méthode de construction d'arbre dans le D-C4.5 est similaire à l'algorithme C4.5 de Quinlan (QUINLAN [1996]). La principale différence est que le D-C4.5 calcule les entropies des caractéristiques et de la variable de classe en utilisant la théorie D-S (cf. section [2.6.4.3]). Contrairement à la procédure d'arbre de décision, une mesure de l'incertitude des variables est utilisée pour définir un nouveau critère de fractionnement. Ainsi, une fonction de masse est calculée pour chaque critère. De cette façon, le D-C4.5 considère que l'ensemble de formation n'est pas très fiable car il peut être affecté par l'incertitude de la classe ou de l'attribut qui peut être causée par la qualité de la source de données. Ainsi, le D-C4.5 peut être considéré comme une méthode appropriée pour les domaines incertains. Le D-C4.5 remplace le critère de division du ratio info-gain de C4.5 par le critère de division de l'UIGR (Uncertainty Info Gain Ratio). Ce critère peut être défini comme suit : dans un problème de classification, nous considérons que la variable  $C$  est la variable de classe (attribut),  $\{x_1, \dots, x_m\}$  est l'ensemble des caractéristiques (Instances), et  $x$  est une caractéristique. L'UIGR (Uncertainty Info Gain Ratio) est donc défini par l'équation ([5.20]) suivante :

$$UIGR(C, X) = \frac{UIG(C, X)}{J(x)} \quad (5.20)$$

Où le gain d'information sur l'incertitude (UIG) est égal à l'équation (5.21) suivante :

$$IGR(C, X) = J(C) - \sum_{i=1}^n P_j(X = x_j) * J(C|X = x_j) \quad (5.21)$$

Où  $P_j(X = x_j)$  est une distribution de probabilité qui appartient à l'ensemble de données  $X$  et  $J(X)$  est l'entropie de Jirousek, nous supposons que  $m$  est le BPA (cf. section 2.6.4.3) de  $X$  et  $a \in x$  (Equation 5.22).

$$J(x) = H(PIP_m(x)) + DP(m(x)) = \sum_{x \in \Omega_x} PIP_m(x) \log \frac{1}{PIP_m(x)} + \sum_{a \in \Omega_a} m(a) \log(|a|) \quad (5.22)$$

Le calcul de l'entropie de Jirousek (JIROUŠEK et SHENOY 2018) est basé sur la fonction de masse de probabilité (FMP)  $m$  et se compose de deux éléments. La première composante est l'entropie de Shannon de  $PIP_m$  (Equation 5.23) qui présente la transformation de plausibilité de  $m$ , et la deuxième composante comprend l'entropie de Dubois and Prade (DUBOIS et PRADE 1987) associée aux ensembles focaux non squelettiques de  $m$ . Cette entropie ne capte que la partie non spécifique de l'incertitude.

$$PIP_m(x) = K^{-1} Q_m(x) = K^{-1} Pl_m(x) \quad (5.23)$$

Pour tout  $x \in 2^\Omega$ , où  $K$  (Equation 5.24) est une constante de normalisation qui garantit que  $PIP_m$  est un PMF.

$$K = \sum_{x \in 2^\Omega} (-1) Pl_m(x) \quad (5.24)$$

Pour tout  $x \in 2^\Omega$ ,  $Pl_m(x)$  est la fonction de plausibilité de Demspter Shafer défini par l'équation 2.10 (cf. section 2.6.4.3).

Alors, le critère UIGR est différent des critères classiques. Il est similaire à l'IIGR et basé sur le principe de l'entropie maximale (JIROUŠEK et SHENOY 2018). Ce principe indique que la distribution de probabilité ayant l'entropie maximale, compatible avec les restrictions disponibles, doit être choisie. Ainsi, l'utilisation de la fonction d'entropie maximale dans la procédure de construction de l'arbre de décision (ABELLIN et MORAL 2005) et la définition de la distribution de probabilité (DP) sont justifiées. Mais ce critère se base principalement sur l'entropie de Jirousek de BPA qui présente une combinaison de l'entropie de Shannon d'une fonction de masse de probabilité (PMF) équivalente et qui capture la mesure de conflit d'entropie et la mesure de non-spécificité (ou Hartley) d'entropie. Le PMF équivalent est celui obtenu en utilisant la transformation de plausibilité (VOORBRAAK 1989).

### 5.5.3.2 Inducteur d'arbre D-C4.5

Dans cette partie, nous nous focalisons sur les aspects les plus importants de cet inducteur d'arbre proposé. Nous nous basons sur l'idée principale introduite dans (QUINLAN 1996) et nous remplaçons l'entropie de Shanon par l'entropie de Jirousek (Equation 5.22). Le processus utilisé pour inférer un arbre de décision est principalement spécifié par les étapes suivantes :

1. Sélectionner l'attribut à insérer dans un nœud et le branchement selon les critères utilisés (critères de division).
2. Déterminer les critères pour arrêter la ramification de l'arbre.

3. Attribuer une étiquette de classe ou une distribution de probabilité aux nœuds feuilles.
  4. Déclencher le processus de post-élagage adopté pour simplifier et optimiser l'arborescence.
- Ces étapes sont détaillées dans ce qui suit.

**5.5.3.2.1 Critères de fractionnement** Le critère du ratio de gain d'information sur l'incertitude (UIGR) a été introduit pour l'inducteur d'arbre, qui pénalise les variables avec de nombreux états. Ce score utilise l'entropie de Dempster pour gérer l'incertitude des données. Nous calculons l'UIGR qui normalise le gain d'information d'un attribut  $X$  par l'entropie Jirousek (JIROUŠEK et SHENOY 2018). Dans cette étape, nous sélectionnons l'attribut ayant le score de rapport de gain d'information le plus élevé et dont le score de gain d'information est supérieur aux scores moyens de gain d'information des attributs fractionnés valides. Les **attributs fractionnés valides** sont ceux qui sont numériques ou qui ont moins de trente pour cent du nombre d'instances dans cette branche.

**5.5.3.2.2 Critère d'arrêt** En utilisant la même méthode que dans l'algorithme C4.5, la ramification d'un arbre de décision est arrêtée lorsqu'il n'y a pas d'attribut avec un score de rapport de gain d'information positif ou lorsqu'il y a un nombre minimum d'instances par feuille qui est généralement fixé à 2.

**5.5.3.2.3 Traitement des attributs numériques** L'inducteur d'arbre manipule les attributs numériques avec une approche très simple. Dans cette méthode, seuls les attributs de division binaires sont considérés et chaque point de division possible est évalué. Finalement, le point qui induit une partition des échantillons avec le score de division basé sur le gain d'information le plus élevé est sélectionné.

**5.5.3.2.4 Traitement des attributs manquants** Les valeurs manquantes sont supposées être distribuées de manière aléatoire (hypothèse "Missing at Random"). Afin de calculer les scores, les instances sont divisées en morceaux. Le poids initial d'une instance est égal à l'unité, mais lorsqu'il diminue, une branche reçoit un poids égal à la proportion d'instances qui appartiennent à cette branche (la somme des poids est égale à 1). Lors de la réalisation de prédictions comme C4.5, le D-C4.5 marginalise la variable manquante en fusionnant les prédictions de toutes les branches possibles qui sont cohérentes avec l'instance (il y a plusieurs branches car elle a une valeur manquante) en utilisant leurs poids calculés précédemment.

**5.5.3.2.5 Processus de post-élimination** Bien qu'il existe de nombreuses et différentes propositions pour effectuer un processus de post-élagage d'un arbre de décision (BRODLEY et UTGOFF 1992), nous adoptons la même technique que celle utilisée par le C4.5, appelée "taille d'erreur pessimiste". Cette méthode calcule une limite supérieure du taux d'erreur estimé d'un sous arbre donné en utilisant une correction de continuité de la distribution binomiale. Lorsque la limite supérieure d'un sous arbre attaché à un nœud donné est supérieure à la limite supérieure des erreurs produites par les estimations de ce nœud (en supposant qu'il agit comme une feuille),

alors ce sous arbre est élagué.

### 5.5.3.3 Description de l'algorithme D-C4.5

Le D-C4.5, décrit par l'algorithme (3) ci-dessous, est une technique d'apprentissage automatique basée sur l'algorithme C4.5 (qui est déjà une version améliorée de l'algorithme ID3)(SALZBERG [1994]) générant un arbre de décision. L'algorithme que nous proposons dans le cadre de cette thèse, le D-C4.5, diffère de l'algorithme C4.5 dans le calcul des entropies. Nous remplaçons l'entropie de Shanon (Equation) par l'entropie de Jirousek de Dempster.

Lors de la construction d'un arbre de décision, l'algorithme peut accepter des attributs continus et catégoriques (qualitatives). En raison d'un bruit élevé ou d'un ensemble de données d'apprentissage très détaillé, l'algorithme D.C4.5 utilise une technique améliorée d'élagage de l'arbre pour réduire l'erreur de classification. En outre, cet algorithme utilise également une méthode de division et de conquête gourmande pour induire récursivement des arbres de décision contenant des attributs de base de données/ensemble de données pour une classification ultérieure. La classification est un paramètre de performance majeur pour tout arbre de décision. L'erreur de classification peut être définie comme le taux de faux positifs et de faux négatifs (Wu et al. [2008]). L'algorithme D-C4.5 peut accepter le continuum et les attributs catégoriels lors du développement d'un arbre de décision. Cet arbre de décision peut être développé en utilisant l'approche descendante ou ascendante. En outre, l'algorithme du classificateur D-C4.5 est divisé en un ensemble de données basé sur les différentes valeurs d'attributs des données actuelles pour séparer la prédiction probable. L'arbre de décision contient de nombreux nœuds de décision et nœuds feuilles, où les nœuds de décision déterminent les attributs de test, tandis que les nœuds feuilles représentent les valeurs de classe (SAHU et MEHTRE [2015]). Chaque chemin dans les arbres de décision commence de la racine à la feuille. Le nœud détermine la règle. Notre algorithme, le D-C4.5, peut développer son arbre de décision en fonction des informations des valeurs théoriques des attributs des données d'entraînement actuelles. En outre, chaque caractéristique ou attribut estime séparément la valeur du gain et le processus de calcul se poursuit jusqu'à ce que le processus de prédiction soit terminé. Une caractéristique appropriée est définie comme la caractéristique qui donne plusieurs informations sur les instances de données. Cette caractéristique peut être classée comme nœud racine si elle consiste en un gain maximal d'informations. Après avoir sélectionné le nœud racine, cet algorithme peut diviser les données de formation en plusieurs sous-ensembles qui correspondent aux différentes valeurs d'une caractéristique choisie et ce processus est répété pour chaque sous-ensemble jusqu'à ce que chaque sous-ensemble soit affecté à une classe. En effet, nous intégrons notre modèle de données dans le D-C4.5 pour modéliser la prédiction d'orientation post triage dans le SUA. Nous utilisons notre base de données issue du CHU de Lille qui contient 336 254 cas. Nous entraînons 66% de cette base pour l'apprentissage et 33% pour la validation et le test. Nous gardons les mêmes types et natures des données entrantes du modèle C4.5 usuel et les mêmes outputs. L'algorithme D-C4.5 nous permet donc de :

- construire des modèles faciles à comprendre.
- utiliser des valeurs catégorielles et des valeurs continues.
- fournir une technique connue sous le nom de l'imputation, qui traite les valeurs manquantes.
- résoudre le problème des valeurs manquantes, qui est une caractéristique importante.
- envisager un processus d'élagage de l'arbre, qui permet de construire des arbres de petite taille et d'éviter un ajustement excessif des données.



- gérer l'incertitude et l'imprécision des sources de données en utilisant l'entropie basée sur la théorie D-S.
- procéder au remplacement de sous-arbres par une feuille qui réduit l'erreur de classification a posteriori.

---

**Algorithme 3 : D-C4.5 algorithm**


---

```

1 Input
2  $C_{n_i}^i$  : Vecteur de variables d'entrée (heure d'arrivée, moyen d'arrivée, motif d'arrivée, antécédents, âge, fréquence cardiaque,
   fréquence respiratoire, saturation en O2, pression sanguine, température, code CCMU, orientation post-triage);
3 Output
4  $N$  : L'arbre de décision;
5 Initialization
6  $i \leftarrow 0$ ;
7  $N \leftarrow 0$ ;
8 Créer un noeud racine  $N$  ;
9 if  $T \in C$  then
10 |    $noeud_{feuille} \leftarrow N$  ;
11 |   Marquer  $N \in C$ ; Return  $N$ ;
12 end
13 for  $i$  to  $N$  do
14 |   Calculer  $UIGR(C_i, X_i)$  avec l'équation 5.20;
15 |    $t \leftarrow attribut_{est}$  ;
16 |    $Nt \leftarrow \max UIGR$  ;
17 |   if  $Nt = Continu$  then
18 |   |   Trouver le seuil ;
19 |   end
20 |   for  $t \in T$  do
21 |   |   if  $t = 0$  then
22 |   |   |   Le fils de  $N$  est un noeud feuille;
23 |   |   |   else
24 |   |   |   |   fils de  $N = dTreeT$  ;
25 |   |   |   end
26 |   |   end
27 |   end
28 |   Calculez le taux d'erreur de classification du noeud  $T$  ;
29 |   Return  $N$  ;
30 end

```

---

L'approche de l'arbre de décision proposée est un modèle de classification qui assure la gestion de l'incertitude des données. Nous implémentons ce modèle en se basant sur les données réelles du CHU de Lille. Les résultats sont présentés et discutés dans le chapitre suivant.

## 5.6 Conclusion

Dans ce chapitre, nous présentons une étude statistique dont l'objectif est d'acquérir une compréhension avancée et une meilleure connaissance du fonctionnement des urgences. Cette étude est suivie des modèles de prédiction qui permet de décrire la réalité de notre terrain en exploitant ses données réelles historiques. En outre, nous décrivons des nouvelles approches basées sur le ML et la théorie de Dempster qui permet de gérer l'incertitude des données. Ces modèles sont proposés afin d'optimiser les résultats de prédiction et de classification et réduire le risque d'erreur. Des résultats de simulation utilisant une base de données réelles du SUA et prouvant l'intérêt des approches proposées sont présentés dans le chapitre suivant.

# Expérimentations et Résultats

## 6.1 Introduction

Dans ce chapitre, nous présentons les différents résultats d'expérimentations des approches proposées dans les chapitres 4 et 5. Ces approches ont pour objectif d'optimiser la qualité des soins dans les SUA et de réduire la tension en utilisant une base de données (BD) réelle fournie par notre partenaire du CHU de Lille dans le cadre du projet OIILH (2019-2020). Ce projet est soutenu par l'agence française de la recherche et référencé par ANR-18-CE19-0019. La base fournie porte sur quatre ans (juin 2016 - juin 2020) et a été extraite par le logiciel ResUrgences<sup>1</sup>. Les résultats de l'expérimentation sont présentés pour prouver à la fois l'intérêt de notre approche hybride qui regroupe les approches symboliques et subsymboliques pour la prédiction de l'admission dès l'arrivée du patient, l'affluence des arrivées, les orientations post triage, la tension et aussi aider les infirmiers de triage à classer les patients selon leur degré de sévérité.

## 6.2 Expérimentations et résultats du modèle de prédiction proposé pour l'hospitalisation du patient dès son arrivée aux urgences

Dans cette partie, nous présentons les résultats de notre approche proposée (cf. section 5.3.2) en la comparant avec d'autres modèles de ML. Notre base de données réelle comprend les données de triage et d'orientation entre juin 2016 jusqu'à juin 2020 (Figure 5.1). Cette base de données, que nous détenons actuellement, contient toutes les données pertinentes pour notre système SATGT. Nous avons filtré puis normalisé ces données afin de faciliter l'utilisation de la méthode proposée sur des données homogènes par nos ontologies de domaine (cf. section 4.4). Pour implémenter l'approche proposée, nous définissons les variables de décision pour l'admission des patients aux urgences. Ainsi, le cadre de discernement  $\Omega$  est l'ensemble des décisions ( $d_z$ ) pour chaque patient aux urgences  $P_i$  où ( $z \in \{1, 2\}$ ) :  $d_1$  est la décision de retour

1. L'éditeur de ce logiciel est Berger Levrault qui est notre partenaire industriel dans le projet ANR OIILH.

Data $j$	$m_j^1(d_1)$	$m_j^1(d_2)$	$m_j^1(d_\Omega)$
1 : AM = SAMU	0.21	0.44	0.35
2 : PS = Valide	0.35	0.39	0.26
3 : Age = 70	0.33	0.48	0.19
4 : MH = cardio	0.31	0.35	0.34
5 : ESI = 2	0.18	0.59	0.23
6 : CC = malaise	0.29	0.41	0.30

TABLEAU 6.1 – Les BBA des données médicales du patient  $P_1$ 

$WBA_{1,j}^i$	$P_1$	$P_2$	$P_3$	$P_4$	$P_5$
$WBA_{1,1}^i$	0.657	0.266	0.144	0.122	0.238
$WBA_{1,2}^i$	0.153	0.544	0.376	0.355	-0.123
$WBA_{1,3}^i$	0.789	-0.78	0.576	0.78	0.345
$WBA_{1,4}^i$	0.117	-0.01	-0.876	-0.87	0.45
$WBA_{1,5}^i$	1.782	0.122	0.456	0.233	-0.456
$WBA_{1,6}^i$	0.4	0.144	-1.33	0.877	1.12

TABLEAU 6.2 – Le calcul des WBA pour la couche entrante

à domicile et  $d_2$  est l'hospitalisation. Pour le jeu de données, nous avons utilisé 225 392 cas de chaque classe  $d_z$  pour l'entraînement (la phase de l'apprentissage) et 111 064 cas de patients pour le test. Notre base de données contient 59% de patients qui sont rentrés à leur domicile et 41% de patients hospitalisés. Les sources d'information présentent les données médicales d'entrée : âge, statut du patient (PS), mode d'arrivée (AM), ESI (Emergency Severity Index), température (T), Motifs de venues (CC), Antécédents (MH), etc.

### 6.2.1 Expérimentations : phase 1

D'abord, nous expliquons le fonctionnement de notre algorithme DDMLP (cf.section 5.3.2) étape par étape avec un problème de petite taille avec 5 patients. Le tableau 6.1 montre le BBA de chaque entrée médicale  $x_j^1$  du patient  $P_1$  en respectant l'équation (2.5).

Ensuite, l'algorithme calcule la WBA de chaque paramètre médical pour chaque patient  $P_i$  avec l'équation (5.3) (cf. section 5.3.2.1.1) (tableau 6.2).

Dans cette étape, l'équation 2.7 (cf.section 2.6.4.3) est utilisée pour calculer la masse combinée de chaque source. Le tableau 6.3 présente la combinaison entre chaque couple de sources successives. Par exemple,  $j = 1$  correspond à la combinaison des masses entre les sources AM (SAMU) et (Valide). Ensuite, nous calculons la fonction d'activation en utilisant les sorties de la couche précédente  $a_{1,j}^i$ .

Maintenant, la WBA est calculée dans la couche cachée en utilisant l'équation 5.5 (cf.section 5.3.2.1.2) (tableau 6.4).

Ensuite, nous calculons les sorties  $a_{2,j}^i$  en fonction des poids  $WBA_{2,j}^i$ . Après,  $W_{3,1}^1$  est choisi aléatoirement pour calculer l'entrée de la couche de sortie  $a_{2,1}^1$  (tableau 6.5).

Enfin, la fonction sigmoïde est déployée pour calculer l'entrée de cette dernière couche. Nous pouvons voir les résultats de la décision dans le tableau 6.6 ci-dessous. Ce tableau compare

## 6.2. Expérimentations et résultats du modèle de prédiction proposé pour l'hospitalisation du patient dès son arrivée aux urgences

Data $j$	$S_{2,j}$	$m_j^1(d_1)$	$m_j^1(d_2)$	$m_j^1(d_\Omega)$
1	-0.839	0.018	0.148	0.09
2	-0.795	0.081	0.040	0.059
3	-0.745	0.142	0.02	0.05

TABLEAU 6.3 – Le calcul des neurones entrants de la couche cachée

$WBA_{2,j}^i$	$P_1$	$P_2$	$P_3$	$P_4$	$P_5$
$WBA_{2,1}^i$	1.44	0.79	0.03	-2.44	1.74
$WBA_{2,2}^i$	-0.694	-1.33	-2.07	0.22	0.33
$WBA_{2,3}^i$	-2.44	0.56	0.66	1.42	-0.66

TABLEAU 6.4 – Les poids de la couche cachée

les résultats de notre modèle de prédiction des patients avec l'algorithme MLP (Multi couches perceptron) usuel avec les données réelles de notre base de données du SUA (EDDB) qui a été prise pour chaque patient  $P_i$  où  $1 < i < 5$ .

Cette simulation montre que notre approche est efficace sur une petite instance de problème (5 patients). En effet, le DDMLP a fait une seule erreur par rapport au modèle MLP qui en a fait quatre par rapport aux données réelles de notre BD (EDDB). Cet exemple détaille le processus de calcul au sein de l'algorithme DDMLP que nous proposons à chaque étape en utilisant la théorie de Dempster Shafer (D-S). La simulation montre l'efficacité de notre méthode et sa rapidité dans la phase d'apprentissage.

### 6.2.2 Expérimentations : phase 2

Maintenant, nous mettons en place plusieurs expériences afin de comparer notre méthode avec d'autres techniques de prédiction. Dans ce contexte, nous réalisons deux expérimentations, la première montre la contribution de notre algorithme DDMLP par rapport au MLP usuel et l'algorithme DMLP (Dynamic multi layers perceptron) de Mustapha (MUSTAFA, ALLEN et APPIAH 2019) et la seconde compare notre modèle avec quatre autres techniques usuelles d'apprentissage automatique.

#### 6.2.2.1 1ère partie : Comparaison DDMLP vs DMLP et MLP

Dans cette partie, nous comparons notre algorithme DDMLP par rapport au MLP usuel et l'algorithme DMLP (Dynamic multi layers perceptron) de (MUSTAFA, ALLEN et APPIAH 2019). Pour ce faire, nous choisissons les valeurs de paramètres suivantes : Taux d'apprentissage = 0.001

$N_s$	$P_1$	$P_2$	$P_3$	$P_4$	$P_5$
$a_{2,1}1$	1.158	0.6	0.92	-0.82	0.21
$S_3$	0.76	0.645	0.71	0.305	0.55

TABLEAU 6.5 – Le calcul de la couche sortante

Méthodes	$P_1$	$P_2$	$P_3$	$P_4$	$P_5$
MLP	0	0	0	0	1
DDMLP	1	1	1	0	1
EDDB	1	1	1	0	0

TABLEAU 6.6 – Les résultats de la comparaison entre l’approche proposée, le MLP usuel et les données réelles

Méthodes	Précision	Sensitivité	Spécificité
MLP	0.59	0.53	0.57
DMLP	0.71	0.69	0.67
DDMLP	0.83	0.79	0.81

TABLEAU 6.7 – Les résultats d’expérimentations après 20 époques

et Batch Size= 5. De plus, nous exécutons 20 époques l’algorithme de back propagation (BP) pour chaque méthode, puis, nous montrons la sensibilité, la sensibilité et la précision de classification dans le tableau 6.7. Les résultats de cette expérience prouvent que le modèle proposé est plus précis par rapport à l’algorithme MLP classique et le DMLP. Nous remarquons que notre modèle a obtenu une haute performance après 20 époques. En revanche, l’algorithme MLP et DMLP sont encore loin de l’optimisation. En effet, les résultats obtenus montrent que notre méthode réduit les erreurs. Donc, le réseau de DDMLP est plus optimisé avec moins d’erreurs après 20 époques (correction des erreurs) de l’étape d’apprentissage (algorithme BP).

Les algorithmes MLP et DMLP ne dépassent pas 0,59 et 0,67 de précision et notre modèle proposé donne une précision égale à 0,83. L’algorithme DMLP de (MUSTAFA, ALLEN et APPIAH 2019) est meilleur que l’algorithme usuel MLP grâce à son dynamisme et sa gestion des données manquantes mais notre modèle proposé, le DDMLP, reste plus efficace que les modèles DMLP et MLP. La figure 6.1 représente les courbes qui décrivent le début de la phase BP pour les trois algorithmes : MLP, DMLP et DDMLP. Nous pouvons remarquer la rapidité du DDMLP qui est très élevée par rapport aux deux autres modèles.

### 6.2.2.2 2ème partie : Comparaison DDMLP vs CART, RF, KNN et LR

Dans la deuxième expérimentation, nous comparons notre méthode DDMLP aux algorithmes CART de l’arbre de décision, RF (Random Forest), KNN (K-Nearest Neighbors) et LR (Régression logistique) (tableau 6.8). La courbe ROC (Figure 6.2) montre les résultats obtenus par les méthodes CART, KNN, RF, DDMLP et LR.

Méthodes	Précision	Sensitivité	Spécificité	Runtime (ms)
CART	0.61	0.71	0.59	12
LR	0.74	0.70	0.75	5
RF	0.79	0.81	0.77	8
KNN	0.75	0.76	0.72	10
DDMLP	0.89	0.92	0.88	9

TABLEAU 6.8 – Résultats de comparaison entre les méthodes CART, LR, RF, KNN et DDMLP

## 6.2. Expérimentations et résultats du modèle de prédiction proposé pour l'hospitalisation du patient dès son arrivée aux t

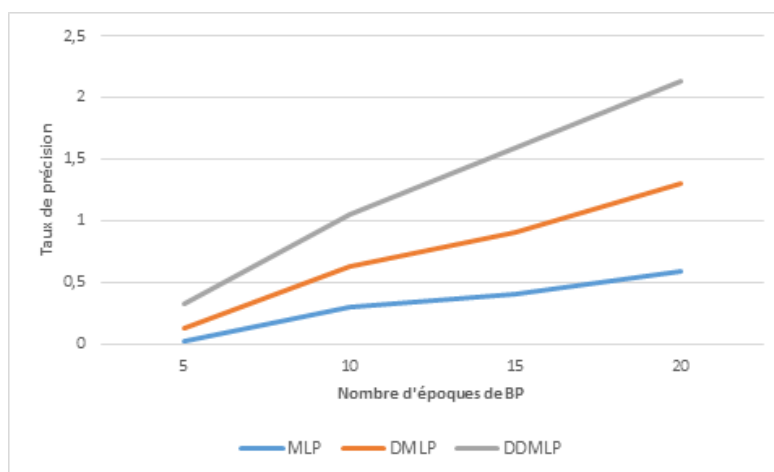


FIGURE 6.1 – Courbe de la phase BP pour les algorithmes MLP, DMLP, DDMLP




FIGURE 6.2 – Courbe de la phase BP pour les algorithmes MLP, DMLP, DDMLP

### 6.2.3 Discussions

Concernant la 2ème expérimentation, le tableau 6.8 et la courbe ROC montrent la performance de notre méthode par rapport aux autres. Visuellement, notre approche est plus efficace et plus précise que les autres méthodes de ML. Aussi, la spécificité et la sensibilité des autres méthodes montrent que le taux des faux positifs et des faux négatifs est très important par rapport à notre méthode. Ce résultat peut être argumenté par la gestion de l'incertitude qui améliore la qualité des données de notre modèle. Cette amélioration s'explique d'une part par la gestion des données manquantes et d'autre part en équilibrant le poids de l'information en fonction de son importance grâce à la théorie D-S. En effet, le calcul des poids au sein de l'algorithme D-S a été effectué en fonction de l'importance de l'information. Le calcul des poids au sein de notre algorithme DDMLP permet donc d'optimiser les résultats (tableau 6.8) et de minimiser les erreurs identifiées dans la phase amont. La gestion de l'incertitude des données utilisées améliore ainsi la précision de notre algorithme et réduit le nombre de faux positifs. Notre étude montre que l'apprentissage automatique peut prédire de manière robuste l'admission à l'hôpital lors du triage des urgences. La mesure de l'incertitude des données améliore la fiabilité et la performance prédictive des données utilisées en gérant les sources inhérentes. Ainsi, les données manquantes et non fiables réduisent l'efficacité des modèles de classification et augmentent le taux de faux positifs, ce qui prouve que l'approche que nous proposons pour gérer l'incertitude est plus efficace pour réduire le taux d'erreurs que les travaux existants. De plus, la vitesse d'apprentissage et la complexité font partie des limites majeures des réseaux de neurones mais le dynamisme et la nouvelle méthode de calcul des poids peuvent les améliorer.

Cependant, l'algorithme présente quelques limites qui peuvent être améliorées en intégrant notre ontologie de domaine (définie dans chapitre 4 (section 4.4)) pour pouvoir profiter des données textuelles qui contiennent des informations pertinentes sur l'état patient. Pour cela, il est utile d'ajouter une technique d'extraction des données textuelles qui est incluse dans notre ontologie. De plus, l'obtention de l'historique du patient est l'une des tâches les plus difficiles car chaque médecin le mentionne d'une manière différente. Ainsi, une base de données fiable, cohérente et précise peut mieux améliorer la performance et la précision des résultats de la classification. Nous détaillons cette partie plus tard, c'est-à-dire après les résultats expérimentaux liés à notre approche de prévision de l'affluence des patients.

## 6.3 Expérimentations et résultats du modèle de prévision de l'affluence des patients

Dans cette partie, nous présentons les résultats de l'expérimentation de notre approche ED-Deep MDPRL qui est capable à prédire l'affluence des patients en la comparant avec d'autres méthodes ML pour prouver sa performance. Comme expliqué précédemment, nous utilisons toujours notre BD du SUA du CHU de Lille pour notre étude expérimentale. Nous avons commencé par filtrer et normaliser cette BD afin de faciliter l'utilisation de la méthode proposée sur des données homogènes (par exemple, transformer des données textuelles en données binaires). Pour l'expérimentation, nous fixons la capacité  $N$  du SUA à  $N=32$  pour la prédiction des arrivées de patients. Pour le jeu de données, nous avons utilisé 22 429 instances pour la phase d'apprentissage et 11 214 pour la phase de test. Dans ce qui suit, nous testons d'abord le modèle proposé en le comparant avec un modèle RL (Reinforcement Learning), puis nous démontrons

Variabes	Valeur
Learning rate	$10^{-7}$
Epsilon	1
Epsilon decay	0.999
Epsilon min	$10^{-8}$
Discount factor	0.9999
Taille de la mémoire	2000
Itération	1000
Batch size	100

TABLEAU 6.9 – Les hyper paramètres de l'algorithme ED-Deep MDPRL

Méthode	Runtime (ms)	Précision
LSTM	35	79%
ANN	30.6	69%
LR	15	82%
ED-Deep MDPRL	21	92%

TABLEAU 6.10 – Les résultats de comparaison

ses avantages en le comparant avec d'autres méthodes existantes telles que l'ANN, le LSTM et l'ARIMA dans un deuxième temps.

Pour évaluer davantage notre modèle par rapport aux différentes méthodes de prévision, nous avons mis en place deux parties d'expériences. Nous implémentons d'abord le modèle proposé en le comparant avec un modèle RL (Reinforcement Learning). Ensuite, nous testons les algorithmes RL, LSTM et ANN pour prouver la performance de la méthode proposée en exposant le temps de calcul (min) et la précision de la prévision (%) dans le Tableau 6.10. En effet, l'algorithme ED-DEEP MDPRL a été codé en Python avec l'API Keras. Pour concevoir l'algorithme Deep Q-Learning (DQN), une architecture ANN entièrement connectée a été développée. Le nombre total des couches cachées est de 4 et le nombre de nœuds pour chaque couche est respectivement de 64, 32 et 3.

Comme fonction d'activation, l'unité linéaire redressée par fuite est utilisée pour toutes les couches. Pour tester le Deep-RL dans les SUAs, l'expérience a été conçue comme suit : Avant de comparer avec les autres méthodes, le Deep-RL doit être entraîné par l'ensemble de données. La définition de la valeur des hyper paramètres est essentielle (tableau 6.8), car elle détermine les performances du réseau Q profond. Cependant, trouver la valeur optimale est un défi en raison de l'espace de recherche étendu des hyper paramètres. Les valeurs du tableau 6.9 ont été trouvées en effectuant une recherche aléatoire, qui a donné les meilleures performances. La figure 6.3 montre la prévision des arrivées des patients sur soixante jours sélectionnés dans la BD de test (1er février 2019) en observant les données réelles avec les résultats prédits par notre modèle proposé. Ces derniers montrent une précision efficace de prévision de l'arrivée des patients lorsqu'ils sont comparés aux données observées en même temps. Notre modèle a pu détecter 10 pics d'augmentation ou de diminution du nombre des arrivées sur les 10 pics de la courbe des données observées. Ainsi, les résultats des deux courbes sont très proches, ce qui montre l'efficacité de la méthode proposée. De plus, le tableau 6.10 montre une précision plus efficace pour le modèle proposé par rapport aux autres modèles. Ce résultat peut être expliqué par la capacité du MDP à raisonner dans un environnement incertain et inconnu.






FIGURE 6.3 – Comparaison entre la méthode proposée et les données observées

De plus, les données historiques qui sont à la base des modèles ANN et LSTM sont des facteurs d'aide à la prévision mais ils ne peuvent pas donner des résultats efficaces sans utiliser d'autres facteurs (comme les facteurs climatiques) en temps réel. De plus, l'algorithme DQN est meilleur que le Q-Learning de RL car il a réussi de traiter le problème de surcharge de la mémoire (Tableau 6.9). Pour cela, le modèle proposé est plus précis que le RL. En ce qui concerne le temps de calcul, le RL est le meilleur mais celui du modèle proposé reste acceptable. Cette amélioration peut être due à la complexité de la conception de notre modèle et à l'importance du calcul dans celui-ci, de sorte que l'utilisation d'un réseau neuronal profond a également contribué à augmenter le temps de réponse. Mais, dans l'ensemble, le modèle proposé est plus efficace que les autres méthodes. Les résultats présentés dans cette étude indiquent que la méthode Deep RL aide les décideurs à prendre des décisions appropriées dans les situations de surpeuplement. Dans l'ensemble, les performances du RL sont meilleures que celles des méthodes de prédiction actuellement utilisées. Des tendances similaires ont été observées dans les différents résultats, ce qui implique que le Deep RL peut aider à prédire correctement le nombre des arrivées dans des situations normales et extrêmes. Un système de dossier médical électronique (DME) a été introduit dans les systèmes d'information des services des urgences des hôpitaux, dans lequel les données des patients sont collectées dans un système de BD. Ces données, représentant les caractéristiques des patients et de leur état de santé, permettant à notre algorithme d'apprendre une politique lui permettant de prédire le nombre de patients arrivant au service des urgences.

En fonction de ces caractéristiques, les hyperparamètres de l'algorithme doivent être ajustés pour obtenir une meilleure solution. En outre, il est nécessaire que l'algorithme avec la politique apprise passe par une phase de simulation avec des données aléatoires pour vérifier la validation. Une fois l'algorithme déployé, il est essentiel que les performances soient surveillées en permanence par les cliniciens et les ingénieurs en même temps. Pour faire face à une variété de changements dans une situation d'urgence, l'algorithme doit apprendre en permanence et doit être mis à jour sur une base ad hoc. De ce point de vue, l'algorithme peut aider les décideurs à prévoir des situations stressantes pour eux dans des environnements dynamiques et encombrés. La présente étude est limitée par les hypothèses formulées en raison du manque de données sur

les ressources médicales. Bien que le nombre de ressources médicales (nombre de boxes) soit flexible en fonction de la fenêtre temporelle, cette information n'était pas disponible dans la littérature.

Comme autres limites, notre étude se focalise sur le service des urgences alors que d'autres composantes liées à ce service, comme les salles d'opération et la salle d'attente, sont exclues. Sachant que les hypothèses susmentionnées puissent affecter la précision du modèle, les composantes des urgences incluses dans cette étude sont suffisantes pour représenter le test basé sur le Deep-RL. Cette étude peut être étendue pour tenir compte du déroutement des ambulances, qui affecte l'encombrement des urgences. L'intégration des urgences et des arrivées des ambulances peut représenter de manière plus réaliste les conditions d'encombrement des urgences. En outre, cette étude peut être abordée sous l'angle d'un modèle multi-agent Deep-RL intégrant d'autres facteurs, tels que les salles d'opération.

D'autres extensions sont possibles avec des technologies plus avancées pouvant prendre en considération la corrélation entre différents facteurs environnementaux externes tels que la température, la période de crise, etc.

Dans la partie qui suit, nous présentons les résultats expérimentaux du modèle d'aide au triage au profit du personnel de santé (proposé dans le chapitre 4 (section 4.4.2)). Ce dernier permet d'éviter la tension en améliorant la qualité des soins.

## 6.4 Expérimentations et résultats liés au modèle proposé d'aide au triage

Dans cette partie, nous présentons les résultats obtenus en implémentant le modèle d'aide au triage selon la méthodologie proposée (chapitre 4). Nous étudions les mesures de performance possibles pour prouver la pertinence de la solution proposée pour le problème de triage dans les SUAs.

### 6.4.1 Etude expérimentale

Pour notre expérimentation, nous utilisons notre BD réelle du CHU de Lille. L'objectif principal de cette étude est de créer un modèle de performance pour aider les infirmiers à trier les patients à leur arrivée. La méthodologie proposée est basée principalement sur les ontologies de domaine OntoTriS (cf. section 4.4.1) et FOTS (cf. section 4.4.2). Nous adaptons un classifieur basé sur l'algorithme ANN en intégrant le score F-ESI 1.0 (cf. section 4.4.1.4) dans un premier temps avant d'intégrer la deuxième version du score c'est-à-dire le F-ESI 2.0 (cf. section 4.4.2.2.2). L'expérience établie est composée de deux parties : d'abord, nous testons notre modèle en le comparant avec plusieurs méthodes usuelles d'apprentissage automatique telles que : KNN, SVM, CART et RF (Random Forest), LR (Logistic Regression), NB (Naive Bayes). Ensuite, nous testons ces méthodes avec les deux ontologies du domaine et les scores flous. Les résultats de la première partie de l'expérience est présentée dans le tableau 6.11. D'après les résultats obtenus, nous pouvons constater que le meilleur classificateur est l'algorithme ANN avec un taux de précision de 80%. Bien que cet outil soit considéré comme une boîte noire, il donne tout de même les meilleurs résultats par rapport aux autres techniques d'apprentissage automatique. Le classificateur NB a aussi également donné des résultats acceptables qui peuvent être améliorés.

Algorithme	Test AUC	Sensitivité	Spécificité	Précision	FP Rate	Runtime (ms)
RF	0.657	0.77	0.32	0.696	0.58	6.6
CART	0.378	0.80	0.20	0.64	0.80	7
SVM	0.57	0.80	0.44	0.75	0.66	10
NB	0.86	0.78	0.37	0.74	0.63	14
KNN	0.58	0.71	0.19	0.62	0.81	12
LR	0.69	0.80	0.20	0.64	0.80	8
ANN	0.86	0.84	0.83	0.80	0.17	11

TABLEAU 6.11 – Résultats de classifieurs

Système	Test AUC	Sensitivité	Spécificité	Précision	FP Rate	Runtime
ANN	0.86	0.84	0.83	0.80	0.17	11
ANN+ Ontolo	0.934	0.833	0.941	0.844	0.059	16
OntoTriS+ANN+ F-ESI 1.0	0.959	0.860	0.961	0.922	0.123	12
FOTS+ANN+ F-ESI 2.0	0.977	0.870	0.968	0.926	0.012	9
NB	0.86	0.78	0.37	0.74	0.63	14
NB+ Onto	0.718	0.792	0.375	0.670	0.125	20
OntoTriS+NB+ F-ESI 1.0	0.881	0.840	0.541	0.815	0.152	22
FOTS+NB+ F-ESI 2.0	0.898	0.849	0.564	0.833	0.436	19
KNN	0.58	0.71	0.19	0.62	0.81	12
KNN+ Onto	0.643	0.792	0.417	0.629	0.083	18
OntoTriS+KNN+ F-ESI 1.0	0.721	0.854	0.621	0.831	0.111	20
FOTS +KNN+ F-ESI 2.0	0.732	0.866	0.597	0.845	0.103	17
LR	0.69	0.80	0.20	0.64	0.80	8
LR+ Onto	0.663	0.75	0.250	0.563	0.750	10
OntoTriS+LR+ F-ESI 1.0	0.821	0.864	0.752	0.796	0.110	13
FOTS + LR + F-ESI 2.0	0.834	0.857	0.467	0.854	0.133	7

TABLEAU 6.12 – Comparaison du système proposé avec les autres techniques de ML

Après le premier test, nous observons que le taux des faux positifs est de moins en moins important donc les données non structurées influencent la qualité des résultats obtenus. Nous pouvons ainsi identifier la différence entre l'utilisation brute d'un algorithme ML et l'intégration de cet algorithme dans le modèle proposé. Le tableau 6.12 prouve que l'intégration de l'ontologie pour améliorer le modèle de classification et la fuzzification augmente l'efficacité et la précision.

Ainsi, avec le système que nous proposons, le taux de précision est de 85% avec RL, 84% avec KNN, 82% avec NB et 96% avec ANN. Nous avons fixé notre choix sur l'ANN mais les autres se sont également améliorés par rapport à l'utilisation d'un classifieur seul. Dans la figure 6.4, la courbe (a) correspond au modèle basé sur le KNN, la courbe (b) pour le modèle basé sur le LR, la courbe (c) pour le modèle basé sur l'ANN et la courbe (d) pour le modèle basé sur le NB. Les quatre modèles sont mis en œuvre avec l'ontologie FOTS et le score F-ESI 2.0 proposé.

Malgré les améliorations des différents modèles, le modèle basé sur l'ANN (courbe C) reste le meilleur. On voit bien que la courbe est bien supérieure à la diagonale, ce qui prouve que notre modèle peut donner des résultats efficaces avec une fraction très faible de faux positifs. Le prétraitement des données et la fuzzification des concepts flous établis par l'ontologie FOTS permettent d'utiliser les informations et les connaissances pertinentes et précises qui améliorent la qualité des données et les résultats obtenus. La figure 6.5 montre trois courbes : la courbe

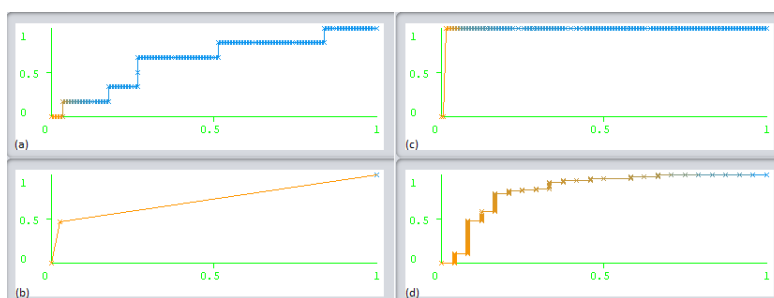


FIGURE 6.4 – les courbes ROC des modèles (a) KNN (b) LR (c) ANN (d)

(a) présente le modèle basé sur l'ontologie FOTS et le score F-ESI 2.0, la courbe (b) correspond au modèle basé sur l'ontologie OntoTriS et le score F-ESI 1.0 et la courbe (c) décrit la technique ANN uniquement.

La courbe (a) présente les résultats du modèle proposé. L'amélioration est très claire donc la contribution ontologie-fuzzification : l'ontologie FOTS avec le score F-ESI 2.0 est bien vérifiée.

## 6.4.2 Discussions

Ainsi, le modèle de classification ANN a été amélioré par la fuzzification. Cette amélioration est basée d'une part sur le raffinement du résultat de la classification et sa précision et d'autre part sur l'apport au modèle flou des prérequis présentés par les données floues exploitées à l'aide de l'ontologie. Ainsi, la gestion de l'imprécision des données utilisées améliore la précision de notre modèle et réduit le nombre des faux positifs. Le tableau [6.12](#) montre l'intérêt de la combinaison de l'IA symbolique avec l'IA sub-symbolique avec la contribution de l'ontologie et de la logique floue par rapport aux techniques usuelles d'apprentissage automatique. En outre, notre étude montre que l'ANN peut classer de manière robuste les patients en fonction de leur état de gravité au moment du triage dans le SUA. L'ontologie est un élément très important dans notre modèle. Elle nous aide à prétraiter les données correctement d'une part, en préservant la partie sémantique de l'information afin de l'utiliser et de la classer, et d'autre part, elle facilite la récupération de l'information en utilisant des requêtes sémantiques. Le raisonnement par score F-ESI 2.0 est déployé via une ontologie. Nous ne pouvons pas comparer notre modèle avec d'autres ontologies de domaine de triage car il n'existe pas d'ontologies fonctionnelles complètes pour les prendre comme références.

Les données manquantes et non fiables influencent négativement le modèle de classification, ce qui prouve que l'approche que nous proposons pour gérer l'imprécision est plus efficace pour réduire le taux d'erreur que les travaux de la littérature. Ces derniers classent les données utilisées en fonction de leur impact sur la décision de triage mais ils ne prennent pas en compte les incertitudes de ces données. Nous avons donc établi une nouvelle classification basée sur la logique floue et l'apprentissage profond pour montrer comment l'imprécision des données peut influencer la décision. Nous montrons également que la technique d'apprentissage profond est plus performante que les autres techniques selon les tests effectués. Ensuite, nous prouvons que l'ontologie a un rôle potentiel dans le traitement des données textuelles et la standardisation des vocabulaires médicaux utilisés d'une part et la gestion des connaissances et l'amélioration du système sémantique d'autre part.

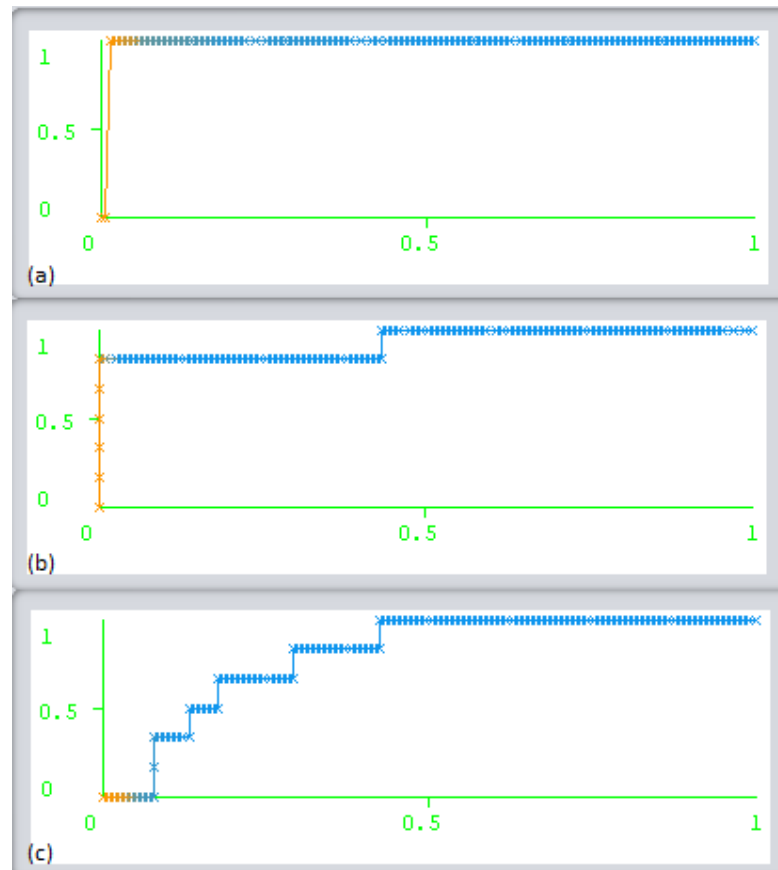


FIGURE 6.5 – Comparaison entre la méthode proposée et les données observées

Les résultats obtenus montrent qu'un système basé sur l'ontologie est plus efficace. Par la suite, la mesure de l'incertitude des données pourrait améliorer la fiabilité et la performance prédictive pour les sources de données inhérentes où l'intégration de la gestion de l'incertitude dans les modèles d'aide à la décision sera nécessaire. Avec la logique floue, nous pouvons aborder le problème de l'imprécision des connaissances et des informations médicales mais l'incertitude n'est pas vraiment abordée. Pour cela, nous complétons notre système d'aide de triage par un modèle de prédiction d'orientation post-triage basé sur la théorie de D-S qui gère l'incertitude des données. Les résultats expérimentaux de cette solution est présentée dans la partie qui suit.

## 6.5 Expérimentations et résultats du modèle de prédiction de l'orientation post-triage

Dans cette partie, nous présentons les résultats de l'expérimentation de notre modèle proposé pour aider les infirmiers de triage à bien orienter les patients (chapitre 5(cf. section 5.5.3)). La BD utilisée dans cette expérimentation est notre base du CHU de Lille. Deux expérimentations sont présentées dans cette partie :

1. L'objectif de la première expérience est de montrer que le D-C4.5 améliore le résultat trouvé par l'algorithme usuel C4.5. Ce dernier est différent de l'algorithme proposé, le D-C4.5, car il utilise la mesure IGR pour le critère de division au lieu de la mesure UIGR adoptée. Les deux techniques utilisent le même processus d'élagage.
2. La deuxième expérience étudie les performances de D-C4.5 par rapport à C4.5 usuel et à l'algorithme ID3. L'ID3 est l'équivalent au C4.5 usuel en remplaçant la mesure IGR par l'IG. De plus, toutes les variables disponibles dans un nœud sont utilisées pour le critère de division.

Pour déployer la méthode proposée, nous avons défini :

- les variables de classe  $C$  pour l'orientation du patient dans le SUA,
- le cadre de discernement  $\Omega$  qui est l'ensemble des variables  $(x_i)$  pour chaque patient  $P_j$ .
- La variable de décision  $d_k$  où  $(k \in \{1, 2, 3\})$  :
  - $d_1$  correspond à l'orientation circuit court,
  - $d_2$  à l'orientation circuit long et
  - $d_3$  à l'orientation réanimation pour chaque patient  $P_i$ .
- Les sources d'information présentent les données médicales d'entrée, telles que : l'âge, le mode d'arrivée (AM), l'ESI (Emergency Severity Index), la température, la plainte principale (CC), l'antécédent médical (MH), la fréquence cardiaque, la fréquence respiratoire, les examens complémentaires, etc. Ces indicateurs ont un impact important sur la décision  $d_k$ .

Dans la partie suivante, nous mettons en place une expérience avec une base de données des urgences validant notre travail par une simulation détaillée de cinq patients puis par une comparaison avec d'autres méthodes usuelles de ML. La base de données que nous détenons actuellement contient toutes les données pertinentes pour la prise de décision. Nous avons structuré ces données à l'aide de notre ontologie pour faciliter l'adaptation de la méthode proposée

Méthodes sans élagage	Précision	Sensitivité	Spécificité	NB de feuilles	Runtime
C4.5	0.59	0.62	0.52	21	0.04
D-C4.5	0.63	0.65	0.61	20	0.08

TABLEAU 6.13 – Comparaison entre l’algorithme C4.5 et D-C4.5 sans élagage

Méthodes (élagage)	Précision	Sensitivité	Spécificité	Tailles (arbre)	Nfeuilles	Runtime
C4.5	0.78	0.81	0.72	22	19	1.2
D-C4.5	0.93	0.89	0.92	17	16	1.4

TABLEAU 6.14 – Comparaison entre l’algorithme C4.5 et D-C4.5 avec élagage

avec des données hétérogènes comme les observations médicales. Pour le jeu de données, nous avons utilisé 336 456 cas de chaque classe  $d_k$  ( $k \in \{1, 2, 3\}$ ) pour l’entraînement et 1200 cas de patients pour les tests. Nous réalisons des expériences comparant donc les performances de l’algorithme D-C4.5 proposé avec d’autres modèles de classification. Nous effectuons l’analyse en utilisant différents paramètres tels que le taux de vrais positifs, le taux de faux positifs, la précision, la sensibilité et la spécificité. Les vrais positifs (TP) sont définis comme les exemples utilisés dans l’étude qui ont été correctement prédits comme étant normaux. Les vrais négatifs (TN) sont les exemples qui ont été correctement prédits comme étant des anormaux. Les faux positifs (FP) sont définis comme les exemples qui ont été faussement prédits comme étant anormaux alors qu’ils étaient normaux, tandis que les faux négatifs (FN) sont définis comme les exemples qui ont été supposés normaux, mais qui étaient anormaux. La précision du système est décrite comme le nombre de prédictions correctes faites par le système.

### 6.5.1 C4.5 vs D-C4.5

Dans la première partie de l’expérience, nous montrons les résultats obtenus par les arbres C4.5 et D-C4.5. Les tableaux 6.13 et 6.14 présentent les résultats de précision de la taille des arbres (nombre de nœuds) de chaque méthode sans élagage et avec élagage appliqué sur nos jeux de données. Ces derniers ont été prétraités avant la simulation. Ensuite, nous présentons la structure de chaque arbre avec élagage (figure 6.6 et 6.7). Enfin, la courbe ROC des deux méthodes est présentée par la figure 6.8. L’objectif de cette section est de comparer l’algorithme D-C4.5 avec l’algorithme C4.5 afin de montrer l’apport de la méthode proposée dans le domaine des arbres de décision. Les résultats de la section précédente sont analysés selon les aspects suivants : précision, sensibilité, spécificité, aire AUC, taille de l’arbre et nombre de feuilles.

- - Précision : Selon ce facteur, nous pouvons dire que le D-C4.5 avec élagage est plus efficace que le C4.5 usuel. Cependant, les deux sont presque équivalents, étant un peu plus efficace que le D-C4.5 sans élagage. L’ajout de la théorie de Dempster dans le calcul de l’entropie montre qu’il existe une différence notable en faveur du D-C4.5 avec élagage par rapport à la méthode classique. Cette différence est importante lorsque le niveau d’incertitude est élevé.
- Sensibilité, spécificité : Selon ces facteurs, le D-C4.5 avec élagage a la sensibilité et la spécificité les plus élevées que la méthode C4.5 usuelle. Cependant, les deux sont presque équivalentes, étant légèrement meilleures que D-C4.5 sans élagage. Ces résultats montrent que l’algorithme proposé est plus efficace pour générer des vrais positifs et des vrais né-

```
-----  
ESI = 1: CC (6.0/1.0)  
ESI = 2  
| Radiological_exam = oui: CL (25.0)  
| Radiological_exam = non  
| | Chief_complaint = Cardiologie: CL (5.27/0.27)  
| | Chief_complaint = Maladies infectieuses: CL (0.0)  
| | Chief_complaint = Orl: CC (5.27)  
| | Chief_complaint = Gastro-enterologie: CL (7.38/1.38)  
| | Chief_complaint = Rhumatologie non traumatique: CL (3.16/1.16)  
| | Chief_complaint = Traumatologie: CC (3.16)  
| | Chief_complaint = Pneumologie: CL (0.0)  
| | Chief_complaint = Stomatologie: CC (2.11)  
| | Chief_complaint = Psychiatrie: CC (1.05)  
| | Chief_complaint = Dermatologie: CC (1.05)  
| | Chief_complaint = Uro-nephrologie: CL (5.27/1.27)  
| | Chief_complaint = Neurologie: CL (4.22/0.22)  
| | Chief_complaint = Divers: CL (0.0)  
| | Chief_complaint = Endocrino-metabolisme: CL (1.05/0.05)  
ESI = 3: CL (4.0)  
ESI = 4: CL (1.0)  
ESI = 5: R (4.0)  
  
Number of Leaves : 19  
  
Size of the tree : 22
```

FIGURE 6.6 – Structure de l'arbre C4.5



```

-----
ESI = 1: CC (6.0/1.0)
ESI = 2
| Radiological_exam = oui: CL (25.0)
| Radiological_exam = non
| | Chief_complaint = Cardiologie: CL (5.27/0.27)
| | Chief_complaint = Maladies infectieuses: CL (0.0)
| | Chief_complaint = OrL: CC (5.27)
| | Chief_complaint = Gastro-enterologie: CL (7.38/1.38)
| | Chief_complaint = Rhumatologie non traumatique: CL (3.16/1.16)
| | Chief_complaint = Traumatologie: CC (3.16)
| | Chief_complaint = Pneumologie: CL (0.0)
| | Chief_complaint = Stomatologie: CC (2.11)
| | Chief_complaint = Psychiatrie: CC (1.05)
| | Chief_complaint = Dermatologie: CC (1.05)
| | Chief_complaint = Uro-nephrologie: CL (5.27/1.27)
| | Chief_complaint = Neurologie: CL (4.22/0.22)
| | Chief_complaint = Divers: CL (0.0)
| | Chief_complaint = Endocrino-metabolisme: CL (1.05/0.05)
ESI = 3: CL (4.0)
ESI = 4: CL (1.0)
ESI = 5: R (4.0)

Number of Leaves :    19

Size of the tree :    22

```

FIGURE 6.7 – Structure de l'arbre D-C4.5

```

=====
Chief_complaint = Cardiologie : CL (8.67/0.5) [1.33/0.33]
Chief_complaint = Maladies infectieuses : CL (1.08/0.06) [0.04/0.04]
Chief_complaint = OrL : CC (4.33/0.17) [3.17/1.17]
Chief_complaint = Gastro-enterologie : CL (7.58/1.44) [4.29/1.29]
Chief_complaint = Rhumatologie non traumatique : CL (3.25/1.19) [4.13/0.13]
Chief_complaint = Traumatologie
| Radiological_exam = oui : CL (3/0) [1/0]
| Radiological_exam = non : CC (2.42/0.21) [1.21/0.21]
Chief_complaint = Pneumologie : CL (2.17/0.13) [3.08/0.08]
Chief_complaint = Stomatologie : CC (1.08/1.04) [4.04/1.04]
Chief_complaint = Psychiatrie : CC (1.08/0.04) [0.04/0.04]
Chief_complaint = Dermatologie : CC (3.25/0.13) [0.13/0.13]
Chief_complaint = Uro-nephrologie : CL (2.17/0.13) [3.08/1.08]
Chief_complaint = Neurologie : CL (8.67/1.5) [1.33/0.33]
Chief_complaint = Divers : CL (2.17/0.13) [0.08/0.08]
Chief_complaint = Endocrino-metabolisme : CL (1.08/0.06) [0.04/0.04]

Size of the tree : 17

```

FIGURE 6.8 – Courbe ROC de C4.5 et D-C4.5

gatifs. Ainsi, l'utilisation de l'entropie de Jirousek avec sa théorie de l'entropie maximale permet de gérer l'incertitude des données et d'améliorer la prédiction des vrais positifs et des vrais négatifs. Ils montrent qu'il existe une différence significative en faveur du D-C4.5 avec élagage par rapport à la méthode classique.

- Surface AUC : D'après la courbe ROC des deux méthodes, la méthode D-C4.5 est plus efficace par rapport à la méthode usuelle. La courbe de la méthode proposée présente une fraction de faux négatifs très faible. Par contre, la courbe du C4.5 a une fraction très importante de faux négatifs. Les résultats des deux méthodes sans élagage sont équivalents mais il y a une différence favorable pour la méthode proposée avec élagage. La fonction de masse de chaque classe de variable traite les valeurs manquantes dans la base de données, assurant ainsi une propagation plus efficace de l'information.
- Taille de l'arbre : Nous pouvons observer que le D-C4.5 a construit de plus petits arbres. Le nombre moyen de nœuds de cette méthode est inférieur au nombre de nœuds de la méthode C4.5 car elle effectue une discrétisation en utilisant seulement deux intervalles. Les deux méthodes C4.5 et D-C4.5 (sans élagage) ont une taille moyenne d'arbre similaire. Nous pouvons donc expliquer cette différence par l'utilisation de la probabilité pour chaque classe de variables, ce qui peut donner une vision approximative de l'impact de chaque variable. Ainsi, parmi les spécificités de l'entropie utilisée, elle ignore les variables qui ont un conflit très élevé, ce qui réduit le nombre de variables incluses dans l'arbre.
- Nombre de feuilles : Nous pouvons remarquer selon les résultats obtenus que la méthode proposée a le plus petit nombre de feuilles par rapport à la méthode usuelle. Par contre, les deux méthodes sans élagage sont presque équivalentes. Ce fait peut être expliqué par l'exploitation de l'entropie de Dempster qui traite l'incertitude, ignore les conflits et considère la sémantique de la théorie D-S. Suite à cette analyse, nous pouvons récapituler comme suit :
- Arbres D-C4.5 (D-C4.5 sans élagage) vs Méthode usuelle sans élagage (C4.5) : Nous pouvons observer avec cette expérience que les arbres D-C4.5 améliorent les résultats obtenus par les méthodes classiques (sans élagage) pour les données du SUA. Selon la surface AUC, cette différence est significative. Par conséquent, nous pouvons conclure que le processus d'élagage est une partie fondamentale des méthodes usuelles (C4.5) pour améliorer leur précision. Pour cette raison, nous nous sommes concentrés sur les méthodes avec un processus d'élagage dans l'expérience suivante.
- Arbres D-C4.5 vs l'algorithme usuel (C4.5) : D-C4.5 obtient toujours (avec ou sans élagage) de meilleurs résultats moyens de précision que le C4.5 qui obtient l'aire AUC la plus basse ; et, selon la courbe ROC, ces différences sont statistiquement significatives. En outre, le D-C4.5 présente la plus petite taille moyenne d'arbre et le plus petit nombre de feuilles.

### 6.5.2 D-C4.5 vs techniques usuelles de ML

Dans la deuxième expérimentation, le tableau 6.15 montre un comparatif sur les résultats de précision des méthodes suivantes : le RF, le D-C4.5, le KNN, le ANN et le NB lorsqu'elles sont appliquées sur nos jeux de données réelles. De plus, la Figure 6.9 décrit la courbe ROC de chaque méthode où la courbe (a) correspond à la méthode proposée D.C4.5, la courbe (b) correspond à la méthode NB, la courbe (c) correspond à la méthode ANN, la courbe (d) correspond à la méthode RF et la courbe (e) à la méthode KNN. L'objectif de cette section est de comparer l'algorithme

Méthodes	Précision	Sensitivité	Spécificité	AUC	Runtime (ms)
D.C4.5	0.93	0.89	0.92	0.94	1.4
ANN	0.79	0.77	0.75	0.78	7
RF	0.80	0.81	0.76	0.76	2.3
KNN	0.75	0.71	0.73	0.72	4
NB	0.72	0.6	0.73	0.66	6

TABLEAU 6.15 – Résultats de comparaison entre le D-C4.5 et les techniques usuelles de ML




FIGURE 6.9 – Comparaison entre la méthode proposée et les données observées

D-C4.5 avec l'algorithme C4.5 et d'autres techniques de ML. En particulier, cette comparaison est importante afin de montrer l'amélioration de la méthode proposée dans le domaine du ML. Les résultats de la section précédente sont analysés selon les aspects suivants : précision, sensibilité, spécificité et aire AUC. - La précision : la méthode proposée est plus précise avec le taux de précision le plus élevé. Ces résultats peuvent être expliqués de différentes manières ; le traitement des données manquantes, la gestion de l'incertitude dans les données médicales, la prise en compte de l'imprécision des sources de données et la sémantique catégorisée par la théorie D-S. Ainsi, le modèle proposé avec un taux de précision de 94% montre une efficacité favorisée par rapport à toutes les autres techniques. - Sensibilité, spécificité : Selon ces deux facteurs, le D-C4.5 est plus performant avec une différence très nette par rapport aux autres méthodes. Notre méthode est plus efficace pour prédire les vrais résultats, qu'ils soient négatifs ou positifs. Le déploiement de l'entropie qui est basée sur la théorie D-S améliore la qualité des données et par la suite la qualité des résultats obtenus. - Surface AUC : Nous pouvons observer à partir des courbes ROC obtenues que le D-C4.5 est la meilleure méthode avec une fraction très faible de faux négatifs, c'est la courbe la plus éloignée de la diagonale. D'autre part, les autres méthodes sont similaires avec des résultats acceptables mais non performants. Par conséquent, la gestion de l'incertitude des données est très importante pour exploiter des données de bonne qualité et obtenir de bons résultats. De plus, la théorie des probabilités est également importante car elle permet de catégoriser les variables en fonction de leur impact sur la décision finale. Après cette analyse, nous pouvons conclure les points suivants sur la comparaison de ces algorithmes : - L'entropie basée sur D-S joue un rôle très important dans la classification des données, sa partie sémantique améliore la qualité des données et la gestion des conflits réduit le nombre d'itérations, la taille de l'arbre de décision et par conséquent la complexité. -La méthode proposée est plus efficace par rapport aux autres méthodes. -La gestion de l'incertitude est très importante dans les modèles de classification pour améliorer la qualité de l'apprentissage. Les points ci-dessus nous permettent de remarquer les conclusions suivantes sur l'étude expérimentale : (i) Pour créer des arbres plus petits avec un niveau de précision similaire, le D-C4.5 est plus adéquat que les méthodes basées sur les probabilités classiques. (ii) L'utilisation du D-C4.5 est particulièrement appropriée pour être appliquée sur des ensembles de données de mauvaise qualité et à très forte incertitude. Cette conclusion est raisonnable à partir de la définition du D-C4.5 qui repose sur l'entropie de Jirousek. Cette méthode a été définie en supposant que l'ensemble de formation n'est pas très fiable. Les règles de combinaison de la théorie de D-S ont été utilisées pour calculer la fonction de masse des caractéristiques et de la variable de classe. Nous avons implémenté notre système, baptisé SATGT, en se basant sur l'architecture (cf. section 4.2). Dans la partie qui suit, nous établissons une simulation de 30 patients dans le SUA afin d'évaluer notre système en temps réel.

## 6.6 Implémentation et simulation du SATGT proposé

Cette thèse, qui fait partie du projet ANR OIILH, a pour objectif de contribuer au développement d'un système d'aide à la décision (SATGT) pour optimiser la chaîne logistique des urgences. Un SATGT se charge de la collecte ainsi que de la transformation des données brutes issues de sources hétérogènes en des connaissances pertinentes en vue de simplifier le processus de prise de décisions. L'idée de notre SATGT est d'extraire des données médicales brutes et non structurées textuelles et les transformer en des connaissances pertinentes pour améliorer la prise de décision au cours du triage et faciliter la gestion de situations de tension. Dans cette

Patients	Date	CCMU	F-ESI 1.0	F-ESI 2.0	Orientation post Triage	D-C4.5	Orientation post-SUA	DDMLP
Patient01	28/03/2022	2	2	3	LC	LC	H	H
Patient02	28/03/2022	2	3	3	LC	LC	H	H
Patient03	28/03/2022	2	1	1	CC	CC	D	D
Patient04	28/03/2022	3	3	4	LC	LC	H	H
Patient05	28/03/2022	2	3	3	LC	LC	H	H
Patient06	28/03/2022	3	3	4	LC	LC	H	H
Patient07	28/03/2022	4	4	5	LC/R	R	H	H
Patient08	28/03/2022	2	3	3	LC	LC	H	H
Patient09	28/03/2022	3	3	4	LC	LC	H	H
Patient10	28/03/2022	2	2	3	CC/LC	LC	H	H
Patient11	28/03/2022	2	3	3	CC/LC	LC	H	H
Patient12	28/03/2022	2	2	2	CC	CC	D	D
Patient13	29/03/2022	2	3	3	CC/LC	LC	D	D
Patient14	29/03/2022	2	2	2	CC	CC	D	D
Patient15	29/03/2022	3	3	4	LC	LC	H	H
Patient16	29/03/2022	2	2	2	CC	CC	D	D
Patient17	29/03/2022	5	5	5	R	R	H	H
Patient18	29/03/2022	2	2	3	CC/LC	LC	D	D
Patient19	29/03/2022	1	1	2	CC	CC	D	D
Patient20	29/03/2022	2	2	2	CC	CC	D	D

TABLEAU 6.16 – Comparaison entre les données réelles du SUA et les résultats du système proposé SATGT




FIGURE 6.10 – Comparaison entre le CCMU du système ResUrgence, le F-ESI 1.0 et le F-ESI 2.0

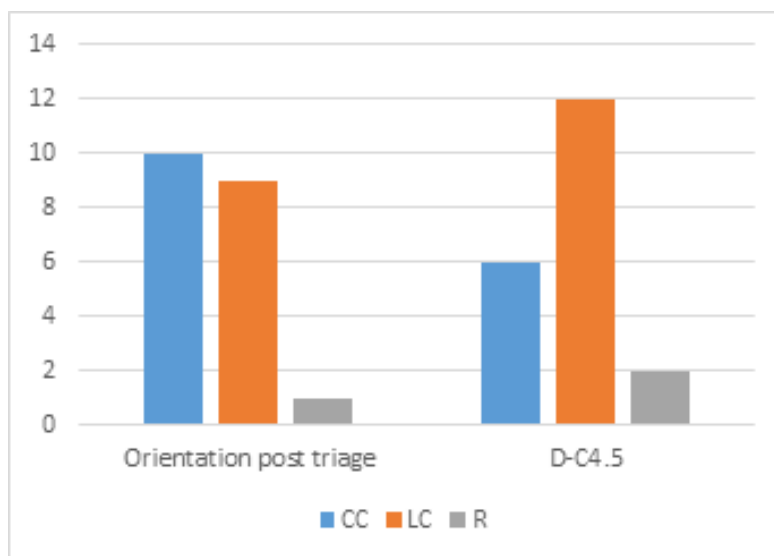


FIGURE 6.11 – Comparaison entre l'orientation post triage du système ResUrgence et de modèle D-C4.5

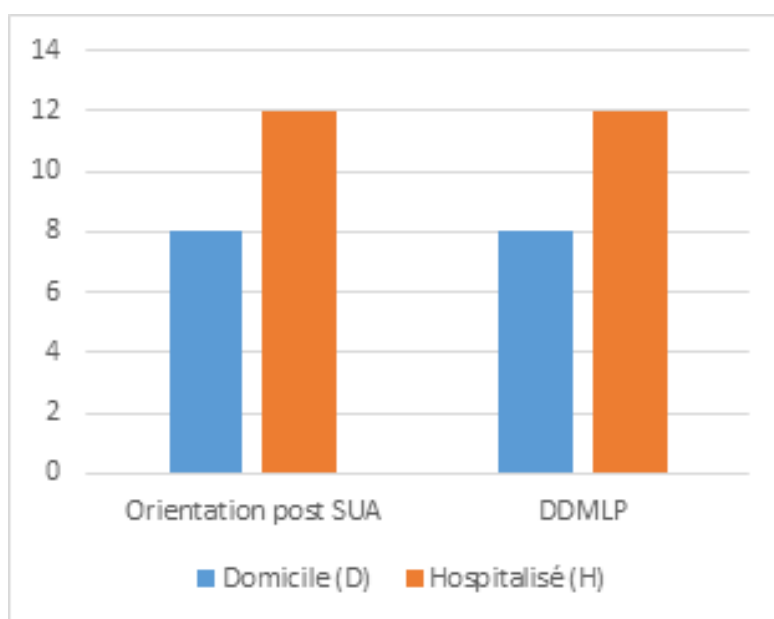


FIGURE 6.12 – Comparaison entre les résultats de prédiction du DDMLP et les données réelles

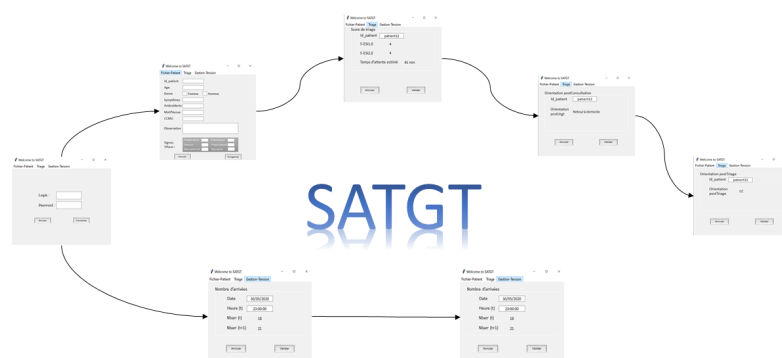


FIGURE 6.13 – Les interfaces implémentées du SATGT

partie d'expérimentation, nous simulons un processus de prise en charge de 20 patients pour évaluer en temps réel le système proposé par rapport au système ResUrgence (tableau 6.16). Ces résultats sont affichés via les interfaces implémentées de notre système (Figure 6.13)(cf. Annexe 2). Les histogrammes des figures 6.10, 6.11 et 6.12 affichent les résultats retenus permettant d'évaluer le système SATGT. Nous avons validé ces résultats avec nos partenaires urgentistes en vérifiant le parcours patient dans le SUA afin d'évaluer le score de triage. Selon la figure 6.10, nos partenaires urgentistes du projet OILH, ont constaté une amélioration par rapport au score CCMU. L'attribution du score 2 a diminué et le score 5 reste toujours une minorité mais il est plus présent dans le F-ESI 2.0. Le F-ESI 2.0 est plus précis que le F-ESI 1.0. La figure 6.11 présente une comparaison entre l'orientation post-triage des patients et le résultat du modèle D-C4.5. Selon ces résultats, nous constatons que notre modèle peut améliorer la décision d'orientation. Par exemple, il y'a 5 patients dans le tableau 6.16 qui ont été réorienté à cause d'une orientation incorrecte. Cette erreur permet de rallonger la durée de séjour du patient dans le SUA et augmente le risque d'encombrement. En revanche, le modèle D-C4.5 a pu identifier tout de suite le bon parcours de soin. Donc, le modèle proposé peut améliorer le système de triage et réduire le risque d'erreur. Concernant la figure 6.12, nous comparons l'orientation réelle post SUA avec la prédiction précoce de l'admission au moment de l'arrivée en utilisant notre algorithme DDMLP. Les résultats obtenus sont confondues avec les données réelles ce qui montre l'efficacité de notre algorithme de prédiction. Cette dernière permet d'aider le personnel de santé à bien gérer les moments de tension en prenant en compte le nombre d'hospitalisation. Notre système SATGT est capable de prédire les situations de tension en déployant notre ontologie du SU et l'algorithme ED-Deep MDPRL qui prédit l'affluence des patients. Le tableau 6.17 présente les résultats de notre système SATGT sur quatre jours successifs : entre le 29/05/2020 et le 01/06/2020. Nous prenons les mesures des indicateurs de performance du SUA ainsi les résultats de prédiction issus du modèle ED-Deep MDPRL. Toutes les mesures de performances sont extraites et calculées par l'ontologie EDOMO qui aide à prédire la situation de tension et recommande la bonne solution pour la gestion.

En effet, le modèle ED-Deep MDPRL a pu prédire parfaitement le nombre des arrivées pour les quatre jours successifs et les résultats obtenus sont très proche du nombre réel (Figure 6.14). La base de données ontologique que nous avons déployée comporte les mêmes colonnes que celle du CHU de Lille auxquelles nous rajoutons une colonne pour inscrire les résultats de chacun de nos algorithmes. A travers l'étude de prédiction de l'affluence des patients ainsi que l'ontologie EDOMO, il est possible d'avoir une vision globale sur la situation du SUA dans le futur et de recommander des solutions en cas de tension

Date	Nbarr tot	H = t	ED-Deep MD-PRL	Nbarr réel à t	PWT	T2	Np	PM	Qs	Ct	RS	OES
29/05/2020	180	10H	4	5	0.5H	0.2H	10	2	0.14	23	6	Normal
		23H	28	26	5H	2.25H	45	9	1.42	173	28	Très critique
30/05/2020	160	19H	15	14	3.5H	0.8H	28	5	1	76	19	critique
		23H	21	19	4.5H	1.75H	46	9	1.28	143	26	Très critique
31/05/2020	200	20H	19	21	4.5H	1.75H	35	7	1.28	123	23	Critique
		23H	28	29	5H	2.5H	50	10	1.42	180	26	Très critique
01/06/2020	178	21H	22	20	4.75H	2H	37	7	1.35	110	22	critique
		23H	26	27	5H	2.25H	48	9	1.42	173	26	Très critique

TABLEAU 6.17 – Résultat de SATGT pour prédire l'affluence des patients et la tension

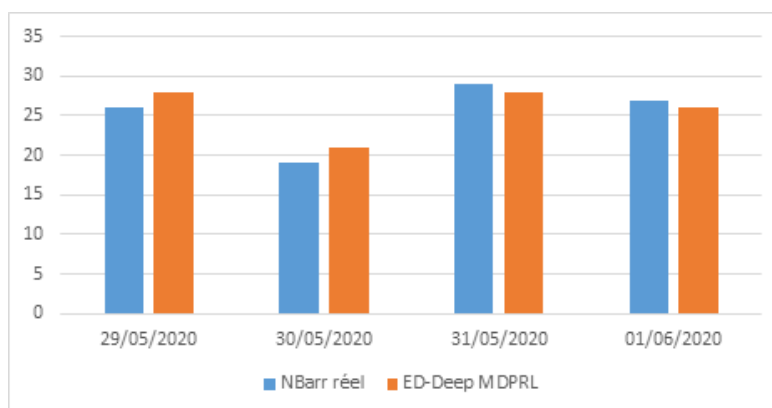


FIGURE 6.14 – Comparaison entre les résultats de prédiction du DDMLP et les données réelles



## 6.7 Conclusion

Dans ce chapitre, nous avons présenté les expérimentations et les résultats montrant l'intérêt de nos approches en utilisant une base de données réelle. D'abord, nous avons simulé notre algorithme DDMLP qui est basée sur un réseau de neurone. Les résultats des expérimentations montrent que notre approche a pu prédire l'hospitalisation dès l'arrivée des patients. Ensuite, nous avons testé notre approche ED-Deep MDPRL qui est basée sur le modèle Markovien et l'algorithme Deep Q-Learning. Les résultats des expérimentations nous ont permis de conclure que la mise en place de cette approche permet à la fois de prédire le nombre des arrivées et la tension. Puis, nous avons présenté les résultats d'expérimentation de notre approche de triage qui est basée sur l'ontologie floue et l'algorithme D-C4.5 qui ont amélioré les performances du SUA par l'aide au triage. Pour conclure, nous avons présenté les résultats de notre SATGT en simulant le processus de prise en charge de 20 patients afin d'évaluer sa performance globale en temps réel.

# Conclusion générale

La tension dans les services des urgences est un problème majeur de santé publique dans le monde. Depuis des années, on constate une augmentation du taux de fréquentation de ce type de service qui perturbe le fonctionnement de l'organisation et le bon déroulement des soins. En effet, l'afflux soudain des patients, quel que soit le niveau de gravité, entraîne des difficultés à répondre à la demande. Les conséquences directes sont multiples et malheureusement fréquentes. Nous pouvons citer par exemple les longs délais d'attente, l'insatisfaction des patients et la surcharge de travail du personnel médical. Parfois, des drames tels que le décès de patients en attente de traitement surviennent dans les services. Heureusement, ce scénario reste rare de nos jours, mais il est très médiatisé, notamment lors des épidémies. De plus, les professionnels de santé ne sont ni habitués, ni bien préparés à faire face à cette situation. L'une des principales difficultés rapportées réside dans le décalage entre les urgences vitales pour lesquelles ils ont été formés et leur rôle de régulateur du flux de patients arrivant à l'hôpital. Ces limitations rendent nécessaire la recherche de solutions pour améliorer les performances des urgences et les aider. Parmi ces solutions, l'aide au triage et à l'orientation ainsi que la prédiction de la tension semblent être une approche prometteuse. Le protocole de triage est un processus largement adopté au niveau des services des urgences pour trier les patients en fonction de leur état de santé. Son efficacité et sa rapidité ne peuvent qu'augmenter les chances de survie des patients atteints de maladies graves. En général, les erreurs de triage des patients peuvent avoir de graves conséquences telles que des diagnostics erronés, des retards dans le traitement, une mauvaise utilisation des ressources de santé et une augmentation des coûts. Dans ce contexte, nous avons proposé dans le cadre de cette thèse une architecture hybride basée sur des approches d'IA symboliques et des approches d'IA subsymboliques en proposant un système d'aide à la décision intelligent déployant des ontologies de domaine et des techniques d'apprentissage artificiel. En effet, les approches symboliques sont présentées par trois ontologies : OntoTriS, FOTS et EDOMO qui sont des ontologies de domaines du SUA. Nous avons intégré dans nos ontologies deux bases de règles logiques (SWRL) : une base pour calculer le degré de sévérité des patients au moment du triage et une base pour calculer les indicateurs de performances du SUA en assurant la prédiction et la recommandation des actions convenables en cas de risque d'encombrement. Les ontologies assurent, dans un premier temps, l'extraction des informations pertinentes issues des données textuelles non structurées puis les modélisent et les intègrent dans la base des données ontologique. De plus, elles transforment les données cliniques en des connaissances pour faciliter leur exploitation sémantique. Elles permettent aussi la génération des bases de règles et de bases de connaissances à travers un moteur d'inférence intégré. Les approches subsymboliques sont présentées par nos algorithmes d'apprentissage automatique qui sont capables de raisonner intelligemment en se basant sur une base de données très importante. Afin d'améliorer la qualité des données exploitées, nous avons intégré la théorie de Dempster Shafer qui est capable de gérer l'incertitude dans le déploiement des algorithmes sur lequel

notre système d'aide à la décision s'est basé : l'algorithme des réseaux de neurones et l'algorithme C4.5 de l'arbre de décision. Nous avons donc proposé des versions améliorées et adaptées de ces deux algorithmes à notre problématique de l'amélioration de la prise en charge des patients aux urgences. En effet, nous avons proposé dans cette thèse une nouvelle approche DDMLP (Dynamic Dempster Multi Layer Perceptron) qui est un modèle de classification basé sur les réseaux de neurones. Cet algorithme est proposé afin de prédire l'hospitalisation des patients dès leur arrivée. L'efficacité de notre approche est prouvée en le comparant avec des modèles de ML classiques. Nous avons défini aussi une approche qui permet d'orienter les patients après le triage vers le parcours adéquat (Circuit court, circuit long, Réanimation). En effet, c'est une méthode d'arbre de décision intégrant l'entropie de Jirousek (Dempster Shafer). Les expérimentations ont montré une efficacité par rapport aux modèles de classification existants. En outre, nous avons développé un modèle d'apprentissage par renforcement qui prédit l'affluence des patients en alertant en cas de dépassement de la capacité de charge du SUA. Ce modèle est basé sur l'algorithme Deep Q-Learning. La qualité de cet algorithme proposé est prouvée en le comparant avec d'autres modèles de prédiction basé sur le ML. Les résultats expérimentaux ont montré que les performances de notre solution est meilleure que celles des méthodes usuelles de ML. Pour évaluer ses performances, l'approche proposée a été testée au service des urgences du CHU de Lille en se basant sur des données réelles de triage et les indicateurs de performances du SUA. Les résultats des expérimentations ont démontré l'association prometteuse entre les deux paradigmes "ontologie- apprentissage". Le système de triage basé sur l'ontologie FOTS proposée a prouvé des performances supérieures aux modèles d'apprentissage sans ontologie. Ainsi, l'ontologie EDOMO a montré des résultats performants dans la prédiction de la tension en se basant sur le score OES et l'approche ED-Deep MDPRL qui est basé sur l'apprentissage par renforcement profond.

Cette thèse présente de nombreuses perspectives scientifiques et techniques :

- Développer et intégrer une approche qui identifie les données les plus corrélées possibles afin de combiner leurs sources dans notre modèle DDMLP.
- Aligner les ontologies proposées en une seule ontologie afin d'améliorer son fonctionnement et sa coordination entre les différents résultats obtenus des modèles d'apprentissage.
- Intégrer et explorer les avantages de l'algorithme LSTM (Mémoire à long terme et à court terme) dans notre modèle d'apprentissage par renforcement profond (deep reinforcement learning) pour améliorer la robustesse et la performance de notre approche. Développer une méthode d'apprentissage par renforcement pour prédire l'affluence des patients en temps réel.
- Prédire le temps d'attente des patients en déployant une technique d'apprentissage de série temporelles tel que le LSTM.
- Adopter une approche multi-agent pour assurer une collaboration efficace entre l'ontologie et les modèles d'apprentissages.

# Bibliographie

- ABELLIN, J et S MORAL (2005). "An algorithm that computes the upper entropy for order-2 capacities". In : *International journal of uncertainty, fuzziness and knowledge-based systems* 14.2, p. 141-154.
- ABEYSIRIWARDANA, Prabath Chaminda et Saluka R KODITUWAKKU (2012). "Ontology based information extraction for disease intelligence". In : *arXiv preprint arXiv :1211.3497*.
- AFOURAS, Triantafyllos et al. (2020). "Self-supervised learning of audio-visual objects from video". In : *European Conference on Computer Vision*. Springer, p. 208-224.
- AGGARWA, Charu C et al. (2015). "Data Classification : Algorithms and Applications". In : *Data Mining and Knowledge Discovery Series*.
- AHMED, Farid E (2005). "Artificial neural networks for diagnosis and survival prediction in colon cancer". In : *Molecular cancer* 4.1, p. 1-12.
- AJMI, Faiza (2021). "Optimisation collaborative par des agents auto-adaptatifs pour résoudre les problèmes d'ordonnement des patients en inter-intra urgences hospitalières". Thèse de doct. Centrale Lille Institut.
- AKREMI, Houda et al. (2016). "FONTO : Une nouvelle méthode de la fuzzification d'ontologies". In : *6ièmes Journées Francophone sur les Ontologies*.
- ALIP, Sylvia L et al. (2022). "Future platforms of robotic surgery". In : *Urologic Clinics* 49.1, p. 23-38.
- ALKAHTANI, Mohammed et al. (2019). "A decision support system based on ontology and data mining to improve design using warranty data". In : *Computers & industrial engineering* 128, p. 1027-1039.
- ARIES, Serge, Benoît LE BLANC et Jean-Louis ERMINE (2008). *MASK : une méthode d'ingénierie des connaissances pour l'analyse et la structuration des connaissances*.
- ARULKUMARAN, Kai et al. (2017a). "A brief survey of deep reinforcement learning". In : *arXiv preprint arXiv :1708.05866*.
- (2017b). "Deep reinforcement learning : A brief survey". In : *IEEE Signal Processing Magazine* 34.6, p. 26-38.
- ASPLIN, Brent R et al. (2003). "A conceptual model of emergency department crowding". In : *Annals of emergency medicine* 42.2, p. 173-180.
- ASSI, Elie Bou et al. (2017). "Towards accurate prediction of epileptic seizures : A review". In : *Biomedical Signal Processing and Control* 34, p. 144-157.
- AUSSENAC-GILLES, Nathalie, Sylvie DESPRES et Sylvie SZULMAN (2008). *The TERMINAE Method and Platform for Ontology Engineering from Texts*.
- AUSSENAC-GILLES, Nathalie, Philippe LAUBLET et Chantal REYNAUD (1996). *Acquisition et ingénierie des connaissances : tendances actuelles : recueil de textes requis de communications présentées aux journées Françaises de l'acquisition de connaissance en 1991, 1992 et 1993*. Cepadue-éditions.

- BAEK, Yujin et Ha Young KIM (2018). "ModAugNet : A new forecasting framework for stock market index value with an overfitting prevention LSTM module and a prediction LSTM module". In : *Expert Systems with Applications* 113, p. 457-480.
- BAEVSKI, Alexei et al. (2022). "Data2vec : A general framework for self-supervised learning in speech, vision and language". In : *arXiv preprint arXiv :2202.03555*.
- BAHADORI, Mohammadkarim et al. (2017). "Factors affecting the overcrowding in outpatient healthcare". In : *Journal of education and health promotion* 6.
- BAILEY, Cara, Roger MURPHY et Davina POROCK (2011). "Trajectories of end-of-life care in the emergency department". In : *Annals of emergency medicine* 57.4, p. 362-369.
- BARONZIO, Gianfranco, Gurdev PARMAR et Miriam BARONZIO (2015). "Overview of methods for overcoming hindrance to drug delivery to tumors, with special attention to tumor interstitial fluid". In : *Frontiers in oncology* 5, p. 165.
- BATIHA, GE et al. (2021). "Possible mechanistic insights into iron homeostasis role of the action of 4-aminoquinolines (chloroquine/hydroxychloroquine) on COVID-19 (SARS-CoV-2) infection". In : *Eur. Rev. Med. Pharmacol. Sci* 25, p. 7565-7584.
- BATT, Robert J et Christian TERWIESCH (2015). "Waiting patiently : An empirical study of queue abandonment in an emergency department". In : *Management Science* 61.1, p. 39-59.
- BAUMANN, Michael R et Tania D STROUT (2007). "Triage of geriatric patients in the emergency department : validity and survival with the Emergency Severity Index". In : *Annals of emergency medicine* 49.2, p. 234-240.
- BECKER, Kurt et al. (1997). "Design and validation of an intelligent patient monitoring and alarm system based on a fuzzy logic process model". In : *Artificial intelligence in medicine* 11.1, p. 33-53.
- BENDERSKAYA, Elena N et Sofya V ZHUKOVA (2013). "Multidisciplinary trends in modern artificial intelligence : Turing's way". In : *Artificial Intelligence, Evolutionary Computing and Metaheuristics*. Springer, p. 319-343.
- BENNANE, Abderrazak (2010). "Traitement des valeurs manquantes pour l'application de l'analyse logique des données à la maintenance conditionnelle". Thèse de doct. École Polytechnique de Montréal.
- BERGONZONI, Alice et al. (2020). "Les établissements de santé : édition 2020". In.
- BERMEJO-PELÁEZ, David et al. (2022). "Deep learning-based lesion subtyping and prediction of clinical outcomes in COVID-19 pneumonia using chest CT". In : *Scientific Reports* 12.1, p. 1-11.
- BERNERS-LEE, Tim, James HENDLER et Ora LASSILA (2001). "The Semantic Web. A new form of Web content that is meaningful to computers will unleash a revolution of new possibilities". In : *Scientific American* 284, p. 34-43.
- BERNSTEIN, Steven L et al. (2009). "The effect of emergency department crowding on clinically oriented outcomes". In : *Academic Emergency Medicine* 16.1, p. 1-10.
- BEVERIDGE, Robert et al. (1998). "Implementation guidelines for the Canadian emergency department Triage & Acuity Scale (CTAS)". In : *Canadian association of emergency physicians*, p. 1-32.
- BIKDELI, Behnood et al. (2020). "COVID-19 and thrombotic or thromboembolic disease : implications for prevention, antithrombotic therapy, and follow-up : JACC state-of-the-art review". In : *Journal of the American college of cardiology* 75.23, p. 2950-2973.
- BISGIN, Pinar et al. (2022). "Thrilling AI—A novel, signal-based digital biomarker for diagnosing canine heart diseases". In : *Current Directions in Biomedical Engineering* 8.2, p. 765-768.
- BISHOP, Christopher M et al. (1995). *Neural networks for pattern recognition*. Oxford university press.

- BLASIAK, Agata, Jeffrey KHONG et Theodore KEE (2020). "CURATE. AI : optimizing personalized medicine with artificial intelligence". In : *SLAS technology* 25.2, p. 95-105.
- BOLHASANI, Hamidreza, Maryam MOHSENI et Amir Masoud RAHMANI (2021). "Deep learning applications for IoT in health care : A systematic review". In : *Informatics in Medicine Unlocked* 23, p. 100550.
- BOLOURANI, Siavash et al. (2021). "A machine learning prediction model of respiratory failure within 48 hours of patient admission for COVID-19 : model development and validation". In : *Journal of medical Internet research* 23.2, e24246.
- BOSER, Bernhard E, Isabelle M GUYON et Vladimir N VAPNIK (1992). "A training algorithm for optimal margin classifiers". In : *Proceedings of the fifth annual workshop on Computational learning theory*, p. 144-152.
- BOUCHON-MEUNIER, Bernadette (2000). "Uncertainty management in medical applications". In : *Nonlinear Biomedical Signal Processing* 1, p. 1-26.
- BRACHMAN, Ronald J et al. (1991). "Living with CLASSIC : When and how to use a KL-ONE-like language". In : *Principles of semantic networks*. Elsevier, p. 401-456.
- BREIMAN, Leo (1992). *Probability*. SIAM.
- (2001). "Random forests". In : *Machine learning* 45.1, p. 5-32.
- BREUKER, Joost et Walter Van de VELDE (1994). *CommonKADS library for expertise modelling : reusable problem solving components*. T. 21. IOS press.
- BRINK, Anniek et al. (2022). "Predicting in-hospital admission at the emergency department : a systematic review". In : *Emergency Medicine Journal* 39.3, p. 191-198.
- BRODLEY, Carla E et Paul E UTGOFF (1992). *Multivariate versus univariate decision trees*. Citeseer.
- BÜYÜKÖZKAN, Gülçin et Gizem ÇİFÇİ (2011). "A novel fuzzy multi-criteria decision framework for sustainable supplier selection with incomplete information". In : *Computers in industry* 62.2, p. 164-174.
- CALDAS, Francisco M et Cláudia SOARES (2022). "A Temporal Fusion Transformer for Long-term Explainable Prediction of Emergency Department Overcrowding". In : *arXiv preprint arXiv :2207.00610*.
- CALLEJA, Pauline et Louise FORREST (2011). "Improving patient privacy and confidentiality in one regional emergency department—a quality project". In : *Australasian Emergency Nursing Journal* 14.4, p. 251-256.
- CAMERON, Allan et al. (2017). "Predicting admission at triage : are nurses better than a simple objective score?". In : *Emergency Medicine Journal* 34.1, p. 2-7.
- CARMEN LEGAZ-GARCÍA, María del et al. (2016). "A semantic web based framework for the interoperability and exploitation of clinical models and EHR data". In : *Knowledge-Based Systems* 105, p. 175-189.
- CARTER, Eileen J, Stephanie M POUCH et Elaine L LARSON (2014). "The relationship between emergency department crowding and patient outcomes : a systematic review". In : *Journal of Nursing Scholarship* 46.2, p. 106-115.
- CHAN, HC Stephen et al. (2019). "Advancing drug discovery via artificial intelligence". In : *Trends in pharmacological sciences* 40.8, p. 592-604.
- CHANDOUL, Wided (2015). "Conception et réalisation d'un système d'aide à la gestion des tensions dans les services d'urgences pédiatriques : vers des nouvelles approches d'évaluation, de quantification et d'anticipation". In.
- CHARLET, Jean (2002). "L'ingénierie des connaissances : développements, résultats et perspectives pour la gestion des connaissances médicales". Thèse de doct. Université Pierre et Marie Curie-Paris VI.
- CHEN, Irene Y et al. (2021). "Ethical machine learning in healthcare". In : *Annual review of biomedical data science* 4, p. 123-144.

- CHENGSHENG, Tu, Liu HUACHENG et Xu BING (2017). "AdaBoost typical Algorithm and its application research". In : *MATEC Web of Conferences*. T. 139. EDP Sciences, p. 00222.
- CHONDE, Seifu J et al. (2013). "Model comparison in Emergency Severity Index level prediction". In : *Expert systems with applications* 40.17, p. 6901-6909.
- CLIFTON, David A et al. (2012). "A large-scale clinical validation of an integrated monitoring system in the emergency department". In : *IEEE journal of biomedical and health informatics* 17.4, p. 835-842.
- CLIFTON, Jesse et Eric LABER (2020). "Q-learning : theory and applications". In : *Annual Review of Statistics and Its Application* 7, p. 279-301.
- COOK, Mark J et al. (2013). "Prediction of seizure likelihood with a long-term, implanted seizure advisory system in patients with drug-resistant epilepsy : a first-in-man study". In : *The Lancet Neurology* 12.6, p. 563-571.
- CROCKETT, Leah K et al. (2018). "Knowledge sharing between general and pediatric emergency departments : connections, barriers, and opportunities". In : *Canadian Journal of Emergency Medicine* 20.4, p. 523-531.
- CURTIS, Dorothy W et al. (2008). "SMART—an integrated wireless system for monitoring unattended patients". In : *Journal of the American Medical Informatics Association* 15.1, p. 44-53.
- DARMONI, Stéfan J et al. (2000). "CISMeF : a structured health resource guide". In : *Methods of information in medicine* 39.01, p. 30-35.
- DAS, Malay K et Tapash CHAKRABORTY (2016). "ANN in pharmaceutical product and process development". In : *Artificial neural network for drug design, delivery and disposition*. Elsevier, p. 277-293.
- DEUVE, Thierry (2004). "Phylogénie et classification du genre *Carabus* Linné, 1758. Le point des connaissances actuelles (Coleoptera, Carabidae)". In : *Bulletin de la Société entomologique de France* 109.1, p. 5-39.
- DEY, Prithwiraj et Pramit PANDIT (2020). "Relevance of data transformation techniques in weed science". In : *Journal of Research in Weed Science* 3.1, p. 81-89.
- DIERCKS, Deborah B. et al. (2007). "Prolonged Emergency Department Stays of Non-ST-Segment-Elevation Myocardial Infarction Patients Are Associated With Worse Adherence to the American College of Cardiology/American Heart Association Guidelines for Management and Increased Adverse Events". In : *Annals of Emergency Medicine* 50.5, p. 489-496. ISSN : 0196-0644. DOI : <https://doi.org/10.1016/j.annemergmed.2007.03.033>. URL : <https://www.sciencedirect.com/science/article/pii/S0196064407004453>.
- DJELLAL, Asma (s. d.). "Prise en compte de la notion de flou pour la représentation d'ontologies multi-points de vue en logique de descriptions". In : ().
- DUBOIS, Didier et Henri PRADE (1987). "Properties of measures of information in evidence and possibility theories". In : *Fuzzy sets and systems* 24.2, p. 161-182.
- DUCH, Wlodzislaw, Karthikeyan SWAMINATHAN et Jaroslaw MELLER (2007). "Artificial intelligence approaches for rational drug design and discovery". In : *Current pharmaceutical design* 13.14, p. 1497-1508.
- EDELMANN, Lars et al. (2022). "Reduced Length of Stay Following Patient Pathway Optimization for Primary Hip and Knee Arthroplasty at a Swiss Hospital". In : *ClinicoEconomics and Outcomes Research* 14, p. 105-117.
- EL-DIRABY, Tamar A, Celson LIMA et B FEIS (2005). "Domain taxonomy for construction concepts : toward a formal ontology for construction knowledge". In : *Journal of computing in civil engineering* 19.4, p. 394-406.
- EL-DIRABY, Tamer E (2013). "Domain ontology for construction knowledge". In : *Journal of Construction Engineering and Management* 139.7, p. 768-784.

- EL-SAPPAGH, Shaker et Mohammed ELMOGY (2017). "A fuzzy ontology modeling for case base knowledge in diabetes mellitus domain". In : *Engineering science and technology, an international journal* 20.3, p. 1025-1040.
- EL-SAPPAGH, Shaker H et al. (2014). "An ontological case base engineering methodology for diabetes management". In : *Journal of medical systems* 38.8, p. 1-14.
- ELKIN, Peter L et al. (2018). "Artificial intelligence : bayesian versus heuristic method for diagnostic decision support". In : *Applied clinical informatics* 9.02, p. 432-439.
- ELLIMAN, Dave et JRG PULIDO (2002). "Visualizing ontology components through self-organizing maps". In : *Proceedings Sixth International Conference on Information Visualisation*. IEEE, p. 434-438.
- ERGEN, Mustafa et al. (2019). "What is artificial intelligence? Technical considerations and future perception". In : *Anatolian J. Cardiol* 22.2, p. 5-7.
- EUZENAT, Jérôme et Pavel SHVAIKO (2013). "Overview of matching systems". In : *Ontology Matching*. Springer, p. 201-283.
- EVERMANN, Joerg, Jana-Rebecca REHSE et Peter FETTKKE (2017). "XES tensorflow-Process prediction using the tensorflow deep-learning framework". In : *arXiv preprint arXiv :1705.01507*.
- FAKHFAKH, Khouloud, Ahmed MAALEL et Waad FARHAT (2019). "Towards a Pancreatic Lesions Disease Classification System based on Ontologies". In : *2019 6th International Conference on Control, Decision and Information Technologies (CoDIT)*. IEEE, p. 1474-1479.
- FAKHFAKH, Khouloud et al. (2021a). "Fuzzy Ontology for Patient Emergency Department Triage". In : *International Conference on Computational Science*. Springer, p. 719-734.
- FAKHFAKH, Khouloud et al. (2021b). "Ontology for Overcrowding Management in Emergency Department". In : *MedInfo Medical and Health Informatics*.
- FAN, Guo-Feng et al. (2019). "Application of the weighted k-nearest neighbor algorithm for short-term load forecasting". In : *Energies* 12.5, p. 916.
- FARION, Ken et al. (2009). "Clinical decision support system for point of care use". In : *Methods of information in medicine* 48.04, p. 381-390.
- FAROOQ, Muhammad Usman et Usman QAMAR (2022). "Develop an Ontology for E-Commerce based on a Web Application to Assist Color-blind people". In : *2022 2nd International Conference on Digital Futures and Transformative Technologies (ICoDT2)*. IEEE, p. 1-5.
- FASIHI, Maedeh Sadat et Wasfy B MIKHAEL (2016). "Overview of current biomedical image segmentation methods". In : *2016 International Conference on Computational Science and Computational Intelligence (CSCI)*. IEEE, p. 803-808.
- FELDMAN, RONEN, James SANGER et al. (2007). *The text mining handbook : advanced approaches in analyzing unstructured data*. Cambridge university press.
- FENSEL, Dieter (2001). "Ontologies". In : *Ontologies*. Springer, p. 11-18.
- FERNANDES, Marta et al. (2020). "Clinical decision support systems for triage in the emergency department using intelligent systems : a review". In : *Artificial Intelligence in Medicine* 102, p. 101762.
- FERNÁNDEZ-LÓPEZ, Mariano, Asunción GÓMEZ-PÉREZ et Natalia JURISTO (1997). "Methontology : from ontological art towards ontological engineering". In.
- FIELD, Matthew et al. (2022). "Infrastructure platform for privacy-preserving distributed machine learning development of computer-assisted theragnostics in cancer". In : *Journal of Biomedical Informatics*, p. 104181.
- FISCHER, Thomas et Christopher KRAUSS (2018). "Deep learning with long short-term memory networks for financial market predictions". In : *European journal of operational research* 270.2, p. 654-669.



- FOSTER, Kenneth R, Robert KOPROWSKI et Joseph D SKUFCA (2014). "Machine learning, medical diagnosis, and biomedical engineering research-commentary". In : *Biomedical engineering online* 13.1, p. 1-9.
- FU, Chao et al. (2022). "Cross-domain decision making based on TrAdaBoost for diagnosis of breast lesions". In : *Artificial Intelligence Review*, p. 1-31.
- GAIESKI, David F et al. (2017). "The impact of ED crowding on early interventions and mortality in patients with severe sepsis". In : *The American journal of emergency medicine* 35.7, p. 953-960.
- GAMS, Matjaž et al. (2014). "Integrating artificial and human intelligence into tablet production process". In : *Aaps Pharmscitech* 15.6, p. 1447-1453.
- GANGEMI, Aldo et al. (2002). "Sweetening ontologies with DOLCE". In : *International conference on knowledge engineering and knowledge management*. Springer, p. 166-181.
- GAO, Fei et al. (2022). "Predictive Models for Emergency Department Triage using Machine Learning : A Systematic Review". In : *Obstetrics and Gynecology Research* 5.2, p. 136-157.
- GAO, Jing (2012). "Data preprocessing". In.
- GARCIA, Frédérick et Emmanuel RACHELSON (2013). "Markov decision processes". In : *Markov Decision Processes in Artificial Intelligence*, p. 1-38.
- GARCÍA, Salvador et al. (2016). "Big data preprocessing : methods and prospects". In : *Big Data Analytics* 1.1, p. 1-22.
- GARCÍA-FERNÁNDEZ, Lorena et al. (2022). "Different emotional profile of health care staff and general population during the COVID-19 outbreak." In : *Psychological Trauma : Theory, Research, Practice, and Policy* 14.2, p. 266.
- GARCÍA-GONZALO, Esperanza et al. (2016). "Hard-rock stability analysis for span design in entry-type excavations with learning classifiers". In : *Materials* 9.7, p. 531.
- GAYRARD, Pascale (s. d.). "Urgences & demandes de soins en urgence". In : ().
- GAZZAH-URGENTISTE, Mounir (s. d.). "Solutés De Perfusion Et Solutés De Remplissage". In : ().
- GERSTNER, Wulfram et al. (2006). "Réseaux de neurone artificiels, une introduction à l'apprentissage automatique". In : *Laboratory of computational neuroscience*.
- GHAFAPOUR, Ahmad et al. (2016). "A review of the dedicated studies to breast cancer diagnosis by thermal imaging in the fields of medical and artificial intelligence sciences". In : *Biomedical Research* 27.2, p. 543-552.
- GHAMRI, Salah Eddine (2016). "Commande Neuronale d'un Robot Mobile Non-Holonome avec glissement des roues". In : *Mémoire Présenté pour l'obtention du diplôme de MAGISTER en Électronique, Centre universitaire Batna2*.
- GHANI, MAMA, FATIMA DIHMANE, SMAIL MANSOURI et al. (2017). "COMMANDE VECTORIELLE DE LA MACHINE ASYNCHRONE A DOUBLE ALIMONTATION PAR LA LOGIQUE FLOUE". Thèse de doct. Université Ahmed Draia-ADRAR.
- GHAZOUANI, Fethi (2018). "Modélisation spatio-temporelle multi-niveau à base d'ontologies pour le suivi de la dynamique en imagerie satellitaire". Thèse de doct. Ecole nationale supérieure Mines-Télécom Atlantique Bretagne Pays de la Loire.
- GHORBEL, Hanène, Afef BAHRI et Rafik BOUAZIZ (2009). "Fuzzy protégé for fuzzy ontology models". In : *Age* 12.18, p. 30.
- GLIGORIJEVIC, Djordje et al. (2018). "Deep attention model for triage of emergency department patients". In : *Proceedings of the 2018 SIAM International Conference on Data Mining*. SIAM, p. 297-305.
- GOTO, Tadahiro et al. (2018). "Machine learning approaches for predicting disposition of asthma and COPD exacerbations in the ED". In : *The American journal of emergency medicine* 36.9, p. 1650-1654.

- GRABER, Mark L, Nancy FRANKLIN et Ruthanna GORDON (2005). "Diagnostic error in internal medicine". In : *Archives of internal medicine* 165.13, p. 1493-1499.
- GRAHAM, Byron et al. (2018). "Using data mining to predict hospital admissions from the emergency department". In : *IEEE Access* 6, p. 10458-10469.
- GRANDINI, Margherita, Enrico BAGLI et Giorgio VISANI (2020). "Metrics for multi-class classification : an overview". In : *arXiv preprint arXiv :2008.05756*.
- GREENHILL, Alexandra T et Bethany R EDMUNDS (2020). "A primer of artificial intelligence in medicine". In : *Techniques and Innovations in Gastrointestinal Endoscopy* 22.2, p. 85-89.
- GRIGULL, Lorenz et Werner M LECHNER (2012). "Supporting diagnostic decisions using hybrid and complementary data mining applications : a pilot study in the pediatric emergency department". In : *Pediatric research* 71.6, p. 725-731.
- GRUBER, Thomas R (1993). "A translation approach to portable ontology specifications". In : *Knowledge acquisition* 5.2, p. 199-220.
- GRÜNINGER, Michael, Katy ATEFI et Mark S Fox (2000). "Ontologies to support process integration in enterprise engineering". In : *Computational & Mathematical Organization Theory* 6.4, p. 381-394.
- GUARINO, Nicola et Pierdaniele GIARETTA (1995). "Ontologies and knowledge bases". In : *Towards very large knowledge bases*, p. 1-2.
- GUARINO, Nicola et al. (2000). "A formal ontology of properties". In : *International Conference on Knowledge Engineering and Knowledge Management*. Springer, p. 97-112.
- GUO, Gongde et al. (2003). "KNN model-based approach in classification". In : *OTM Confederated International Conferences" On the Move to Meaningful Internet Systems*". Springer, p. 986-996.
- GUPTA, Trilok et al. (2019). "Prediction of mechanical properties of rubberised concrete exposed to elevated temperature using ANN". In : *Measurement* 147, p. 106870.
- GUTTMANN, Astrid et al. (2011). "Association between waiting times and short term mortality and hospital admission after departure from emergency department : population based cohort study from Ontario, Canada". In : *Bmj* 342.
- HAMADA, Mohamed, BB ZAIDAN et AA ZAIDAN (2018). "A systematic review for human EEG brain signals based emotion classification, feature extraction, brain condition, group comparison". In : *Journal of medical systems* 42.9, p. 1-25.
- HAMET, Pavel et Johanne TREMBLAY (2017). "Artificial intelligence in medicine". In : *Metabolism* 69, S36-S40.
- HAN, Jiawei, Jian PEI et Hanghang TONG (2022). *Data mining : concepts and techniques*. Morgan kaufmann.
- HAN, Mengjie et al. (2019). "A review of reinforcement learning methodologies for controlling occupant comfort in buildings". In : *Sustainable cities and society* 51, p. 101748.
- HARRER, Stefan et al. (2019). "Artificial intelligence for clinical trial design". In : *Trends in pharmacological sciences* 40.8, p. 577-591.
- HASTIE, Trevor, Robert TIBSHIRANI et Jerome FRIEDMAN (2009). "Unsupervised learning". In : *The elements of statistical learning*. Springer, p. 485-585.
- HATZILYGEROUDIS, Ioannis et Jim PRENTZAS (2004). "Neuro-symbolic approaches for knowledge representation in expert systems". In : *International Journal of Hybrid Intelligent Systems* 1.3-4, p. 111-126.
- HAUG, Peter J et al. (2013). "An ontology-driven, diagnostic modeling system". In : *Journal of the American Medical Informatics Association* 20.e1, e102-e110.
- HAWTHORNE, Frank C et al. (2021). "Ontology, archetypes and the definition of 'mineral species'". In : *Mineralogical Magazine* 85.2, p. 125-131.
- HEDON, F (2003). "Anxiety and erectile dysfunction : a global approach to ED enhances results and quality of life". In : *International Journal of Impotence Research* 15.2, S16-S19.

- HEMAN, Mounir (2005). "Un Processus de développement d'ontologie dans le cadre du web sémantique". Thèse de doct. Oum-El-Bouaghi.
- HENDERSON, Katherine et Adrian BOYLE (2014). "Exit block in the emergency department : recognition and consequences". In : *British Journal of Hospital Medicine* 75.11, p. 623-626.
- HEUDIN, Jean-Claude (2016). *Comprendre le deep learning : une introduction aux réseaux de neurones*. Science-eBook.
- HINTON, Geoffrey E et al. (1986). "Learning distributed representations of concepts". In : *Proceedings of the eighth annual conference of the cognitive science society*. T. 1. Amherst, MA, p. 12.
- HOCHREITER, Sepp et Jürgen SCHMIDHUBER (1997). "Long short-term memory". In : *Neural computation* 9.8, p. 1735-1780.
- HOGAN, Aidan et al. (2021). "Knowledge graphs". In : *ACM Computing Surveys (CSUR)* 54.4, p. 1-37.
- HORRIDGE, Matthew et Peter F PATEL-SCHNEIDER (2009). "OWL 2 web ontology language manchester syntax". In : *W3C Working Group Note*.
- HORROCKS, Ian (2005). "Owl : A description logic based ontology language". In : *International conference on principles and practice of constraint programming*. Springer, p. 5-8.
- HORROCKS, Ian et al. (2004). "SWRL : A semantic web rule language combining OWL and RuleML". In : *W3C Member submission* 21.79, p. 1-31.
- HORROCKS, Ian et al. (2007). "OWL : a description logic based ontology language for the semantic web". In : .
- HOUILLI, HANAN (s. d.). "Une ontologie floue : Application au domaine des analyses médicales". In : ( ).
- HOYLE, Lisa (2013). "Condition yellow : a hospital-wide approach to ED overcrowding". In : *Journal of Emergency Nursing* 39.1, p. 40-45.
- HU, Ya-Lan et Liang CHEN (2018). "A nonlinear hybrid wind speed forecasting model using LSTM network, hysteretic ELM and Differential Evolution algorithm". In : *Energy conversion and management* 173, p. 123-142.
- HUANG, Shujun et al. (2018). "Applications of support vector machine (SVM) learning in cancer genomics". In : *Cancer genomics & proteomics* 15.1, p. 41-51.
- HUGLI, OW et al. (2006). "Emergency department overcrowding : a legitimate reason to refuse access to urgent care for non-urgent patients?" In : *Revue Medicale Suisse* 2.75, p. 1836-1839.
- HUSSEIN, Nemat A et al. (2017). "Mitigating overcrowding in emergency departments using Six Sigma and simulation : A case study in Egypt". In : *Operations Research for Health Care* 15, p. 1-12.
- IBRAHIM, Siti Aqilah et Zuraidin Mohd SAFAR (2021). "Comparison of Treatment Insomnia Disease Between Prescription Medication and Cognitive Behavioral Therapy Using Rstudio". In : *Applied Information Technology And Computer Science* 2.2, p. 1238-1254.
- ILKOU, Eleni et Maria KOUTRAKI (2020). "Symbolic Vs Sub-symbolic AI Methods : Friends or Enemies?" In : *CIKM (Workshops)*.
- ILYAS, Ihab F et Xu CHU (2019). *Data cleaning*. Morgan & Claypool.
- IQBAL, Ahmed et Shabib AFTAB (2019). "A Feed-Forward and Pattern Recognition ANN Model for Network Intrusion Detection." In : *International Journal of Computer Network & Information Security* 11.4.
- IQBAL, Muhammad Javed et al. (2021). "Clinical applications of artificial intelligence and machine learning in cancer diagnosis : looking into the future". In : *Cancer cell international* 21.1, p. 1-11.
- IVANOV, Oleksandr et al. (2020). "Improving Emergency Department ESI acuity assignment using machine learning and clinical natural language processing". In : *arXiv preprint arXiv :2004.05184*.

- JAIN, Vishal et Mayank SINGH (2013). "Ontology development and query retrieval using protégé tool". In : *International Journal of Intelligent Systems and Applications* 9.9, p. 67-75.
- JAISWAL, Ashish et al. (2020). "A survey on contrastive self-supervised learning". In : *Technologies* 9.1, p. 2.
- JAUPI, Luan (2002). *Contrôle de la qualité : MSP, analyse des performances et contrôle de réception*.
- JAYARAMAN, Prem Prakash et al. (2013). "An ontology-based framework for real-time collection and visualization of mobile field triage data in mass gatherings". In : *2013 46th Hawaii International Conference on System Sciences*. IEEE, p. 146-155.
- JERMYN, Paul, Maurice DIXON et Brian J READ (1999). "Preparing clean views of data for data mining". In : *ERCIM Work. on Database Res*, p. 1-15.
- JIANG, Fei et al. (2017). "Artificial intelligence in healthcare : past, present and future". In : *Stroke and vascular neurology* 2.4.
- JIN, Chen, Luo DE-LIN et Mu FEN-XIANG (2009). "An improved ID3 decision tree algorithm". In : *2009 4th international conference on computer science & Education*. IEEE, p. 127-130.
- JIROUŠEK, Radim et Prakash P SHENOY (2018). "A new definition of entropy of belief functions in the Dempster-Shafer theory". In : *International Journal of Approximate Reasoning* 92, p. 49-65.
- JO, Sion et al. (2015). "ED crowding is associated with inpatient mortality among critically ill patients admitted via the ED : post hoc analysis from a retrospective study". In : *The American journal of emergency medicine* 33.12, p. 1725-1731.
- JO, YoungJu et al. (2018). "Quantitative phase imaging and artificial intelligence : a review". In : *IEEE Journal of Selected Topics in Quantum Electronics* 25.1, p. 1-14.
- JONASSEN, K et R SABOE (1995). "The use of text encoding in the development of a terminology and knowledge system associated with the Norwegian version of the ICD-10." In : *Medinfo. MEDINFO* 8, p. 51-55.
- JONES, Dean, Trevor BENCH-CAPON et Pepijn VISSER (1998). "Methodologies for ontology development". In.
- JONES, Spencer S et R Scott EVANS (2008). "An agent based simulation tool for scheduling emergency department physicians". In : *AMIA Annual Symposium Proceedings*. T. 2008. American Medical Informatics Association, p. 338.
- JORDAN, Silvia et Martin MESSNER (2012). "Enabling control and the problem of incomplete performance indicators". In : *Accounting, Organizations and Society* 37.8, p. 544-564.
- JOSHI, Chirag, Ranjeet Kumar RANJAN et Vishal BHARTI (2021). "A Fuzzy Logic based feature engineering approach for Botnet detection using ANN". In : *Journal of King Saud University-Computer and Information Sciences*.
- KADRI, Farid (2014). "Contribution à la conception d'un système d'aide à la décision pour la gestion de situations de tension au sein des systèmes hospitaliers. Application à un service d'urgence." Thèse de doct. Université de Valenciennes et de Hainaut Cambrésis.
- KADRI, Farid, Sondès CHAABANE et Christian TAHON (2013). "Service d'urgences hospitalières : situations de tension et résilience". In : *Journées Doctorales et Journées Nationales du GDR MACS (JD-JN-MACS)*, p. 1-8.
- KARTHI, SP, MV ARVINTHLAKKSHMAN, B ASHWANTH et al. (2021). "Smart Health Monitoring System Using ANN Algorithm". In : *2021 6th International Conference on Communication and Electronics Systems (ICCES)*. IEEE, p. 1-5.
- KAUL, Vivek, Sarah ENSLIN et Seth A GROSS (2020). "History of artificial intelligence in medicine". In : *Gastrointestinal endoscopy* 92.4, p. 807-812.
- KAYSER, JJ (1997). "Use and knowledge of alternative therapy by nurse practitioners (holistic health care)". In.

- KEHRI, V et al. (2016). "Techniques of EMG signal analysis and classification of neuromuscular diseases". In : *International Conference on Communication and Signal Processing 2016 (ICCASP 2016)*. Atlantis Press, p. 481-487.
- KHIABANI, Sheida Jabbedari, Atefeh BATANI et Ehsan KHANMOHAMMADI (2022). "A hybrid decision support system for heart failure diagnosis using neural networks and statistical process control". In : *Healthcare Analytics*, p. 100110.
- KIRAL-KORNEK, Isabell et al. (2018). "Epileptic seizure prediction using big data and deep learning : toward a mobile system". In : *EBioMedicine* 27, p. 103-111.
- KLEIN, Michel et al. (2001). "The relation between ontologies and XML schemas". In : *Electronic Trans. on Artificial Intelligence* 6.4.
- KOLIAS, Vassileios D et al. (2014). "Utilizing semantic web technologies in healthcare". In : *Concepts and Trends in Healthcare Information Systems*. Springer, p. 9-19.
- KONSTANTOPOULOS, Stasinios et Georgios APOSTOLIKAS (2007). "Fuzzy-DL reasoning over unknown fuzzy degrees". In : *OTM Confederated International Conferences "On the Move to Meaningful Internet Systems"*. Springer, p. 1312-1318.
- KRAFT, Daniel L (2019). *System and methods for the production of personalized drug products*. US Patent 10,189,616.
- KRISHNAN, Rayan, Pranav RAJPURKAR et Eric J TOPOL (2022). "Self-supervised learning in medicine and healthcare". In : *Nature Biomedical Engineering*, p. 1-7.
- KRISHNAN, Sridhar et Yashodhan ATHAVALE (2018). "Trends in biomedical signal feature extraction". In : *Biomedical Signal Processing and Control* 43, p. 41-63.
- KRIZHEVSKY, Alex et al. (2012). *Advances in neural information processing systems*.
- KULSTAD, Erik B et al. (2010). "ED overcrowding is associated with an increased frequency of medication errors". In : *The American journal of emergency medicine* 28.3, p. 304-309.
- KUMAR, Deepak, Pradeepta Kumar SARANGI et Rajit VERMA (2021). "A systematic review of stock market prediction using machine learning and statistical techniques". In : *Materials Today : Proceedings*.
- LAMANTIA, Michael A et al. (2010). "Predicting hospital admission and returns to the emergency department for elderly patients". In : *Academic emergency medicine* 17.3, p. 252-259.
- LAROSE, Daniel T et Chantal D LAROSE (2014). *Discovering knowledge in data : an introduction to data mining*. T. 4. John Wiley & Sons.
- LECUN, Yann et al. (1989). "Backpropagation applied to handwritten zip code recognition". In : *Neural computation* 1.4, p. 541-551.
- LEE, Ching-Chi et al. (2012). "The impact of overcrowding on the bacterial contamination of blood cultures in the ED". In : *The American journal of emergency medicine* 30.6, p. 839-845.
- LEWIS, Roger J (2000). "An introduction to classification and regression tree (CART) analysis". In : *Annual meeting of the society for academic emergency medicine in San Francisco, California*. T. 14. Citeseer.
- LIEW, Don, Danny LIEW et Marcus P KENNEDY (2003). "Emergency department length of stay independently predicts excess inpatient length of stay". In : *Medical Journal of Australia* 179.10, p. 524-526.
- LIN, Jianhua (1991). "Divergence measures based on the Shannon entropy". In : *IEEE Transactions on Information theory* 37.1, p. 145-151.
- LINDEN, M Christien van der, Barbara EAM MEESTER et Naomi van der LINDEN (2016). "Emergency department crowding affects triage processes". In : *International emergency nursing* 29, p. 27-31.
- LIU, Nan et al. (2018). "Artificial intelligence in emergency medicine". In : *J Emerg Crit Care Med* 2.4, p. 82-82.

- LIU, Shan W et al. (2011). "An empirical assessment of boarding and quality of care : delays in care among chest pain, pneumonia, and cellulitis patients". In : *Academic Emergency Medicine* 18.12, p. 1339-1348.
- LIVANAINEN, SME et al. (2019). "Predicting onset and continuity of patient-reported symptoms in cancer patients undergoing immune checkpoint inhibitor (ICI) therapies using machine learning". In : *Annals of Oncology* 30, p. xi18.
- LIVIERIS, Ioannis E (2018). "Improving the classification efficiency of an ANN utilizing a new training methodology". In : *Informatics*. T. 6. 1. MDPI, p. 1.
- LUCKE, Jacinta A et al. (2018). "Early prediction of hospital admission for emergency department patients : a comparison between patients younger or older than 70 years". In : *Emergency Medicine Journal* 35.1, p. 18-27.
- LUENGO-OROZ, Miguel et al. (2020). "Artificial intelligence cooperation to support the global response to COVID-19". In : *Nature Machine Intelligence* 2.6, p. 295-297.
- MA, Zhenghui et Ata KABAN (2013). "K-Nearest-Neighbours with a novel similarity measure for intrusion detection". In : *2013 13th UK Workshop on Computational Intelligence (UKCI)*. IEEE, p. 266-271.
- MAÅLEJ, Sahar et al. (2010). "Construction des composants ontologiques flous à partir de corpus de données sémantiques flous." In : *INFORSID*, p. 361-376.
- MADHULATHA, T Soni (2012). "An overview on clustering methods". In : *arXiv preprint arXiv :1205.1117*.
- MAHMOOD, Hanya et al. (2021). "Artificial Intelligence-based methods in head and neck cancer diagnosis : An overview". In : *British journal of cancer* 124.12, p. 1934-1940.
- MALIK, Paras, Monika PATHANIA, Vyas Kumar RATHAUR et al. (2019). "Overview of artificial intelligence in medicine". In : *Journal of family medicine and primary care* 8.7, p. 2328.
- McCUSKER, Jane et al. (2014). "Increases in emergency department occupancy are associated with adverse 30-day outcomes". In : *Academic Emergency Medicine* 21.10, p. 1092-1100.
- McGUINNESS, Deborah L, Frank VAN HARMELEN et al. (2004). "OWL web ontology language overview". In : *W3C recommendation* 10.10, p. 2004.
- MESSAOUDI, Rim (2021). "Intégration d'ontologies dans la classification parallèle de données médicales pour le diagnostic de lésions du foie". Thèse de doct. Université Clermont Auvergne (2021-...)
- MEZIANE, Farid et al. (2000). "Intelligent systems in manufacturing : current developments and future prospects". In : *Integrated manufacturing systems*.
- MIAO, Jiaju et Wei ZHU (2022). "Precision-recall curve (PRC) classification trees". In : *Evolutionary intelligence* 15.3, p. 1545-1569.
- MICHALOWSKI, Wojtek et al. (2005). "Design and development of a mobile system for supporting emergency triage". In : *Methods of Information in Medicine* 44.01, p. 14-24.
- MILLS, Angela M et al. (2009). "The association between emergency department crowding and analgesia administration in acute abdominal pain patients". In : *Academic Emergency Medicine* 16.7, p. 603-608.
- MILNER, PC (1988). "Forecasting the demand on accident and emergency departments in health districts in the Trent region". In : *Statistics in medicine* 7.10, p. 1061-1072.
- MINSKY, Marvin et Seymour PAPERT (1969). "An introduction to computational geometry". In : *Cambridge tiass., HIT* 479, p. 480.
- MINSKY, Marvin L (1991). "Logical versus analogical or symbolic versus connectionist or neat versus scruffy". In : *AI magazine* 12.2, p. 34-34.
- MINTZ, Yoav et Ronit BRODIE (2019). "Introduction to artificial intelligence in medicine". In : *Minimally Invasive Therapy & Allied Technologies* 28.2, p. 73-81.
- MISHRA, Apoorva et Anupam SHUKLA (2017). "From machine learning to deep learning : Trends and challenges". In : *CSI Communications* 41.8, p. 10-12.

- MITCHELL, Tom et al. (1990). "Machine learning". In : *Annual review of computer science* 4.1, p. 417-433.
- МНИН, Volodymyr et al. (2015). "Human-level control through deep reinforcement learning". In : *nature* 518.7540, p. 529-533.
- MOHAMMADI, Reza, SMT Fatemi GHOMI et Farzad ZEINALI (2014). "A new hybrid evolutionary based RBF networks method for forecasting time series : a case study of forecasting emergency supply demand time series". In : *Engineering Applications of Artificial Intelligence* 36, p. 204-214.
- MOHAPATRA, Pritish, CV JAWAHAR et M Pawan KUMAR (2014). "Efficient optimization for average precision svm". In : *Advances in Neural Information Processing Systems* 27.
- MOISDON, Jean-Claude et Michel PEPIN (2010). "Les impacts de la T2A sur les modes d'organisation et de fonctionnement des établissements de santé". In : *DREES, Etudes et Recherches* 97.
- MOLLA, Michael et al. (2004). "Using machine learning to design and interpret gene-expression microarrays". In : *AI Magazine* 25.1, p. 23-23.
- MONTREUIL, Marjorie (s. d.). "Collaboration à la rédaction". In : ().
- MORLEY, Claire et al. (2018). "Emergency department crowding : a systematic review of causes, consequences and solutions". In : *PloS one* 13.8, e0203316.
- MOSKOP, John C et al. (2019). "Another look at the persistent moral problem of emergency department crowding". In : *Annals of emergency medicine* 74.3, p. 357-364.
- MURPHY, Kevin P (2022). *Probabilistic machine learning : an introduction*. MIT press.
- MURTAGH, Fionn (1991). "Multilayer perceptrons for classification and regression". In : *Neuro-computing* 2.5-6, p. 183-197.
- MUSTAFA, Mohammed Kyari, Tony ALLEN et Kofi APPIAH (2019). "A comparative review of dynamic neural networks and hidden Markov model methods for mobile on-device speech recognition". In : *Neural Computing and Applications* 31.2, p. 891-899.
- MYLES, Anthony J et al. (2004). "An introduction to decision tree modeling". In : *Journal of Chemometrics : A Journal of the Chemometrics Society* 18.6, p. 275-285.
- NAEMI, Amin et al. (2021). "Machine learning techniques for mortality prediction in emergency departments : a systematic review". In : *BMJ open* 11.11, e052663.
- NAMEY, Emily et al. (2008). "Data reduction techniques for large qualitative data sets". In : *Handbook for team-based qualitative research* 2.1, p. 137-161.
- NARAYANASAMY, Senthil Kumar et al. (2022). "A contemporary review on utilizing semantic web technologies in healthcare, virtual communities, and ontology-based information processing systems". In : *Electronics* 11.3, p. 453.
- NATARAJAN, Yuvaraj, Srihari KANNAN et Sachi Nandan MOHANTY (2021). "Survey of Various Statistical Numerical and Machine Learning Ontological Models on Infectious Disease Ontology". In : *Data Analytics in Bioinformatics : A Machine Learning Perspective*, p. 431-442.
- NAUBOURG, Pierre, Marinette SAVONNET et Kokou YÉTONGNON (2011). "Approche préventive de la qualité des données d'importation dans le contexte de la protéomique clinique". In : *QDC-EvalECD 2011*.
- NIJEWEME-D'HOLLOSY, Wendy Oude et al. (2018). "Evaluation of three machine learning models for self-referral decision support on low back pain in primary care". In : *International journal of medical informatics* 110, p. 31-41.
- NIPPAK, PM et al. (2014). "Is there a relation between emergency department and inpatient lengths of stay". In : *Can J Rural Med* 19.1, p. 12-20.
- NOEL, Guilhem, Camille DRIGUES et Gilles VIUDES (2018). "Which indicators to include in a crowding scale in an emergency department? A national French Delphi study". In : *European Journal of Emergency Medicine* 25.4, p. 257-263.

- NOËL, Guilhem et al. (2019). "Real-time estimation of inpatient beds required in emergency departments". In : *European Journal of Emergency Medicine* 26.6, p. 440-445.
- NOY, N, Deborah L MCGUINNESS et al. (2001). "Ontology development 101". In : *Knowledge Systems Laboratory, Stanford University* 2001.
- NTOUTSI, Eirini et al. (2020). "Bias in data-driven artificial intelligence systems—An introductory survey". In : *Wiley Interdisciplinary Reviews : Data Mining and Knowledge Discovery* 10.3, e1356.
- NØRGAARD, M et al. (2001). *Neural networks for modelling and control of dynamic systems*. Springer-Verlag London Limited. London. England.
- OBRST, Leo et al. (2007). "The evaluation of ontologies". In : *Semantic web*. Springer, p. 139-158.
- O'CONNOR, Martin et al. (2005). "Writing rules for the semantic web using SWRL and Jess". In : *Protégé With Rules WS, Madrid*.
- OSMAN, Mohamad Amin, Shahrul Azman Mohd NOAH et Saidah SAAD (2022). "Ontology-Based Knowledge Management Tools for Knowledge Sharing in Organization—A Review". In : *IEEE Access* 10, p. 43267-43283.
- PANESAR, Arjun (2019). *Machine learning and AI for healthcare*. Springer.
- PANISSON, Alison R et al. (2015). "Arguing about task reallocation using ontological information in multi-agent systems". In : *12th International Workshop on Argumentation in Multiagent Systems*. T. 108.
- PASCASIE, Kagobora et Ntombifikile Gloria MTSHALI (2014). "A descriptive analysis of emergency department overcrowding in a selected hospital in Kigali, Rwanda". In : *African Journal of Emergency Medicine* 4.4, p. 178-183.
- PAUL, Debleena et al. (2021). "Artificial intelligence in drug discovery and development". In : *Drug discovery today* 26.1, p. 80.
- PAUL, Sharoda A, Madhu C REDDY et Christopher J DEFLITCH (2010). "A systematic review of simulation studies investigating emergency department overcrowding". In : *Simulation* 86.8-9, p. 559-571.
- PEDRO, J San et al. (2005). "On development and evaluation of prototype mobile decision support for hospital triage". In : *Proceedings of the 38th Annual Hawaii International Conference on System Sciences*. IEEE, p. 157c-157c.
- PENG, Lu et al. (2018). "Effective long short-term memory with differential evolution algorithm for electricity price prediction". In : *Energy* 162, p. 1301-1314.
- PHUONG, Nguyen Hoang et Vladik KREINOVICH (2001). "Fuzzy logic and its applications in medicine". In : *International journal of medical informatics* 62.2-3, p. 165-173.
- PIERRA, Guy (2008). "Context representation in domain ontologies and its use for semantic integration of data". In : *Journal on data semantics X*. Springer, p. 174-211.
- PINES, Jesse M et al. (2009). "The association between emergency department crowding and adverse cardiovascular outcomes in patients with chest pain". In : *Academic Emergency Medicine* 16.7, p. 617-625.
- PINES, Jesse M et al. (2011). "Practical implications of implementing emergency department crowding interventions : summary of a moderated panel". In : *Academic Emergency Medicine* 18.12, p. 1278-1282.
- POLI, Roberto et Johanna SEIBT (2010). *Theory and applications of ontology : Philosophical perspectives*. Springer.
- PUTERMAN, Martin L (1990). "Markov decision processes". In : *Handbooks in operations research and management science* 2, p. 331-434.
- QING, Xiangyun et Yugang NIU (2018). "Hourly day-ahead solar irradiance prediction using weather forecasts by LSTM". In : *Energy* 148, p. 461-468.



- QUAN, Thanh Tho, Siu Cheung HUI et Tru Hoang CAO (2004). "FOGA : A fuzzy ontology generation framework for scholarly semantic web". In : *Proceedings of the Knowledge Discovery and Ontologies Workshop, Pisa, Italy*. T. 24. Citeseer.
- QUINLAN, J. Ross (1996). "Learning decision tree classifiers". In : *ACM Computing Surveys (CSUR)* 28.1, p. 71-72.
- QUINLAN, J Ross (2014). *C4. 5 : programs for machine learning*. Elsevier.
- RADO, Omesaad AM (2019). "Contributions to evaluation of machine learning models. Applicability domain of classification models". Thèse de doct. University of Bradford.
- RAHMAN, Md et al. (2022). "CRISPR-Based Programmable Nucleic Acid-Binding Protein Technology Can Specifically Detect Fatal Tropical Disease-Causing Pathogens". In : *Journal of Tropical Medicine* 2022.
- RAI, Hari Mohan et Kalyan CHATTERJEE (2018). "A unique feature extraction using MRDWT for automatic classification of abnormal heartbeat from ECG big data with multilayered probabilistic neural network classifier". In : *Applied Soft Computing* 72, p. 596-608.
- RAJDHAN, Apurb et al. (2020). "Heart disease prediction using machine learning". In : *International Journal of Research and Technology* 9.04, p. 659-662.
- RAJPATHAK, Dnyanesh, Enrico MOTTA et Rajkumar ROY (2001). "A generic task ontology for scheduling applications". In.
- RAMCHOUN, Hassan et al. (2016). "Multilayer perceptron : Architecture optimization and training". In.
- RANTANEN, Jukka et Johannes KHINAST (2015). "The future of pharmaceutical manufacturing sciences". In : *Journal of pharmaceutical sciences* 104.11, p. 3612-3638.
- RANWEZ, Sylvie (2013). "Les ontologies comme support à l'interaction et à la personnalisation dans un processus décisionnel. Exploitation de la sémantique pour favoriser l'automatisation cognitive". Thèse de doct. Université Montpellier II-Sciences et Techniques du Languedoc.
- RAVANELLI, Mirco et al. (2020). "Multi-task self-supervised learning for robust speech recognition". In : *ICASSP 2020-2020 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*. IEEE, p. 6989-6993.
- RENDERS, Jean-Michel (1995). *Algorithmes génétiques et réseaux de neurones : Applications à la commande de processus*. Hermès Paris.
- RESEARCH, CB Insights (2017). "Healthcare remains the hottest AI category for deals." In.
- REZNEK, Martin A et al. (2017). "Door-to-imaging time for acute stroke patients is adversely affected by emergency department crowding". In : *Stroke* 48.1, p. 49-54.
- RICHARDSON, Drew et Kristin LH McMAHON (2009). "Emergency department access block occupancy predicts delay to surgery in patients with fractured neck of femur". In : *Emergency Medicine Australasia* 21.4, p. 304-308.
- RICHARDSON, Drew B (2002). "The access-block effect : relationship between delay to reaching an inpatient bed and inpatient length of stay". In : *Medical Journal of Australia* 177.9, p. 492-495.
- RIGATTI, Steven J (2017). "Random forest". In : *Journal of Insurance Medicine* 47.1, p. 31-39.
- RONG, Guoguang et al. (2020). "Artificial Intelligence in Healthcare : Review and Prediction Case Studies". In : *Engineering* 6.3, p. 291-301. ISSN : 2095-8099. DOI : <https://doi.org/10.1016/j.eng.2019.08.015>. URL : <https://www.sciencedirect.com/science/article/pii/S2095809919301535>.
- ROSATI, Riccardo (2007). "The limits of querying ontologies". In : *International Conference on Database Theory*. Springer, p. 164-178.
- ROSSE, Cornelius et Jose LV MEJINO (2008). "The foundational model of anatomy ontology". In : *Anatomy Ontologies for Bioinformatics*. Springer, p. 59-117.
- ROY, PM et Y LANNEHOA (2002). "Le triage aux urgences". In : *Réanimation* 11.7, p. 480-485.

- RÜCKSTIESS, Thomas Frank (2016). "Reinforcement Learning in Supervised Problem Domains". Thèse de doct. Technische Universität München.
- RUGGIERI, Salvatore (2002). "Efficient C4. 5 [classification algorithm]". In : *IEEE transactions on knowledge and data engineering* 14.2, p. 438-444.
- SAGHEER, Alaa et Mostafa КОТВ (2019). "Time series forecasting of petroleum production using deep LSTM recurrent networks". In : *Neurocomputing* 323, p. 203-213.
- SAHU, Shailendra et Babu M МЕНТРЕ (2015). "Network intrusion detection system using J48 Decision Tree". In : *2015 International Conference on Advances in Computing, Communications and Informatics (ICACCI)*. IEEE, p. 2023-2026.
- SALWAY, RJ et al. (2017). "Emergency department (ED) overcrowding : evidence-based answers to frequently asked questions". In : *Revista Médica Clínica Las Condes* 28.2, p. 213-219.
- SALZBERG, Steven L (1994). *C4. 5 : Programs for machine learning by j. ross quinlan*. morgan kaufmann publishers, inc., 1993.
- SÁNCHEZ-SALMERÓN, Rocío et al. (2022). "Machine learning methods applied to triage in emergency services : A systematic review". In : *International Emergency Nursing* 60, p. 101109.
- SANZ-GARCIA, Enrique et al. (2022). "Monitoring and adapting cancer treatment using circulating tumor DNA kinetics : Current research, opportunities, and challenges". In : *Science Advances* 8.4, eabi8618.
- SARKER, Iqbal H (2021). "Deep cybersecurity : a comprehensive overview from neural network and deep learning perspective". In : *SN Computer Science* 2.3, p. 1-16.
- SAVIOLI, Gabriele et al. (2022). "Emergency department overcrowding : Understanding the factors to find corresponding solutions". In : *Journal of Personalized Medicine* 12.2, p. 279.
- SCHREIBER, Guus, Bob WIELINGA, Wouter JANSWEIJER et al. (1995). "The KACTUS view on the 'O'word". In : *IJCAI workshop on basic ontological issues in knowledge sharing*. T. 20. Citeseer, p. 21.
- SCHREIBER, Guus et al. (1994). "CML : The CommonKADS conceptual modelling language". In : *International Conference on Knowledge Engineering and Knowledge Management*. Springer, p. 1-25.
- SHAFER, Glenn (1976). *A mathematical theory of evidence*. T. 42. Princeton university press.
- (1992). "Dempster-shafer theory". In : *Encyclopedia of artificial intelligence* 1, p. 330-331.
- SHAHEEN, Mohammed Yousef (2021). "Applications of Artificial Intelligence (AI) in healthcare : A review". In : *ScienceOpen Preprints*.
- SHERIMON, PC et al. (2013). "Ontology based system architecture to predict the risk of hypertension in related diseases". In : *Journal of Information Processing and Management* 4.4, p. 44-50.
- SINGER, Adam J et al. (2011). "The association between length of emergency department boarding and mortality". In : *Academic Emergency Medicine* 18.12, p. 1324-1329.
- SMETS, Philippe (1990). "The combination of evidence in the transferable belief model". In : *IEEE Transactions on pattern analysis and machine intelligence* 12.5, p. 447-458.
- SMITH, Elme et Jan ELOFF (2000). "Cognitive fuzzy modeling for enhanced risk assessment in a health care institution". In : *IEEE Intelligent Systems and their Applications* 15.2, p. 69-75.
- SOININEN, Timo et al. (1998). "Towards a general ontology of configuration". In : *Ai Edam* 12.4, p. 357-372.
- SOUFI, Mahsa Dehghani et al. (2018). "Decision support system for triage management : A hybrid approach using rule-based reasoning and fuzzy logic". In : *International journal of medical informatics* 114, p. 35-44.
- SOWA, John F (1992). "Conceptual graphs as a universal knowledge representation". In : *Computers & Mathematics with Applications* 23.2-5, p. 75-93.

- SPYNS, Peter, Robert MEERSMAN et Mustafa JARRAR (2002). "Data modelling versus ontology engineering". In : *ACM SIGMod Record* 31.4, p. 12-17.
- STAAB, Steffen et Alexander MAEDCHE (2000). *Axioms are objects, too : Ontology engineering beyond the modeling of concepts and relations*. Univ.
- STACEY, William C (2018). "Seizure prediction is possible—now let's make it practical". In : *EBioMedicine* 27, p. 3-4.
- STAVERT-DOBSON, Adrian (2016). "Health Information Systems". In : *Health Informatics, Cham : Springer International Publishing*.
- STEINER, Sebastian et al. (2019). "Organic synthesis in a modular robotic system driven by a chemical programming language". In : *Science* 363.6423, eaav2211.
- STOITSIS, John et al. (2006). "Computer aided diagnosis based on medical image processing and artificial intelligence methods". In : *Nuclear Instruments and Methods in Physics Research Section A : Accelerators, Spectrometers, Detectors and Associated Equipment* 569.2, p. 591-595.
- STOKLOSA, Hanni et al. (2018). "Do EPs change their clinical behaviour in the hallway or when a companion is present? A cross-sectional survey". In : *Emergency Medicine Journal* 35.7, p. 406-411.
- STONEBRAKER, Michael, Ihab F ILYAS et al. (2018). "Data Integration : The Current Status and the Way Forward." In : *IEEE Data Eng. Bull.* 41.2, p. 3-9.
- STRACCIA, Umberto (2001). "Reasoning within fuzzy description logics". In : *Journal of artificial intelligence research* 14, p. 137-166.
- (2005). "Fuzzy ALC with fuzzy concrete domains". In : *Proceedings of the International Workshop on Description Logics (DL-05)*. T. 147. Citeseer, p. 96-103.
- SUCHARITHA, G et Deshoju Vemana CHARY (2021). "Predicting the effect of Covid-19 by using Artificial Intelligence : A case study". In : *Materials today : proceedings*.
- SULEIMAN, Mani et al. (2022). "Bayesian prediction of emergency department wait time". In : *Health Care Management Science* 25.2, p. 275-290.
- SUN, Benjamin C et al. (2013). "Effect of emergency department crowding on outcomes of admitted patients". In : *Annals of emergency medicine* 61.6, p. 605-611.
- SUN, Yan et al. (2009). "Forecasting daily attendances at an emergency department to aid resource planning". In : *BMC emergency medicine* 9.1, p. 1-9.
- SUTTON, Richard S et Andrew G BARTO (2018). *Reinforcement learning : An introduction*. MIT press.
- TAKCI, Hidayet (2022). "Invasive, Non-Invasive, Machine Learning, and Artificial Intelligence Based Methods for Prediction of Heart Failure". In.
- TEIXEIRA, Milene Santos, Vinícius MARAN et Mauro DRAGONI (2021). "The interplay of a conversational ontology and AI planning for health dialogue management". In : *Proceedings of the 36th annual ACM symposium on applied computing*, p. 611-619.
- TEKWANI, Karis L et al. (2013). "Emergency department crowding is associated with reduced satisfaction scores in patients discharged from the emergency department". In : *Western Journal of Emergency Medicine* 14.1, p. 11.
- TRAVERS, Debbie (1999). "Triage : How long does it take? How long should it take?" In : *Journal of Emergency Nursing* 25.3, p. 238-240.
- TSAL, Ming-Ta et al. (2016). "The influence of emergency department crowding on the efficiency of care for acute stroke patients". In : *International Journal for Quality in Health Care* 28.6, p. 774-778.
- USAMA, M (1996). "Advances in knowledge discovery and data mining". In.
- USCHOLD, Michael (1996). "Converting an informal ontology into ontolingua : Some experiences". In : *TECHNICAL REPORT-UNIVERSITY OF EDINBURGH ARTIFICIAL INTELLIGENCE APPLICATIONS INSTITUTE AIAI TR*.

- USCHOLD, Mike et al. (1998). "The enterprise ontology". In : *The knowledge engineering review* 13.1, p. 31-89.
- VAN ENGELLEN, Jesper E et Holger H Hoos (2020). "A survey on semi-supervised learning". In : *Machine Learning* 109.2, p. 373-440.
- VANNAN, Elizabeth (2001). "Quality Data—An Improbable Dream?." In : *Educause Quarterly* 24.1, p. 56-58.
- VASHISTHA, Rajat et al. (2018). "Futuristic biosensors for cardiac health care : an artificial intelligence approach". In : *3 Biotech* 8.8, p. 1-11.
- VATANSEVER, Sezen et al. (2021). "Artificial intelligence and machine learning-aided drug discovery in central nervous system diseases : state-of-the-arts and future directions". In : *Medicinal research reviews* 41.3, p. 1427-1473.
- VERELST, Sandra et al. (2015). "Emergency Department Crowding in Relation to In-hospital Adverse Medical Events : A Large Prospective Observational Cohort Study". In : *The Journal of Emergency Medicine* 49.6, p. 949-961. ISSN : 0736-4679. DOI : <https://doi.org/10.1016/j.jemermed.2015.05.034>. URL : <https://www.sciencedirect.com/science/article/pii/S0736467915005235>.
- VILLENEUVE, Eric et al. (2019). "Decision support in precision sheep farming". In : *IFAC-PapersOnLine* 51.34, p. 236-241.
- VISHWANATHAN, SVM et M Narasimha MURTY (2002). "SSVM : a simple SVM algorithm". In : *Proceedings of the 2002 International Joint Conference on Neural Networks. IJCNN'02 (Cat. No. 02CH37290)*. T. 3. IEEE, p. 2393-2398.
- VOGEL, Claude (1988). *Génie cognitif*. Masson.
- VOORBRAAK, Frans (1989). "A computationally efficient approximation of Dempster-Shafer theory". In : *International Journal of Man-Machine Studies* 30.5, p. 525-536.
- W SHI, Tham et al. (2017). "A review of gene selection tools in classifying cancer microarray data". In : *Current Bioinformatics* 12.3, p. 202-212.
- WANG, Fei et Anita PREININGER (2019). "AI in health : state of the art, challenges, and future directions". In : *Yearbook of medical informatics* 28.01, p. 016-026.
- WANG, Haifeng et Dejin HU (2005). "Comparison of SVM and LS-SVM for regression". In : *2005 International conference on neural networks and brain*. T. 1. IEEE, p. 279-283.
- WANG, Jin et al. (2015). "Patient admission prediction using a pruned fuzzy min-max neural network with rule extraction". In : *Neural Computing and Applications* 26.2, p. 277-289.
- WANG, Ningkui et al. (2020). "An improved evidence theory-based trust model for multiagent resource allocation". In : *2020 IEEE International Conference on Systems, Man, and Cybernetics (SMC)*. IEEE, p. 600-607.
- WARREN, Paul et al. (2015). "Making sense of description logics". In : *Proceedings of the 11th International Conference on Semantic Systems*, p. 49-56.
- WATKINS, Christopher John Cornish Hellaby (1989). "Learning from delayed rewards". In.
- WEBB, Geoffrey I, Eamonn KEOGH et Risto MIKKULAINEN (2010). "Naïve Bayes." In : *Encyclopedia of machine learning* 15, p. 713-714.
- WESSLING, Daniel et al. (2022). "Reduction in Acquisition Time and Improvement in Image Quality in T2-Weighted MR Imaging of Musculoskeletal Tumors of the Extremities Using a Novel Deep Learning-Based Reconstruction Technique in a Turbo Spin Echo (TSE) Sequence". In : *Tomography* 8.4, p. 1759-1769.
- WU, Xindong et al. (2008). "Top 10 algorithms in data mining". In : *Knowledge and information systems* 14.1, p. 1-37.
- WUERZ, Richard C et al. (2001). "Implementation and refinement of the emergency severity index". In : *Academic Emergency Medicine* 8.2, p. 170-176.

- WUNSCH, Guilherme, Cristiano A DA COSTA et Rodrigo R RIGHI (2017). "A semantic-based model for triage patients in emergency departments". In : *Journal of medical systems* 41.4, p. 1-12.
- XIAO, Jin et al. (2010). "A dynamic classifier ensemble selection approach for noise data". In : *Information Sciences* 180.18, p. 3402-3421.
- YACIM, Joseph Awoamim et Douw Gert Brand BOSHOFF (2018). "Impact of artificial neural networks training algorithms on accurate prediction of property values". In : *Journal of Real Estate Research* 40.3, p. 375-418.
- YADAV, Kabir et al. (2016). "Automated outcome classification of computed tomography imaging reports for pediatric traumatic brain injury". In : *Academic emergency medicine* 23.2, p. 171-178.
- YERSIN, B (2006). "Difficultes d'accès aux urgences : un indicateur sensible de la crise du système de santé?" In : *Revue Médicale Suisse* 75, p. 1827.
- YOUSEFZADEH AGHDAM, Mahdi et al. (2022). "A new Ontology-based Multi-Agent System model For Air Traffic Management". In : *International Journal of Transportation Engineering*.
- YUCEL, Gulcin et al. (2012). "A fuzzy risk assessment model for hospital information system implementation". In : *Expert Systems with Applications* 39.1, p. 1211-1218.
- ZADEH, Lotfi A (1965). "Fuzzy sets". In : *Information and control* 8.3, p. 338-353.
- (1990). "The birth and evolution of fuzzy logic". In : *International Journal of General System* 17.2-3, p. 95-105.
- ZADEH, Lotfi Asker (1978). "Fuzzy sets as a basis for a theory of possibility". In : *Fuzzy sets and systems* 1.1, p. 3-28.
- ZENUNI, Xhemal et al. (2015). "State of the art of semantic web for healthcare". In : *Procedia-Social and Behavioral Sciences* 195, p. 1990-1998.
- ZERFASS, Ansgar, Jens HAGELSTEIN et Ralph TENCH (2020). "Artificial intelligence in communication management : a cross-national study on adoption and knowledge, impact, challenges and risks". In : *Journal of Communication Management* 24.4, p. 377-389.
- ZHANG, Caiming et Yang LU (2021). "Study on artificial intelligence : The state of the art and future prospects". In : *Journal of Industrial Information Integration* 23, p. 100224.
- ZHANG, Fu et al. (2013). "Construction of fuzzy OWL ontologies from fuzzy EER models : A semantics-preserving approach". In : *Fuzzy Sets and Systems* 229, p. 1-32.
- ZHANG, Shichao et al. (2017). "Efficient kNN classification with different numbers of nearest neighbors". In : *IEEE transactions on neural networks and learning systems* 29.5, p. 1774-1785.
- ZHAO, Xinxing et al. (2022). "Predicting hospital emergency department visits with deep learning approaches". In : *Biocybernetics and Biomedical Engineering*.
- ZHOU, Jian-Cang et al. (2012). "High hospital occupancy is associated with increased risk for patients boarding in the emergency department". In : *The American journal of medicine* 125.4, 416-e1.
- ZHOU, Xiao-Yun et al. (2020). "Application of artificial intelligence in surgery". In : *Frontiers of medicine* 14.4, p. 417-430.
- ZHOU, Zhi-Hua (2021). *Machine learning*. Springer Nature.
- ZHU, Xiaojin et Andrew B GOLDBERG (2009). "Introduction to semi-supervised learning". In : *Synthesis lectures on artificial intelligence and machine learning* 3.1, p. 1-130.
- ZMIRI, Dror, Yuval SHAHAR et Meirav TAIEB-MAIMON (2012). "Classification of patients by severity grades during triage in the emergency department using data mining methods". In : *Journal of evaluation in clinical practice* 18.2, p. 378-388.
- ZOUAOUI, Samia et Khaled REZEG (2021). "A novel quranic search engine using an ontology-based semantic indexing". In : *Arabian Journal for Science and Engineering* 46.4, p. 3653-3674.

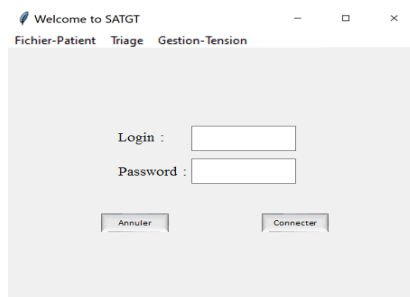
ANNEXE 1

Échelle de tri CIMU v.2 modifiée utilisée au SAU d'Angers

Cardio-vasculaire		TRI	Ophtalmologie			
anomalie fréquence cardiaque	FC > 180/min	1	trouble ou perte de la vision		3 ou 2	
	141 < FC < 179/min		corps étranger		4* 3*	
	120 < FC < 140/min		2	brulure oculaire		4* 3*
	40 < FC < 50/min		3	inflammation œil		5 ou 4
	FC < 40/min		3	<b>Orl stomatologie</b>		
anomalie tension artérielle systolique (tension au deux bras)	PAS > 220 mm Hg et un symptôme associé	2	angine (suspicion)		5 ou 4	
	200 < PAS < 219 mm Hg et un symptôme associé		douleur dentaire		5 ou 4	
	PAS < 200 mm Hg		3	épistaxis active		4*
	75 < PAS < 90 mm Hg		5	épistaxis sans saignement actif		5 ou 4
	< 75 mm Hg		2	gingivorragie		5 ou 4
douleur thoracique	ECG anormal	2 ou 1	odynophagie		5 ou 4	
	ECG normal		3	perte de l'audition		3 ou 2
ischémie aigue de membre		3 ou 2	rhinite		5 ou 4	
			3	tuméfaction orl		5 ou 4
phlébite (suspicion)		3	vertige		5 ou 4	
			3	<b>Pneumologie</b>		
embolie (suspicion)		3	arrêt respiratoire		1	
			3	détresse respiratoire	FR > 40 min et/ou tirage/effort respiratoire encombrent / obstruction	1
malaise ou perte de connaissance		3	douleur latérothoracique		2	
			3	asthme (suspicion)	et DEP inférieure à 50% théorique et DEP ≥ 50% théorique	2
oedème membre(s) inférieur(s)		4 ou 3	dyspnée	et FR < 32/min et 32 < FR < 40/min	4 ou 3	
			4	et FR < 32/min et 32 < FR < 40/min	3	
palpitations		4	hémoptysie mineure (crachats crachats)		3	
			4	hémoptysie importante (caillots caillots)		2
<b>Dermatologie</b>			hypoxémie	85% < SPO2	1	
affection cutanée fébrile		4 ou 3		85% < SPO2 < 90%	2	
			4 ou 3		91% < SPO2 < 94%	3
érythème étendu		4 ou 3	pneumopathie (suspicion)		3	
			4 ou 3	toux +/- crachats		5 ou 4
affection vénérienne		5 ou 4	<b>Rhumatologie</b>			
			5	soiatalgie		4 ou 3
affection cutanée ou muqueuse limitée		5	névralgie		4 ou 3	
			4	arthrite (suspicion)		4 ou 3
prurit		4	gonflement articulaire		4 ou 3	
			4	cervicalgie		5 ou 4
<b>circonstance</b>			dorsalgie		5 ou 4	
problème technique	préciser : sonde cathéter, platre, etc	4	douleur (s) musculaire(s)		5 ou 4	
			4	douleur (s) articulaire(s)		5 ou 4
autres problèmes	renouvellement ordonnance	5	lombalgie		5 ou 4	
			4	pathologie podologique chronique		5
chute		*				
			5			
douleur intense	EVA > 8	5				
			5			
problème social		5				
			5			
<b>Endocrino métabolisme</b>						
glycémie anormale	glycémie >= 2,5 g/l et/ou 0 <= cétonémie < 0,5	4*				
	glycémie >= 2,5 g/l et cétonémie >= 1,5 mmol/l		2			
	glycémie >= 2,5 g/l et 1,5 mmol/l < cétonémie >=		3			
	glycémie < 0,5 g/l avec glasgow inférieur à 12		3*			
	glycémie < 0,5 g/l avec glasgow supérieur à 12		4*			
anomalie métabolique (voir senior)		3				
			3			
altération état général sans comorbidité (AEG)		5				
			5			
altération état général et comorbidité (AEG)		4 ou 3				
			4 ou 3			

## Annexe 2 : Présentation du système SATGT

### Interface 1 : Authentification

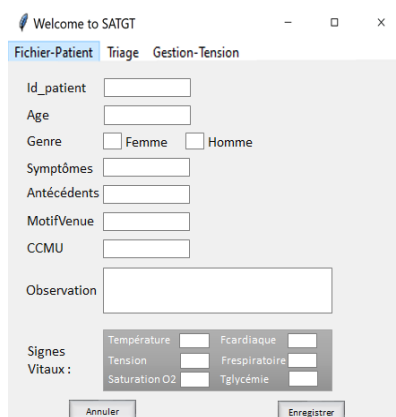


The screenshot shows a window titled "Welcome to SATGT" with three menu items: "Fichier-Patient", "Triage", and "Gestion-Tension". The "Triage" menu item is highlighted. The main area contains a login form with two input fields: "Login :" and "Password :". Below the fields are two buttons: "Annuler" and "Connecter".

Figure 1 : Interface d'authentification

Pour accéder à l'application SATGT, un personnel soignant doit s'authentifier avec son adresse mail et son mot de passe (Figure 1).

### Interface 2 : Fichier-patient



The screenshot shows the "Fichier-Patient" menu item highlighted. The form contains the following fields and options:

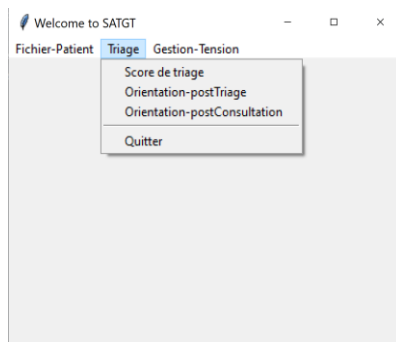
- Id\_patient:
- Age:
- Genre:  Femme  Homme
- Symptômes:
- Antécédents:
- MotifVenue:
- CCMU:
- Observation:
- Signes:  Température  Fcardiaque
- Vitaux:  Tension  Frespriatoire
- Saturation O2  Tglycémie

At the bottom are two buttons: "Annuler" and "Enregistrer".

Figure 2 : Interface du fichier patient

L'infirmière de triage doit remplir le fichier-patient pour chaque nouveau arrivé au SU (Figure 2).

### Interface 3 : Menu Triage



The screenshot shows the "Triage" menu item highlighted. A dropdown menu is open, listing the following options:

- Score de triage
- Orientation-postTriage
- Orientation-postConsultation
- Quitter

Figure 3: Menu de triage

Le personnel soignant (Infirmière de triage) doit ouvrir le menu Triage pour trier un patient convenablement et l'orienter vers le circuit adéquat après la création d'un fichier patient (Figure 3).

#### Interface 4 : Calculer le score de triage

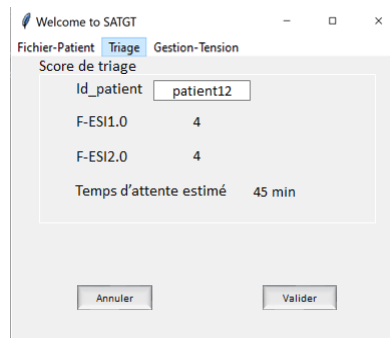


Figure 4 : Score de Triage

Pour calculer le score de triage, le soignant doit saisir « l'identifiant » du patient et cliquer sur « valider ». L'estimation du temps d'attente est totalement théorique et dépend du score trouvé (Figure 4).

#### Interface 5 : Orientation post Triage

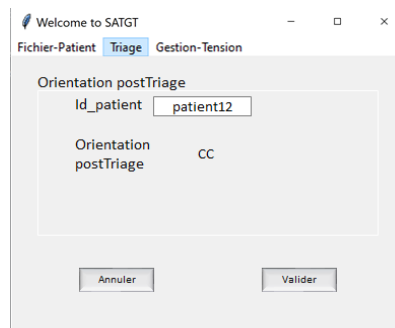


Figure 5 : Orientation post-Triage

Afin d'aider à orienter les patients vers le circuit adéquat, le soignant doit saisir « l'identifiant » de patient au moment de triage et cliquer sur « valider ».

#### Interface 6 : Orientation post-Urgence

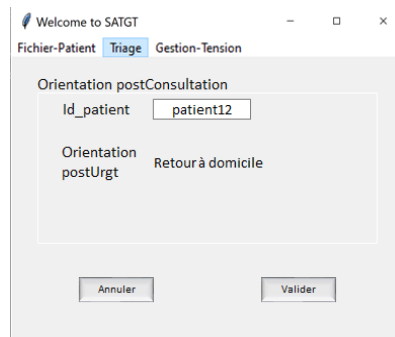


Figure 6 : Orientation post-Urgence



Afin d'aider à bien gérer la partie aval de l'urgence, le soignant peut visualiser une prédiction de l'orientation post-urgence (hospitalisation ou retour à domicile) en saisissant l'identifiant du patient au moment d'arrivée (Figure 6).

#### Interface 7 : Menu de gestion tension

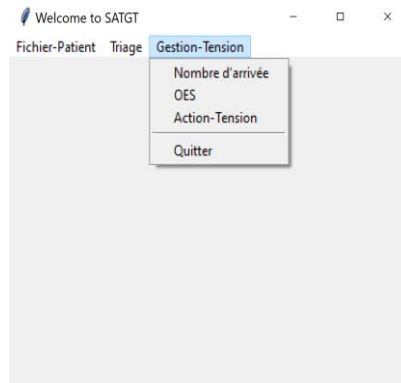
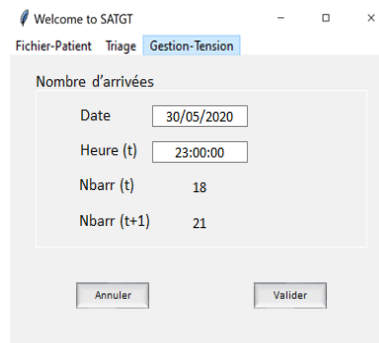


Figure 7 : Menu de gestion de tension

Pour aider les soignants à bien gérer les moments de tension, nous proposons un menu qui permet d'identifier trois fonctions (Figure 7):

- Nombre d'arrivées (t+1)
- OES : score d'estimation de tension
- Recommandation les actions de gestions convenables selon la situation

#### Interface 8 : Calculer le nombre d'arrivées

The image shows a software window titled 'Welcome to SATGT'. At the top, there are three menu items: 'Fichier-Patient', 'Triage', and 'Gestion-Tension'. The 'Gestion-Tension' menu is open, displaying a form titled 'Nombre d'arrivées'. The form contains the following fields and values:

Nombre d'arrivées	
Date	30/05/2020
Heure (t)	23:00:00
Nbarr (t)	18
Nbarr (t+1)	21

At the bottom of the form, there are two buttons: 'Annuler' and 'Valider'.

Figure 8 : Nombre d'arrivées à l'instant t et t+1

Le soignant doit saisir la date et l'heure actuelle puis le système calcule le nombre d'arrivées à l'instant t puis, il prédit les arrivées à t+1 (Figure 8).

#### Interface 9 : Score d'estimation de tension

Welcome to SATGT

Fichier-Patient Triage **Gestion-Tension**

OES

Date 30/05/2020

Heure (t) 23:00:00

OES Très Critique

Annuler Valider

*Figure 9 : Calcul d'OES*

Le soignant doit saisir la date et l'heure actuelle pour évaluer la situation de SU et selon cette évaluation, il peut trouver les actions recommandées pour gérer cette situation (Figure 9).

### Résumé

Ces dernières années, l'amélioration de qualité de soins est l'un des principaux défis auxquels sont confrontés de nombreux établissements hospitaliers, en particulier les services d'urgence (SU). L'augmentation de demandes d'admission aux urgences et le système de triage non précis peuvent conduire à des problèmes de tension. Cette thèse, qui est dans le cadre du projet ANR OIIHL, propose un Système d'Aide au Triage et de Gestion de Tension (SATGT) pour optimiser la prise en charge des patients. En effet, le premier objectif principal de ce système est de prédire la fréquentation des patients et la tension aux urgences. Le second est de recommander aux gestionnaires des urgences les mesures préventives et correctives nécessaires pour éviter les situations de tension. Le dernier objectif est d'aider les infirmiers de triage à orienter les patients vers les parcours adéquats. Les systèmes et les modèles existants, tels que les modèles de réseaux de neurones, sont principalement basés sur des données structurées et ne peuvent pas exploiter les données non structurées textuelles telles que les observations médicales, les symptômes et les antécédents médicaux, etc. Dans ce contexte, nous proposons une approche d'IA hybride qui combine les IA symboliques et les IA subsymboliques. Les IA symboliques sont définies par les ontologies et le raisonnement sémantiques basées sur les règles. Cette partie est proposée pour prétraiter les données non structurées textuelles, les transformer en des connaissances pertinentes et créer une base de règles permettant la recommandation des actions nécessaires pour anticiper et gérer les situations de tensions. Cette base de règles est basée sur les résultats issus des modèles d'apprentissage automatique proposés pour trier les patients, prédire l'admission et l'arrivée des patients. Cette partie présente les IA sub-symboliques qui sont basées principalement sur les réseaux de neurones, la théorie de Dempster pour gérer l'incertitude des données et les techniques d'apprentissage automatique. Les expériences ont été menées sur une base de données réelle collectée dans le service des urgences Adultes (SUA) du centre hospitalier régional de Lille, en France. L'IA hybride s'est avérée être une approche utile pour prédire et anticiper les tensions aux urgences.

**Mots clés :** apprentissage, ontologies médicales, intelligence des données, gestion de l'incertitude.

---

### Abstract

In recent years, improving the quality of care is one of the main challenges facing many hospitals, especially emergency departments (EDs). The increase of admission requests to the ED and the non-accurate triage system can lead to overcrowding problems. We propose in this thesis, which is in the framework of the ANR OIIHL project, a Triage Assistance and Overcrowding Management System (SATGT) to optimize patient pathway. Indeed, the objective of this system is to predict patient admission, to recommend to emergency managers the necessary preventive and corrective measures to avoid overcrowding situations and to help triage nurses to orient patients to the appropriate pathway. Existing systems and models, such as neural network models, are mainly based on structured data and cannot exploit textual unstructured data such as medical observations, symptoms and medical history, etc. In this context, we propose a hybrid approach that combines symbolic AI and subsymbolic AI. The symbolic AI are defined by ontologies and rule-based semantic reasoning. This part is proposed to preprocess unstructured textual data, transform them into relevant knowledge and create a rule base allowing the recommendation of actions needed to anticipate and manage overcrowding situations. This rule base takes into account the results of the proposed Machine Learning models for patients triage classification, predicting patient admission and forecasting arrival flow. This part presents the subsymbolic AI which are mainly based on neural networks, Dempster's theory to manage data uncertainty and machine learning techniques. The experiments were conducted on a real database collected from the Adult Emergency Department (AED) of the Regional Hospital of Lille, France. The hybrid AI proved to be a useful approach for predicting and anticipating emergency department overcrowding.

**Keywords:** learning, medical ontologies, data intelligence, uncertainty management

---