



HAL
open science

Optimisation collaborative par des agents auto-adaptatifs pour résoudre les problèmes d'ordonnancement des patients en inter-intra urgences hospitalières

Faiza Ajmi

► **To cite this version:**

Faiza Ajmi. Optimisation collaborative par des agents auto-adaptatifs pour résoudre les problèmes d'ordonnancement des patients en inter-intra urgences hospitalières. Automatique / Robotique. Centrale Lille Institut, 2021. Français. NNT : 2021CLIL0019 . tel-03774914

HAL Id: tel-03774914

<https://theses.hal.science/tel-03774914>

Submitted on 12 Sep 2022

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

THESE

Présentée en vue
d'obtenir le grade de

DOCTEUR

En

**Spécialité : Automatique, Génie Informatique,
Traitement du Signal et des Images**

Par

Faiza AJMI

DOCTORAT DELIVRE PAR CENTRALE LILLE

Titre de la thèse :

**Optimisation collaborative par des agents auto-adaptatifs pour résoudre les problèmes
d'ordonnancement des patients en inter-intra urgences hospitalières**

Soutenue le 28 septembre 2021 devant le jury d'examen :

Président et Examineur	Aziz MOUKRIM	Professeur, Université de Technologie de Compiègne
Rapporteur	Dominique QUADRI	Professeur, Université Paris-Saclay, France
Rapporteur	Lionel AMODEO	Professeur, Université de Technologie de Troyes
Examineur	Jean-Marie RENARD	MCF.PH, Université de Lille, France
Directeur de thèse	Slim HAMMADI	Professeur, Centrale Lille, France
Co-directrice de thèse	Hayfa ZGAYA-BIAU	Professeur, Université de Lille, France

Thèse préparée dans le Laboratoire CRIStAL

Ecole Doctorale SPI-MADIS

À ma famille.

Remerciements

Tout d'abord, je voudrais adresser mes plus sincères remerciements à Madame Dominique Quadri, Professeur à l'Université Paris-Saclay et Monsieur Lionel Amodeo, Professeur à l'Université de Technologie de Troyes de m'avoir fait l'honneur d'être rapporteurs de ma thèse. Je souhaite également remercier, Monsieur Aziz Moukrim, Professeur à l'Université de Technologie de Compiègne et Monsieur Jean-Marie Renard, Maître de conférences et Praticien hospitalier à l'Université de Lille d'avoir accepté d'être membres de mon jury de thèse.

J'adresse toute ma gratitude à Monsieur Slim Hammadi, Professeur à Centrale Lille et à Madame Hayfa Zgaya-Biau, Professeur à l'Université de Lille, directeur et co-directrice de cette thèse, de m'avoir conseillée, soutenue, encouragée tout au long de ces trois années de doctorat. Vous avez réussi à me pousser à rebondir dans les moments de doute et d'aller jusqu'au bout de cette aventure.

Je tiens à remercier vivement les membres du CHU de Lille, plus particulièrement Messieurs Jean-Marie Renard et Grégoire Smith de m'avoir accueillie et fourni des données et des informations précieuses qui m'ont aidé dans l'avancement de ma thèse.

Enfin, je remercie le personnel de l'administration de Centrale Lille et du laboratoire CRISAL pour leur disponibilité et serviabilité.

Table des matières

Remerciements	v
Table des matières	vii
Liste des tableaux	xiii
Table des figures	xv
Introduction générale	1
1 La gestion de la chaîne logistique des urgences : Amont-Intra-Aval	3
1.1 Introduction	3
1.2 Le réseau logistique hospitalier en France	3
1.2.1 La qualité des soins	4
1.2.1.1 La satisfaction des patients	5
1.2.1.2 La satisfaction des prestataires de soins	6
1.2.1.3 Les normes de qualité des soins	6
1.2.2 Le rôle de la logistique hospitalière dans l'amélioration des soins	7
1.2.3 Les dysfonctionnements des organisations hospitalières	9
1.3 La place de la logistique hospitalière pendant la COVID-19	10
1.4 La chaîne logistique des urgences	11
1.4.1 Qu'est-ce que la tension aux urgences?	13
1.4.2 Quelles sont les causes de tensions aux urgences?	15
1.4.2.1 Les causes en amont	15
1.4.2.2 Les causes en intra-urgences	16
1.4.2.3 Les causes en aval	16
1.4.3 Quelles sont les conséquences de la tension aux urgences?	17
1.4.4 Comment réduire le flux des patients aux urgences?	18

1.4.4.1	Les solutions proposées au sein des urgences (intra)	18
1.4.4.2	Les solutions proposées en amont et en aval des urgences	18
1.5	Problématique de la thèse	19
1.6	Conclusion	21
2	Outils et approches de modélisation, d'optimisation et d'apprentissage	23
2.1	Introduction	23
2.2	La modélisation informatique	23
2.2.1	La modélisation UML : Unified Modelling Language	24
2.2.2	La modélisation SysML : Systems Modeling Language	25
2.2.3	La modélisation Workflow BPMN	25
2.3	Les systèmes multi-agents (SMA)	27
2.3.1	La modélisation à base d'agents	27
2.3.2	Le concept d'agent	27
2.3.3	De l'agent vers les SMA	28
2.3.4	L'approche multi-agent dans le domaine de la santé	30
2.4	Le concept et les approches d'optimisation	31
2.4.1	Les problèmes d'optimisation	32
2.4.1.1	Les problèmes d'optimisation discrète	32
2.4.1.2	Les problèmes d'optimisation combinatoire (POC)	32
2.4.1.3	Les problèmes d'optimisation combinatoire multi-objectif	33
2.4.2	Les méthodes de résolution des problèmes d'optimisation	33
2.4.2.1	Les méthodes exactes	33
2.4.2.2	Les méthodes approchées	34
2.4.2.3	Les méthodes hybrides	38
2.4.3	L'optimisation dans le domaine de la santé	38
2.4.3.1	Les contraintes liées aux ressources humaines et matérielles	40
2.4.3.2	Les contraintes liées à la nature des SU	40
2.5	L'apprentissage automatique	41
2.5.1	L'apprentissage par renforcement	42
2.5.2	Les processus décisionnels de Markov (PDM)	43
2.5.3	PDM partiellement observable	43
2.6	Pourquoi l'IA dans le domaine de la santé?	45
2.6.1	L'automatisation en santé	45

2.6.2 La conciliation IA et le règlement général sur la protection des données (RGPD)	46
2.7 Positionnement	46
2.8 Conclusion	48
3 Prédiction et modélisation dans la chaîne des urgences	51
3.1 Introduction	51
3.2 La chaîne des urgences du CHU de Lille	51
3.3 Analyse des données statistiques	52
3.3.1 L’affluence des patients	53
3.3.2 La durée totale de séjour	54
3.3.3 Le temps d’attente primaire	56
3.3.4 Les examens complémentaires	56
3.3.5 Le moyen d’arriver et l’orientation des patients	56
3.4 L’étude de prédiction	59
3.4.1 Prédiction de l’affluence des patients	60
3.4.1.1 Le modèle FBProphet	60
3.4.1.2 Le modèle de réseau de neurones convolutifs	61
3.4.2 Prédiction du temps d’attente primaire	64
3.4.2.1 Le modèle FBProphet	64
3.4.2.2 Le modèle de réseau de neurones convolutifs	65
3.5 La modélisation du parcours patient	67
3.5.1 Choix de l’outil de modélisation	68
3.5.2 Modélisation du parcours patient dans le SUA	69
3.5.2.1 Le modèle global du parcours patient	69
3.5.2.2 Les sous-processus du parcours patient	73
3.6 La modélisation SysML du SAD proposé aux urgences	75
3.6.1 Le diagramme de contexte	76
3.6.2 Le diagramme de cas d’utilisation	76
3.6.3 Le diagramme de définition de bloc	77
3.6.4 Le diagramme des exigences	78
3.7 Conclusion	79
4 Approche hybride et auto-adaptative pour l’aide à l’ordonnancement	81
4.1 Introduction	81
4.2 Formulation mathématique du problème d’ordonnancement en intra-SUA	81

4.2.1	Les paramètres et variables de décision	82
4.2.2	Les contraintes	83
4.2.3	Le critère temps d'attente aux urgences	84
4.3	Modèle hypercubique de la solution d'ordonnancement	86
4.4	Approche métaheuristique hybride à base d'agents	87
4.4.1	Protocole de collaboration générique	89
4.4.1.1	Le raisonnement interne de l'agent-métaheuristique	89
4.4.1.2	La loi de décisions : LD	93
4.4.1.3	Le déroulement d'interaction collective : DIC	93
4.4.2	Instantiation du PCG : amis et ennemis	94
4.5	Auto-adaptation des agents par l'apprentissage	97
4.5.1	Formulation de l'espace d'états	97
4.5.2	Formulation des actions	98
4.5.3	Formulation de la récompense	99
4.5.4	Formulation de la fonction de transition	99
4.5.5	Formulation du facteur d'actualisation	99
4.5.6	L'algorithme Q-Learning en santé	102
4.6	Les problèmes de gestion des lits d'aval : une cause majeure de saturation	104
4.6.1	Contrôle de nombre de lits nécessaires dans un service : Algorithme CLS	104
4.6.2	Automatisation de l'information sur la disponibilité des lits : Algorithme AIDL	106
4.6.2.1	Méthode de calcul du premier point-temps	106
4.6.2.2	Méthode de calcul du deuxième point-temps	106
4.7	Architecture informatique du SAD proposé	109
4.8	Conclusion	109
5	Expérimentations et Résultats	111
5.1	Introduction	111
5.2	Expérimentations et résultats de l'approche hybride auto-adaptative proposée	111
5.3	Expérimentations et résultats des algorithmes de gestion de lits d'aval	115
5.4	Implémentation et simulation du SAD proposé	121
5.5	Conclusion	125
	Conclusion générale	129
	Bibliographie	133

Table des matières	xi
--------------------	----

Annexes	149
----------------	------------

A	151
----------	------------

B	153
----------	------------

Liste des tableaux

2.1	Résumé des références clés discutées	47
3.1	Comparaison des outils de modélisation (NAFIE 2016)	68
3.2	Description des branchements conditionnels du modèle global	72
3.3	Description des branchements conditionnels du CC	73
3.4	Description des branchements conditionnels du CL	74
3.5	Description des branchements conditionnels de la zone A du CL	74
4.1	Description des symboles du formalisme utilisés (AJMI et al. 2020)	91
5.1	Exemple de 10 patients à ordonnancer	112
5.2	Comparaison du temps d'attente moyen global (min) avec et sans le protocole de collaboration	113
5.3	Comparaison du temps d'attente moyen global (min) en utilisant le protocole de collaboration avec et sans apprentissage par rapport au fonctionnement actuel	114
5.4	Valeurs optimales de l'algorithme CLS (10)	117
5.5	Exemple de résultats d'affectation des lits en situation normale	118
5.6	Exemple de résultats d'affectation des lits en situation de tension	120
5.7	Temps d'attente moyen pour l'obtention d'un lit d'aval avec et sans notre approche	122

Table des figures

1.1	Scores nationaux de satisfaction et d'expérience par étape du parcours de soins .	5
1.2	L'activité en hospitalisation complète versus partielle	10
1.3	La chaîne des urgences	13
2.1	Les différents diagrammes SysML (ROQUES 2011)	26
2.2	Relation Workflow-BPMN	26
2.3	Représentation graphique des interactions agent-environnement	28
2.4	Classement des méthodes de résolution, (HAO, GALINIER et HABIB 1999)	34
2.5	Les méthodes de résolution	39
2.6	L'interaction agent-environnement dans un PDM	44
2.7	L'interaction agent-environnement dans un PDMPO	44
3.1	La structure de la chaîne des urgences (SUA du CHU de Lille)	53
3.2	Extrait de la base de données 2016-2020 du SUA	53
3.3	Résultat de l'étude de l'affluence des patients	54
3.4	L'affluence des patients en fonction de l'année	54
3.5	La durée de séjours aux urgences	55
3.6	La durée de séjours en fonction de CCMU	55
3.7	Le temps d'attente primaire	56
3.8	Le nombre de patients ayant recours à des examens complémentaires	57
3.9	La répartitions des examens complémentaires	57
3.10	Le moyen d'arrivée des patients (2016-2020)	58
3.11	Le niveau CCMU moyen en fonction du mode d'arrivée (2016-2020)	58
3.12	L'orientation des patients dans le SUA (2016-2020)	58
3.13	Le nombre de patients qui se rendent au SUA par jour	61
3.14	La prédiction de l'affluence des patients avec le modèle FBProphet	61

3.15	La prédiction de l’affluence des patients avec le modèle FBProphet	62
3.16	L’encadrement de l’affluence des patients avec le modèle FBProphet	62
3.17	L’affluence des patients au SUA juin 2016 - juin 2020	64
3.18	La prédiction de l’affluence des patients avec le modèle CNN	64
3.19	Le temps d’attente primaire moyen par jour	65
3.20	La prédiction du temps d’attente avec le modèle FBProphet	66
3.21	L’encadrement de la prédiction du temps d’attente avec le modèle FBProphet . .	66
3.22	La prédiction du temps d’attente avec le modèle CNN	67
3.23	Le parcours global du patient dans la chaîne des urgences SUA	71
3.24	Le circuit court « CC » du SUA	72
3.25	Le circuit long « CL » du SUA	72
3.26	Le circuit long du SUA : zone A	73
3.27	Diagramme de contexte du SAD chaîne des urgences	76
3.28	Diagramme de cas d’utilisation du SAD chaîne des urgences	77
3.29	Diagramme de définition de bloc du SAD pour l’optimisation de la chaîne des urgences	78
3.30	Exemple de traçabilité SysML	80
3.31	Diagramme d’exigences du SAD chaîne des urgences	80
4.1	La discrétisation du temps d’attente aux urgences	86
4.2	Modèle hypercube à quatre dimensions	87
4.3	Représentation d’un horizon d’optimisation	87
4.4	Exemple de croisement	88
4.5	La dynamique interne de l’agent	92
4.6	Le DIC proposé	94
4.7	Les modes d’interaction entre les agents	96
4.8	Exemple de solution d’ordonnancement pour quatre patients	99
4.9	Exemple d’insertion multiple dans différents corps médicaux (cf. algorithme 7) .	100
4.10	Exemple d’insertion multiple dans le même personnel soignant (cf. algorithme 7)	101
4.11	Exemple de permutation entre différents personnels soignants (cf. algorithme 7)	101
4.12	Exemple d’échange des tâches dans le planning d’un personnel soignant (cf. algorithme 7)	101
4.13	Le graphe d’états complet et la table Q	101
4.14	Les formats de trames essentiels	107
4.15	L’architecture informatique du SAD	110

5.1	Exemple de solution initiale d'ordonnement	112
5.2	Comparaison des résultats du temps d'attente moyen global (min) dans les deux modes de collaboration	113
5.3	Temps d'attente moyen global (min) de la meilleure solution trouvée avec l'apprentissage par renforcement en fonction du facteur d'actualisation et du taux d'apprentissage	114
5.4	Temps de calcul avec collaboration maximale (3 agents) pour les diverses instances	115
5.5	Exemple d'ordonnement avec l'approche hybride auto-adaptative, mode amis	116
5.6	Comparaison du temps d'exécution en utilisant différents types de sélection . .	116
5.7	Comparaison de la qualité de solution en utilisant différents types de sélection .	116
5.8	Le nombre de transferts internes par an	117
5.9	Beacon Bluetooth Low Energy	118
5.10	Interface patient de l'application Android	119
5.11	Connexion Beacons, patient et tableau de bord	119
5.12	Le tableau de bord dynamique	120
5.13	Affectation des patients aux services d'aval	120
5.14	Comparaison du TAB moyen avec et sans notre approche en situation normale (SN) Service Gériatrie	121
5.15	Comparaison du TAB moyen avec et sans notre approche en situation normale (SN) Service Pneumologie	122
5.16	Comparaison du TAB moyen avec et sans notre approche en situation de tension (ST) Service Gériatrie	123
5.17	Comparaison du TAB moyen avec et sans notre approche en situation de tension (ST) Service Pneumologie	123
5.18	Tableau de Bord sur le nombre des patients en heure, jour et mois	125
5.19	Tableau de Bord sur la proportion de patients par pathologie	125
5.20	Tableau de Bord sur la durée d'attente des patients	126
5.21	Tableau de Bord sur les examens complémentaires	126
5.22	Tableau de Bord : exemple de planning d'opérations (Zone A)	126
5.23	Tableau de Bord : temps d'attente des patients	127
5.24	Vue en temps réel sur le nombre des lits disponibles	127
5.25	Architecture d'exploitation du SAD	127

Introduction générale

L'amélioration des processus des services des urgences implique la nécessité de prendre en considération de multiples variables et objectifs dans un environnement hautement dynamique et imprévisible, ce qui rend la prise de décision extrêmement difficile. L'utilisation de différentes méthodologies et outils pour soutenir le processus décisionnel est donc une question essentielle. Or, les professionnels de santé ne sont ni préparés, ni formés pour résoudre de tels problèmes décisionnels. Il apparaît qu'ils sont démunis en méthodologies et outils d'aide à la décision et de pilotage adaptés aux exigences qu'impliquent leurs modes de fonctionnement futur.

La gestion des systèmes des urgences hospitalières implique en général trois questions : leur conception, leur planification et leur contrôle. La conception est la définition/la prédiction des caractéristiques futures du système hospitalier. Dans cette phase, nous abordons les questions relatives à la conception du système, aux ressources humaines et matérielles utilisées, ou à l'ordre dans lequel les patients sont traités. La planification concerne la détermination des différentes ressources utilisées pour réaliser les opérations de soins aux patients et la définition de la manière et du moment où ces opérations doivent être effectuées. Enfin, le contrôle vise à corriger les perturbations inhérentes. Ces perturbations peuvent être : une aggravation de l'état de santé d'un patient, de nouveaux patients à traiter (donc de nouvelles tâches de soins à réaliser) ou plus généralement, tout événement aléatoire qui nuit à la réalisation du plan de traitement des soins déterminé par l'ordonnancement. Ces trois étapes clés sont exécutées en fonction de la fréquence des problèmes rencontrés lors de l'exécution de l'ordonnancement. L'originalité de cette thèse est de concevoir et développer un système d'aide à l'ordonnancement des tâches de soins à compétences multiples. Les solutions d'ordonnancement sont représentées d'une manière unifiée sur quatre dimensions dans un même schéma. L'idée est d'identifier tous les éléments essentiels afin de prendre en compte toutes les variables et les paramètres de décision pour l'optimisation locale, puis globale du parcours patient. De nombreux travaux sont apparus dans la littérature pour l'optimisation de l'ordonnancement des patients. La plupart d'entre eux n'ont pas utilisé une stratégie qui lie les mesures des performances aux actions qui résultent du processus décisionnel pour piloter les activités de soins en temps réel. Cette thèse étudie et développe une architecture originale à trois niveaux alliant l'optimisation, les systèmes multi-agents et l'apprentissage comme approche appropriée pour assurer l'optimisation collaborative qui génère de bonnes actions à adopter pour améliorer la performance du système. Ces actions sont mises à jour par la communication, la coordination et la négociation entre les différents acteurs de soins du terrain afin d'améliorer en temps réel les indicateurs de performance. Le critère de performance principal à optimiser dans l'ordonnancement des tâches de soins est le temps d'attente des patients en inter et intra urgences. Ce deux types de temps d'attente s'impactent mutuellement vu que l'une des causes principales à la dégradation du critères temps d'attente des patients en intra-urgences est l'attente des lits d'aval. En effet, cette thèse propose une approche d'ordonnancement des patients aux urgences avec prise en compte des contraintes

d'aval minimisant le temps d'attente global moyen en inter et intra urgences.

Ce manuscrit est organisé comme suit :

- Chapitre 1 est dédié à l'étude du réseau logistique hospitalier et en particulier la chaîne des urgences. Dans ce chapitre, nous détaillons les différentes causes et solutions proposées de tension en amont, intra et aval des urgences. Ensuite, nous spécifions la problématique et le terrain d'expérimentation de cette thèse.
- Chapitre 2 présente un état de l'art sur les outils et approches de modélisation, d'optimisation et d'apprentissage dans la chaîne logistique hospitalière, ciblant ainsi la chaîne des urgences. Dans la dernière partie de ce chapitre, nous proposons notre positionnement thématique.
- Chapitre 3 présente dans un premier lieu une étude statistique suivie d'une étude de prédiction en utilisant les deux modèles FBProphet et CNN qui ont permis de transcrire la réalité de notre terrain d'expérimentation (SUA) à l'aide de ses données historiques. En deuxième lieu, une modélisation workflow du parcours patient est présentée afin d'identifier les points clés de décision. Le fonctionnement, les exigences et les contraintes de la prise de décision, nécessaires pour l'exécution du workflow, sont modélisés par le langage SysML à la fin de ce chapitre.
- Chapitre 4 présente une approche d'optimisation hybride et auto-adaptative pour l'aide à l'ordonnancement des patients aux urgences en minimisant le critère temps d'attente global moyen. Afin de garantir une meilleure continuité de prise en charge, le critère temps d'attente des patients est encore optimisé dans un contexte d'attribution des lits d'aval aux patients.
- Chapitre 5 est consacré aux résultats de différentes expérimentations effectuées tout au long de ce manuscrit. Nous commençons par présenter l'intérêt de l'approche hybride auto-adaptative basée sur un algorithme Q-Learning. Ensuite, nous simulons l'approche d'automatisation de l'information sur la disponibilité des lits d'aval grâce à un algorithme génétique et à la technologie des Beacons. Puis, nous présentons le logiciel utilisé pour présenter notre SAD.

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

La gestion de la chaîne logistique des urgences : Amont-Intra-Aval

1.1 Introduction

Le système de santé est à l'heure actuelle en constante évolution, il a connu ces dernières années de nombreux changements : vieillissement de la population, manque de personnel soignant, intégration de technologies de plus en plus sophistiquées. Il est donc essentiel d'évaluer de manière régulière la performance de la logistique hospitalière afin de pouvoir l'adapter à la nature de son environnement qui est à la fois complexe et mouvante. Dans ce contexte, les pics d'activité et les engorgements des services des urgences sont des sources de tension qui sont difficiles, voire impossibles à gérer. Ces pics sont liés aux flux des patients et aux processus de soins. La mise en œuvre des soins de qualité aux urgences implique une meilleure gestion de l'ensemble des ressources et de l'infrastructure ainsi qu'une optimisation de la logistique hospitalière. Cette dernière est constituée d'un maillage d'éléments en interaction. L'amélioration de l'efficacité du parcours patient nécessite l'optimisation de la logistique intra services (urgences) et inter services qu'ils soient ou non au sein de la même structure hospitalière.

Dans ce chapitre, nous présentons le réseau logistique hospitalier en France. Ainsi nous faisons un focus sur les causes de la tension dans les hôpitaux et notamment dans la chaîne des urgences (*amont, intra et aval*). Les systèmes hospitaliers actuels et en particulier les chaînes des urgences font de plus en plus face à des situations critiques qui engendrent des saturations. La question qui se pose aujourd'hui est : existe-il un moyen efficace qui permet d'anticiper ces situations de crises ?

1.2 Le réseau logistique hospitalier en France

Comme dans de nombreux pays de l'Europe, la logistique hospitalière en France est en pleine transformation. La fonction logistique d'un établissement de santé a une conséquence directe sur la qualité des soins et la maîtrise des coûts. Néanmoins, pour avoir les meilleurs soins possibles

à coûts contrôlés, une gestion efficace de tout le réseau de soins est primordiale. Ce réseau logistique hospitalier est considéré comme la forme la plus générale d'une chaîne logistique hospitalière. Il intègre des connexions arbitraires entre les nœuds, les liens entre ces nœuds ne sont pas forcément hiérarchiques (ZGAYA et HAMMADI 2016). Dans ce cadre, le déploiement d'un système de mesure de la performance des différents éléments en interaction qui compose le réseau de soins s'impose au cœur de la démarche nécessaire pour améliorer les bénéfices d'une logistique hospitalière performante.

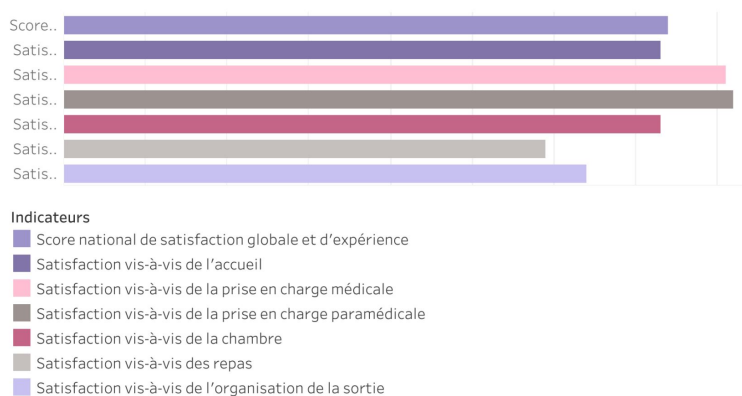
La logistique représente une part non négligeable des fonds d'exploitation d'un centre hospitalier. Ce qui la positionne comme une fonction clé dans ce secteur, entre 30% et 40% des dépenses hospitalières sont investies dans diverses activités logistiques (SAMPIERI-TEISSIER 2016). Les connaissances logistiques, à la fois techniques et managériales permettent de réduire les dysfonctionnements, les coûts, la destruction de médicaments périmés, les erreurs médicamenteuses, les temps d'attente des patients, les déplacements inutiles des personnels et des patients, etc. **Cependant la logistique n'est pas seulement une fonction d'optimisation, elle peut apporter également de la valeur au personnel soignant et aux patients**, en améliorant : la prise en charge des patients, la diffusion et la fiabilité des informations (e.g. heures de prise en charge, visualisation des lits d'aval) et l'anticipation ainsi que l'organisation des flux de patients.

Selon (APTEL 2000), l'hôpital est un endroit où s'exercent deux types de flux : des flux physiques (flux de personnes, flux de matières) et des flux d'informations. En tant que prestataire de service, l'hôpital héberge également deux types de logistiques : une logistique classique et une logistique de service. La première permet la gestion des flux de matières premières responsables à la production du service. La deuxième gère le flux des patients en fonction de la demande et de la capacité d'accueil.

Trois niveaux d'intervention sont à distinguer dans la logistique hospitalière : la conception, la planification et le transport (FRICHI et al. 2018). Dans le premier niveau, la logistique hospitalière intervient pour le dimensionnement des ressources essentielles (par exemple les plateaux techniques, les imageries) et pour l'implantation d'innovations dans le domaine de la santé. Dans le second niveau, elle contribue à la planification et l'ordonnancement des ressources (humaines et matérielles) et des activités de soins et permet ainsi la réorganisation si besoin et en fonction des aléas. Le troisième niveau inclut le transport interne (patients, manutention, etc.) et le transport externe (ambulance, véhicule sanitaire, etc.). Une logistique hospitalière performante, efficace et opérationnelle doit donc mettre à disposition des patients les soins médicaux nécessaires, tout en respectant les réglementations qui garantissent la qualité et la sécurité des soins (FRANÇOIS et al. 2013), (BONED, GUERRY et PIERRON 2018). Pour améliorer « la qualité des soins », il est primordial de bien définir les variables et les paramètres qui influencent la satisfaction des patients, ceux qui affectent la satisfaction des personnels de la santé et ainsi que ceux qui interviennent dans les normes de qualité des soins.

1.2.1 La qualité des soins

L'Organisation Mondiale de la Santé (OMS) définit la qualité des soins comme étant la mesure dans laquelle les soins de santé et les services fournis aux patients améliorent les résultats souhaités en matière de santé. C'est aussi, pour chaque patient, le droit à une prise en charge de qualité assurée par des professionnels sensibilisés à la prévention des événements indésirables (ORGANIZATION 2017). Afin d'atteindre cet objectif, les soins de santé doivent être associés à de nombreuses dimensions, notamment : la sûreté, l'efficacité, la précision, l'accessibilité, l'équité et l'orientation vers le patient. Pour évaluer et déterminer la qualité des soins, il est nécessaire de



Source : Haute Autorité de Santé

FIGURE 1.1 – Scores nationaux de satisfaction et d'expérience par étape du parcours de soins

quantifier l'écart entre la réalité et les attentes en se basant sur certaines normes et lignes directrices (AKACHI et KRUK 2017). Cette évaluation met en évidence les maillons faibles sur lesquels les efforts d'amélioration doivent être appliqués. Par exemple, les auteurs dans (FORMARIER et Jovic 2012) présentent deux approches pour évaluer la qualité des soins : la première approche est basée sur la qualité réelle (respect des normes), c'est-à-dire celle qui évalue les aspects techniques des soins. Cette approche prend en considération les données scientifiques, les protocoles et les recommandations du processus de soins. La seconde approche est basée sur la qualité ressentie par le patient ainsi que sa famille (satisfaction du patient). Cette approche est associée à la fois à la qualité de service et à la qualité relationnelle avec le personnel de santé qui a réalisé les soins.

1.2.1.1 La satisfaction des patients

En France, récolter l'avis des patients est une obligation réglementaire pour tout établissement de santé. Depuis 2015, la Haute Autorité de Santé (HAS) pilote le dispositif national de mesure de la satisfaction et de l'expérience des patients hospitalisés. La satisfaction des patients est présentée comme étant la différence entre les attentes du patient et ce qu'il a réellement reçu pendant son processus de soins. Depuis avril 2016, chaque patient hospitalisé dans une clinique ou un hôpital public a le droit de donner son avis sur son hospitalisation. Il reçoit un courrier électronique qui contient un questionnaire de satisfaction en ligne, sécurisé et anonyme accessible pendant 69 jours. Le questionnaire inclut 63 questions de mesure de la satisfaction et de l'expérience examinant les différentes étapes du parcours patient (accueil du patient, prise en charge par les médecins/chirurgiens, par les infirmier(ère)s/aide-soignant(e)s, chambre, repas et sortie).

La HAS attribue un score de satisfaction et d'expérience qui est exprimé sur 100. Ce score est calculé à partir des réponses des patients aux questionnaires. La figure 1.1 présente les résultats des scores nationaux de satisfaction et d'expérience par étape du parcours de soins, ceci présente un calcul des moyennes nationales. Ces résultats ont été obtenus à travers 332840 questionnaires complets entre novembre 2019 et septembre 2020. La figure 1.1 indique que le score national de satisfaction globale et d'expérience est de 74/100. Les scores respectifs des six indicateurs du parcours de soins sont : 73/100, 81/100, 82/100, 73/100, 59/100 et 64/100. Dans

ce contexte, les établissements de santé cherchent à identifier les facteurs clés de la satisfaction des patients. Plusieurs études scientifiques ont été réalisées pour déterminer ces facteurs (WATERS et al. 2016), (GAUJAL et al. 2016), (BOUAIÏ et al. 2016). Parmi ces facteurs, nous pouvons citer le temps d'attente, le temps de consultation, la procédure administrative, les coûts des soins, les visites, l'aspect interpersonnel (relation, information, confiance, etc.), les conditions logistiques (hébergement, propreté, hygiène, etc.).

Les points de vue et les observations des patients sont cruciaux pour déterminer les sources de mécontentement et ainsi les points à améliorer. Cependant la satisfaction des patients reste subjective et ne permet pas d'apporter une évaluation complète qui prend en compte toutes les dimensions de la qualité des soins. En effet, les patients critiquent les aspects qu'ils peuvent percevoir, comme l'organisation, le confort, etc. Par contre, ils ne peuvent souvent pas critiquer les aspects techniques vu leur manque de compétences. Dans ce cadre, la qualité de soins exige au-delà de la satisfaction des patients, la perception et le ressenti des professionnels de la santé qui représentent également des éléments-clés dans la qualité de soins.

1.2.1.2 La satisfaction des prestataires de soins

La satisfaction des prestataires de soins joue un rôle important dans la performance de la chaîne logistique hospitalière. Un meilleur déploiement de la main-d'œuvre et une meilleure satisfaction au travail sont importants pour fournir de meilleurs soins aux patients. L'environnement du travail de l'hôpital est un environnement complexe et incertain, le personnel soignant représente la ressource capitale pour faire face à la nécessité d'adaptation aux innovations technologiques et médicales permanentes. En effet, la motivation du personnel médical est primordiale pour l'amélioration de la performance de ces établissements. L'OMS accorde une attention particulière aux ressources humaines de la santé car la démotivation de ces dernières présente un frein à l'aboutissement de la performance hospitalière souhaitée. Le premier facteur de motivation des professionnels de la santé est la reconnaissance. L'implication du personnel soignant dans le processus de décision et dans l'organisation de la chaîne logistique hospitalière constitue une deuxième source de motivation. Parmi les facteurs qui peuvent influencer la satisfaction des professionnels de santé, nous pouvons citer : la charge et l'environnement de travail, la disponibilité du matériel, la charge administrative, l'organisation et la coordination du travail, le salaire et l'aspect relationnel.

1.2.1.3 Les normes de qualité des soins

Définir, évaluer et juger la qualité des soins est une démarche fondamentale pour améliorer la chaîne logistique hospitalière. Selon l'OMS, la qualité des soins doit répondre à des normes spécifiques. Ces normes, si elles sont respectées dans un établissement de soins pourraient conduire aux résultats espérés et ainsi garantir la qualité de soins (MOREL 2012). La mise en œuvre de ces normes est effectuée en fonction des types de soins (ambulatoires, hospitalisation, service des urgences, soins dispensaires, soins préventifs, etc.), des types de patients (adultes, enfants, etc.), et des types de milieux de soins (laboratoire, service hospitalier, urgences, services de transfusion sanguine, etc.). Également, ces normes contiennent plusieurs aspects comme les aspects techniques, organisationnels et logistiques. Citons ainsi quelques normes :

- un système d'informations exploitables : chaque établissement de santé possède un dispositif de collecte, d'analyse et de retour d'information pour assurer ses activités, et donc garantir une action précoce et appropriée pour améliorer les soins de chaque patient (ORGANIZATION 2020);
- des ressources matérielles : chaque établissement de santé doit disposer d'équipements, de médicaments, de stocks et des technologies nécessaires pour réaliser une prestation de service efficiente (ORGANIZATION 2015);
- des ressources humaines pluridisciplinaires : chaque établissement de soins doit avoir des personnels compétents, empathiques et multidisciplinaires disponibles pour fournir des soins, manager des complications et assurer un soutien psychologique tout au long du parcours des soins (ORGANIZATION 2020);
- une conception de l'établissement : le bâtiment doit être en bon état et accessible aux personnes à mobilité réduite. L'éclairage, le chauffage et la ventilation du bâtiment doivent être surveillés de manière régulière. De même, l'environnement de l'établissement de santé doit être accueillant et propre (ORGANIZATION 2012);
- une gestion des déchets et des équipements sanitaires : les déchets liés aux soins de santé doivent être triés, séparés, transportés, traités et éliminés avec des mesures de sécurité précises. De même, l'établissement de santé doit disposer d'un environnement physique approprié avec approvisionnement en eau et des installations sanitaires (CHARTIER, ADAMS et BARTRAM 2008);
- une communication efficace avec le patient et sa famille : répondre à leurs besoins et préférences (ORGANIZATION 2020).

La qualité et la sécurité des soins est une exigence pour tous les personnels de soins et pour tous les patients. Plusieurs facteurs peuvent aider à la satisfaction des patients et des prestataires de soins comme ceux identifiés dans les paragraphes 1.2.1.1 et 1.2.1.2. Il est également crucial d'identifier les facteurs susceptibles d'être systématiquement améliorés dans les établissements de santé et qui ont une immense implication pour la qualité des soins. Afin de fournir une haute qualité, les établissements de santé doivent adopter différentes approches, notamment l'optimisation de leur logistique, qui a été jugée, par plusieurs auteurs, comme l'un des moyens efficaces pour améliorer la qualité des soins (COSTIN 2010),(KRIEGEL et al. 2013).

1.2.2 Le rôle de la logistique hospitalière dans l'amélioration des soins

Les acteurs de la santé s'intéressent de plus en plus à la logistique hospitalière car elle leur permet de déployer efficacement les ressources matérielles nécessaires au fonctionnement de l'ensemble de la chaîne logistique hospitalière. La fonction logistique a un rôle principal dans le processus de soins car elle entraîne une valeur ajoutée (COSTIN 2010). Le système hospitalier est qualifié comme un véritable système de production de soins dont la mission principale est de prodiguer le meilleur soin au patient. Il présente des problèmes logistiques très complexes :

- la forte incertitude de son déroulement, variabilité du processus de prise en charge dû à l'état du malade, à l'environnement et aux modes d'organisation du travail ;
- le système est directement lié au caractère humain qui n'est pas forcément maîtrisable et dont les réactions ne peuvent pas être anticipées ;
- la multiplicité des missions, de la hiérarchisation, du cloisonnement, de la diversité des métiers et de l'hétérogénéité des équipes et des installations.

Cette complexité est réduite si la fonction logistique considérée prend en compte d'une manière efficace l'articulation de l'intra avec l'amont et l'aval. Si cette articulation est bien réalisée, elle garantit une durée de séjour à la fois efficace et la plus courte possible. Par exemple, les admissions programmées ne devraient pas être réalisées que si l'aval (date de sortie) est prévu. Pour améliorer la qualité de soins et atteindre un haut niveau de service, autant pour le patient que pour le professionnel de santé, une gestion complète et efficace de la logistique hospitalière devient nécessaire. En effet, du côté patient, la qualité de prise en charge est notamment mesurée par la rapidité du service et le respect des délais. Du côté des professionnels de la santé, la qualité de service est reliée par exemple à la répartition impartiale de charge du travail entre les différents membres. La fonction logistique représente aujourd'hui l'un des outils les plus pertinents pour aider les hôpitaux à améliorer la qualité de la prise en charge de patients. Elle permet d'optimiser plusieurs critères :

- réduire le temps d'attente : le manque de synchronisation entre les ressources et les besoins représente l'une des principales raisons d'un temps d'attente long. Cette attente est la conséquence directe de l'inadaptation entre la disponibilité des ressources (personnel soignant, médicaments, équipements, lits, etc.) et les besoins en soins. Ceci est dû à un déficit d'activités logistiques qui pourrait être au niveau de la planification, la coordination, ou la communication (MELO 2012). En effet, une meilleure gestion de la planification des rendez-vous peut permettre la réduction du temps d'attente dans les hôpitaux. Ainsi, une gestion complète de la chaîne logistique hospitalière peut contribuer à atténuer l'inadaptation entre l'offre et le besoin ;
- améliorer la disponibilité des professionnels de la santé : plusieurs recherches prouvent que le personnel soignant accorde entre 10% et 30% de son temps à des tâches logistiques (BEAUDRY et al. 2010), (VOLLAND et al. 2017). Ceci peut être amélioré avec l'application de certaines mesures visant à réduire le temps que le personnel soignant consacre pour des activités autres que les activités de soins, comme passer des commandes de réapprovisionnement ou trouver un lit disponible pour un patient dans un service d'aval. Ces activités logistiques peuvent être automatisées à l'aide des nouvelles technologies et ainsi apporter une aide en libérant les professionnels de la santé de certaines tâches administratives et logistiques, et leur permettre d'accorder plus de temps aux patients ;
- optimiser le système d'information : le système d'information est le centre de la chaîne logistique. Il permet l'échange d'informations et la coordination entre les différentes parties du système. Sa mise en place permet de réduire la probabilité d'une duplication d'un examen complémentaire par exemple. L'introduction du dossier médical électronique simplifie les procédures administratives et améliore la gestion des flux d'information (ZEMOUR, BELGHITRI et MIDOUN 2018).
Un système d'information permet à l'hôpital de perfectionner le système d'enregistrement, le suivi des données patients et par la suite l'amélioration de la qualité. L'amélioration de

la gestion administrative permet la réduction du temps d'attente (le temps pour organiser les dossiers, pour chercher une information, etc.). Entre autres, l'amélioration d'une partie de la chaîne logistique influence forcément les autres parties de la chaîne ;

- améliorer l'accès physique aux soins de santé : les activités logistiques telles que le transport des patients, leur manutention, l'entretien et la conception des bâtiments, sont reconnues comme l'un des principaux points à améliorer dans un système de santé. Par exemple, les auteurs dans (BEAUDRY et al. 2010) révèlent que le transport des patients est mal géré dans plusieurs hôpitaux, ce qui cause des complications pour les patients, des perturbations et des coûts supplémentaires. L'arrivée retardé d'un patient à un service de soins perturbe également les planifications initialement prévues du service, ce qui retarde les rendez-vous suivants et augmente le temps d'attente. L'amélioration du transport extra hospitalier et intra hospitalier réduit donc les temps d'attente et améliore les résultats en matière de santé (SYED, GERBER et SHARP 2013).

1.2.3 Les dysfonctionnements des organisations hospitalières

En France, le secteur de la santé est en pleine expansion, quoiqu'il soit confronté de plus en plus à de nouvelles réglementations, parmi lesquelles la maîtrise de ses dépenses. Les hôpitaux sont contraints à mener une réflexion entière sur leur fonctionnement et leur organisation de manière à ce qu'ils améliorent la qualité de soins tout en réduisant les coûts. L'agence technique de l'information sur l'hospitalisation (ATIH) publie un rapport en 2012 dans lequel elle analyse les coûts des prises en charge à l'hôpital et en clinique. L'ATIH a audité 36 établissements publics, 10 établissements à but non lucratif et 24 cliniques. L'étude illustre une disparité importante entre le secteur public (et privé non lucratif) et le secteur privé. En fonction de l'activité de soins et du mode de prise en charge (ambulatoire ou pas), chaque montant correspond aux ressources mobilisées par l'établissement et non au coût pour l'assurance-maladie. Selon l'ATIH, le coût moyen d'une prise en charge à l'hôpital est estimé à 2115 euros. Ce coût varie de 575 euros pour une séance de chimiothérapie ou de dialyse à 4564 euros pour un séjour de chirurgie. En chirurgie, le coût d'une prise en charge ambulatoire est de 1315 euros tandis que le coût pour une hospitalisation d'un patient en situation compliquée est de 16650 euros. Ainsi, le coût moyen de la prise en charge dans une clinique est quasiment deux fois inférieur à celui des établissements publics (1204 euros). Dans une clinique, le coût de l'acte chirurgical est de 1910 euros, qui est à peu près deux fois et demie inférieur à celui de secteur public (900 euros pour une chirurgie ambulatoire et 8000 euros pour une hospitalisation lourde). Dans ce contexte, les responsables de la gestion des hôpitaux se sont occupés de l'aspect logistique qu'il faut prendre en compte pour pouvoir trouver une solution qui permet à la fois d'améliorer la qualité des soins et de réduire les coûts. Le moyen qui permet d'unir la qualité et la performance économique est d'innover dans la gestion de la chaîne logistique dans les hôpitaux.

Selon la direction de la recherche, des études, de l'évaluation et des statistiques en 2018 (BERGONZONI et al. 2020), le secteur hospitalier en France compte 3042 établissements de santé (1360 établissements publics, 1000 établissements privés et 682 établissements privés à but non lucratif) assurent la prise en charge des patients. Le vieillissement de la population et l'augmentation du nombre des personnes atteintes de maladies chroniques font partie des causes principales à l'accroissement du nombre de prises en charge hospitalière. Il existe en France quatre types d'établissements dans le secteur public :




FIGURE 1.2 – L'activité en hospitalisation complète versus partielle

- les centres hospitaliers régionaux (CHR) qui sont au nombre de 178 ;
- les centres hospitaliers (CH, y compris les ex-hôpitaux locaux) qui sont au nombre de 947 ;
- les centres hospitaliers spécialisés en psychiatrie (CHS) qui sont au nombre de 95 ;
- 140 autres établissements publics, qui correspondent à des unités de soins de longue durée (USLD).

Entre 2013 et 2018, le nombre des établissements de soins a diminué de 2,7% (3042 en 2018 contre 3125 en 2013). Cette diminution est plus visible au niveau du secteur public, puisque le nombre a reculé de 4,2% pendant la même période. En 2018, les établissements de soins comptent 396000 lits d'hospitalisation à temps complet contre 323000 lits en 2003. Néanmoins, les hôpitaux font face à une diminution régulière du nombre de lits d'hospitalisation à temps complet (hospitalisation de plus de 24h), et à une hausse considérable du nombre de places d'hospitalisation partielle (sans nuitée). Cette hausse est due à des innovations en matière de technologies médicales et de traitements médicamenteux destinés au suivi et au traitement des maladies. La figure 1.2 présente l'évolution de l'activité en hospitalisation complète (séjours) et partielle (journées). La fermeture assez régulière des lits de court séjour -33000 lits en 15 ans et la diminution de la capacité des USLD (80000 lits en 2003 à 31000 lits en 2018) qui sont transformées en certaines unités d'Ehpad (établissements d'hébergement pour personnes âgées dépendantes) influencent fortement l'activité logistique.

En plus de ces facteurs décrits ci-dessus (la diminution du nombre des établissements de soins et la fermeture assez régulière des lits de court séjour), la crise sanitaire de la COVID-19 a mis en évidence et en lumière les difficultés impensées du système de santé français qui a besoin d'être préparé à faire face aux pandémies.

1.3 La place de la logistique hospitalière pendant la COVID-19

La crise sanitaire de la COVID-19 a influencé à la fois les plans économique, social, culturel et humanitaire. Le nombre des personnes admises en réanimation après avoir été contaminées par la COVID-19 a principalement déstabilisé les organisations hospitalières fragiles en termes de capacités et de gestion des ressources (humaines et matérielles). Néanmoins, les personnels

soignants, ainsi que tous les acteurs du système ont fait preuve d'une remarquable abnégation pour sauver des vies.

Cette pandémie de coronavirus a eu un effet sans précédent sur la prestation des soins de santé à l'échelle nationale et internationale. Même si la reconfiguration des établissements de santé a commencé au début mars 2020, cela n'a pas empêché le nombre important de difficultés rencontrées par les soignants dans les unités de COVID-19. Par exemple, les soignants vêtus d'équipements non adaptés ou le manque de matériels comme les lits d'hospitalisation en réanimation ou les respirateurs artificiels. Face à une augmentation rapide des demandes de soins (l'afflux des patients positifs à la COVID-19 et atteints de détresse respiratoire aigüe), les autorités politiques et gouvernementales ont été confrontées à une prise de décision urgente à laquelle elles n'étaient pas préparées : quelles mesures appliquer pour éviter un afflux de patients amplement supérieur aux capacités de lits d'hospitalisation en réanimation ? Quelle solution logistique peut être envisagée ?

Dans la littérature, l'impact de la crise sanitaire a été visible sur trois axes logistiques : l'augmentation des délais, l'augmentation des coûts et la diminution de la flexibilité. Dans ce contexte, (BOURRET 2016) explique que les méthodes inter-organisationnelles de coordination en santé (les réseaux coordonnés de soins, la maison de santé pluri-professionnelle) se sont prouvées comme une réponse au choc des épidémies. Ainsi l'auteur précise que l'utilisation de la technologies de l'information et de la communication (TIC) est bénéfique dans la traçabilité des coopérations au sein de ces méthodes. En outre, dans (GARIDI 2020) l'auteur a montré qu'une chaîne logistique multi-acteur orchestrée autour de la traçabilité du parcours patient est la plus adaptée pour la gestion des flux des patients pendant une crise sanitaire comme la COVID-19. Également, les mêmes travaux ont montré que les TIC facilitent la traçabilité des flux et par conséquent elles contribuent à l'amélioration de la qualité des soins et à la rapidité de la circulation des flux.

Bien que les services des urgences ont dédié une zone d'accueil pour les patients COVID-19 en respectant la division des flux (COVID et non COVID), cet effort n'a malheureusement pas empêché le développement fulgurant de l'épidémie. Afin de mieux gérer cette situation, une étude analysant le retour d'expérience de deux structures des urgences en Alsace (centre hospitaliers de Mulhouse et de Colmar) a été réalisée (NOIZET et al. 2020). Cette étude décrit le fonctionnement des structures des urgences avant et pendant la crise sanitaire ainsi que les stratégies mises en place pour l'orientation post-urgence, la prise en charge des patients en détresse respiratoire et la gestion des lits COVID.

1.4 La chaîne logistique des urgences

Les services des urgences (SU) accueillent les personnes qui ont pris d'elles-même la décision de venir, ainsi que celles qui se sont adressées à un système de secours. Le système de secours en France est assuré par : 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. Les SU présentent l'unité de soins aigus annexée à un établissement de santé afin de fournir des traitements médicaux primaires aux patients dont l'état nécessite une intervention immédiate. Ces unités semi-autonomes sont ouvertes et dotées de personnels pluridisciplinaires 24 heures par jour et 365 jours par an, y compris les jours fériés. Le nombre de patients qui se présentent dans les SU ne cesse d'augmenter, plus de 19 millions de patients consultent les SU chaque année. En France, il existe environ 709 structures d'urgence qui sont autorisées et situées dans les hôpitaux publics et les cliniques. Selon le département de la re-

cherche statistique¹, environ 15% des patients qui se présentent aux SU sont transférés par les services de secours et plus de la moitié des blessés et malades qui s’y rendent arrivent par leurs propres moyens. En effet, la durée de séjour aux urgences est très variable; 20% des patients passent moins d’une heure et 10% passent entre quatre et huit heures, tandis que 2% partent sans attendre leur prise en charge. Suite à la prise en charge des patients, trois-quart d’entre eux rentrent chez eux alors que 20% des patients sont hospitalisés.

Le rôle initial des SU est de prendre en charge prioritairement les patients qui présentent une détresse vitale. Bien que les visites aux SU portent sur un large échelle de pathologies, c’est-à-dire des cas véritablement urgents, des cas urgents, des cas semi-urgents et des cas non urgents. Les SU s’organisent aujourd’hui pour augmenter leurs ressources pour pouvoir traiter tous ces cas. La prise en charge de ces patients s’effectue selon différents modes, c’est-à-dire en fonction du type de soins nécessaires : soins programmés, soins qui nécessitent ou non une hospitalisation, soins non programmés et soins urgents ou non urgents. A partir de ces différents modes, le temps d’attente prévisionnel d’un patient est déterminé. Par exemple, pour un accident vasculaire cérébral (AVC) le temps d’attente est estimé à 20 minutes, pour une douleur thoracique le temps d’attente est estimé à 60 minutes et pour une entorse de cheville le temps d’attente est estimé à 120 minutes. Une fois le patient pris en charge, son parcours peut demander un plateau technique ou des avis spécialisés dont le SU dispose ou pas. Dans le cas où le SU ne dispose pas du plateau technique ou de l’avis spécialisé requis, le patient doit être géré en interne ou en interaction avec d’autres services le plus rapidement possible. Si le patient doit être transporté vers un autre service de soins plus appropriés, c’est le SAMU qui est chargé d’effectuer ce transport.

Dans la plupart des SU, le volume d’admission varie peu d’un jour à un autre ou d’un jour de semaine à un week-end. 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 correspondent à la France métropolitaine et hors service de santé des armées (SSA). Cette progression est constante depuis vingt ans (3,4% par an en moyenne). Par exemple, en 1996 les urgences ont enregistré 10,1 millions de passages pour la France métropolitaine et hors SSA. Chaque SU parmi les 709 SU en France reçoit en moyenne 30800 patients par an, ce nombre est moins important dans les services des urgences pédiatriques (27300 passages en moyenne et par an) que dans les services des urgences adultes (31300 passages en moyenne et par an). Avec ces chiffres, nous pouvons conclure que même si le volume d’activité des SU augmente fortement, le nombre des SU en France reste stable. Il existe en plus des SU, 101 SAMU et 387 SMUR dans la France métropolitaine qui ont pour rôle d’assurer l’orientation, le transport des malades et la prise en charge pré-hospitalière si nécessaire avec l’aide d’un médecin correspondant.

Le SU représente le pilier capital de la chaîne logistique hospitalière, il est constamment dans une démarche d’amélioration continue de la qualité des soins. Néanmoins, vu l’augmentation de 3,4% du nombre de passages moyen aux urgences en France par an et vu la nature imprévue de l’arrivée des patients. Les SU sont confrontés à des demandes contrastées auxquelles ils ont du mal à répondre et c’est ainsi que le SU peut se trouver à tout moment face à une situation d’engorgement. Lorsque la demande est supérieure à l’offre, il s’ensuit généralement une situation de tension. La tension est connue comme un problème mondial (HOYLE 2013), (PASCASIE et MTSHALI 2014). Par exemple, elle représente une crise nationale aux États-Unis (KELLERMANN et al. 2013). La tension dans les SU est due à un excès important de patients dans

1. Statista Research Department: Les urgences médicales en France




FIGURE 1.3 – La chaîne des urgences

les zones de traitement, qui dépasse la capacité réelle des urgences et réclame ainsi des prises en charge dans les couloirs des SU et dans d'autres zones d'examen improvisées (HUSSEIN et al. 2017).

L'inadéquation entre les ressources et les besoins, le vieillissement de la population et l'augmentation du nombre de personnes atteints de maladies chroniques affaiblit encore le système des urgences. Les difficultés de capacité s'aggravent plus en début de semaine vu que les patients ne vont pas aux urgences généralement pendant les week-ends. Ceci expose les SU de plus en plus à des problèmes d'engorgement (NOËL 2019). La tension aux SU pose des problèmes à la fois aux patients et aux personnels soignants, parmi les conséquences de ce phénomène : l'augmentation de temps d'attente, le détournement des ambulances, l'allongement de la durée des séjours et l'augmentation des erreurs médicales. En outre, la tension dans les urgences provient de l'engorgement et la saturation des hôpitaux et la solution à ce problème complexe se trouve dans les urgences elles-mêmes (intra) ainsi qu'en dehors des urgences : l'amont et l'aval des urgences (figure 1.3).

1.4.1 Qu'est-ce que la tension aux urgences ?

La tension est connue comme un problème mondial (SALWAY et al. 2017). Elle est la cause principale des diverses difficultés telles qu'un excès extrême de patients dans les zones de traitements, une prolongation des temps d'attente qui implique une longue durée de séjours, des soins médicaux dans les couloirs du SU. Dans ce contexte, la tension dégrade la qualité des soins et la satisfaction des patients, du moment qu'il y a pas assez de personnel disponible. D'autant plus que, le personnel soignant est à la fois entre les prises en charge des patients dont le pronostic vital n'est pas engagé (CCMU=1), des arrivées en SAMU et des réanimations après un accident. Ce phénomène entraîne de sérieux problèmes de qualité aux SU comme : l'augmentation de la probabilité des erreurs médicales (PINES et al. 2011), (BERNSTEIN et al. 2009), l'augmentation du stress des patients qui attendent d'être pris en charge (PINES et al. 2011) et les détournements des ambulances (PAUL, REDDY et DEFLITCH 2010). Selon les règles d'éthique médicale, les situations de tension sont incompatibles avec la prise en charge des patients (Moskoff et al. 2019). Ainsi, la résolution du problème de tension est un défi qui préoccupe les praticiens hospitaliers, les chercheurs universitaires, les médias, etc (SALWAY et al. 2017).

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* ». Cette définition est proche de la définition des auteurs dans (HUSSEIN et al. 2017) qui indique 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* ». Ces définitions ne prennent pas en compte l'aspect temporel alors que les conséquences de la tension dans le SU sont relatives à sa prolongement dans le temps. Nous pouvons certainement penser que les attentes dans les SU sont dues à une mauvaise gestion des urgences et à l'impossibilité d'optimiser les flux. Cependant, la maîtrise de ce phénomène demande une réflexion plus générale. D'ailleurs, un nombre important de recherches (SALWAY et al. 2017) ont conclu que **la tension des urgences est en grande partie due à 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)² ont défini 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* » (CHANDOU 2015). Ce projet avait pour objectif 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 dans les urgences pédiatriques du centre hospitalier universitaire (CHU) de Lille. En outre, la FEDORU³ française a défini la tension aux SU comme « *une inadéquation entre la demande (flux entrant de patients et besoins d'hospitalisation) et 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)* ». La définition du projet ANR HOST ainsi que celle de la FEDORU sont complémentaires : la première prend en considération à la fois l'état des urgences (intra) et l'horizon temporel, et la deuxième prend en considération l'état des urgences (intra) ainsi que l'aval des urgences. Comme nous l'avons mentionné précédemment (cf. section 1.4); afin de maîtriser l'engorgement et la saturation des urgences, il faut améliorer la chaîne des urgences : les urgences elles-mêmes (intra) ainsi qu'en dehors des urgences : l'amont et l'aval.

La qualification et la quantification de la tension hospitalière en France n'ont pas un consensus précis. Plusieurs indicateurs ont été présentés au niveau international qui permettent de mesurer le degré de cette tension. Ces indicateurs ont comme objectif de proposer un plan qui avertit le personnel hospitalier quand le service des urgences est en état de tension. Parmi ces indicateurs : NEDOCS (WEISS et al. 2004) ou l'EDWIN (BERNSTEIN et al. 2003) aux États-Unis, l'ICMED en Angleterre (BOYLE et al. 2016), le SEAL en Suède (WRETBORN et al. 2015) et SAGeT en France (CHANDOU 2015). Il est important de souligner que l'ensemble de ces outils ne prennent pas en considération la gravité des patients dans le calcul de leurs scores. Ainsi, les patients non urgents qui présentent un CCMU (classification clinique des malades aux urgences) égal à 1 impactent le calcul de scores de la même façon qu'un patient grave (CCMU= 5). En France, seul le directeur d'établissement ou son représentant peut annoncer, modifier ou clôturer une situation de tension. Selon le ministère de la santé⁴, il y a 97 hôpitaux sur 650 qui ont déjà activé le plan "hôpital sous tension". Ceci indique que ces hôpitaux ont fait face à une situation compliquée de prise en charge aux urgences hospitalières, qui peut mener à déclencher le plan blanc. Il s'agit d'un mode de fonctionnement propre à chaque établissement qui implique généralement la

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

3. FEDORU : Fédération des Observatoires Régionaux des Urgences

4. Politique de santé-Hôpital sous tension

déprogrammation des activités jugées non-prioritaires. Ce plan est déclenché par le préfet et est jugé très coûteux.

1.4.2 Quelles sont les causes de tensions aux urgences ?

Avant de déterminer les causes de tension dans les SU, il est essentiel d'individualiser les situations en trois catégories : (1) la tension en amont des urgences ; (2) la tension au sein des urgences et (3) la tension en aval des urgences. Dans la première catégorie, c'est l'affluence des patients qui est la cause de ce phénomène, qu'elle soit saisonnière, hebdomadaire, événementielle ou suite à une épidémie. Cette affluence est une hausse du nombre d'arrivées des patients (en particulier âgés et/ou en situation grave) de façon consécutive. La seconde catégorie est due principalement au processus non optimal des soins au sein des urgences, par exemple un problème structurel (diminution des effectifs, panne informatique, etc.) ou un problème logistique (un ou plusieurs patients en séquence de réanimation, équipe en intervention, plateau technique inaccessible, etc). La troisième et la dernière catégorie correspond à la déficience des lits d'aval qui peut être une déficience en : soins critiques (réanimation, soins intensifs), en hospitalisations (hospitalisations programmées ou non programmées), en maternité, en SSR (soins de suite et de réadaptation). Ce genre de situation provoque une augmentation de la charge de travail en intra urgences sans que les flux entrants ou sortants ne soient augmentés.

1.4.2.1 Les causes en amont

Parmi les facteurs qui sont à l'origine de la tension aux SU, la constante augmentation de l'afflux des patients. Cette augmentation est due au vieillissement de la population, à la facilité d'accès aux urgences (accessible à tous), les épidémies saisonnières (la grippe) et à la difficulté de trouver rapidement un rendez-vous pour un soin non programmé (vu le manque de coordination entre les médecins traitants et les spécialistes). La comparaison du système de santé français par rapport aux autres systèmes de santé doit être réalisée avec une vigilance, car le coût d'un passage aux urgences est différent. En France, ce coût est d'environ 70 euros si le patient retourne chez lui après la prise en charge. À noter que ce coût est complètement pris en charge par l'assurance maladie. Or dans le système américain, ce coût est d'environ 1000 dollars et il est à la charge du patient sauf s'il bénéficie d'une mutuelle (ce qui n'est pas le cas pour la majorité). Cette comparaison permet de conclure qu'en France, les patients n'hésitent pas à consulter aux SU même pour des symptômes légers.

Selon le rapport FEDORU qui a compté 20 millions de passages aux SU en 2017, il y a 18% de patients non urgents (CCMU=1) contre 20% en 2019. Ces patients non urgents présentent une charge de travail souvent faible, ils sont rarement hospitalisés. S'ils se présentent pendant une situation de tension, la question est de savoir à quel point leur présence influence cette situation ? Les auteurs dans (KIRKLAND et al. 2019) ont apporté une réponse à cette question : si le SU est composé d'un circuit court et/ou d'une réorientation à l'accueil des urgences, les patients non urgents ne seront pas la cause principale de la tension. En outre, la plupart du professionnel de santé n'a pas à sa disposition des outils adaptés, qui lui permettent de prédire le nombre d'arrivées journaliers dans le SU et ainsi anticiper ces afflux. Sachant que la pathologie des patients admis doit être prise en compte lors de l'évaluation de la tension parce que l'évolution de l'état de santé des ces derniers détermine la charge de travail associée.

L'afflux important dans l'amont des urgences peut entraîner une tension ponctuelle. Néanmoins,

cet afflux n'engendre pas automatiquement une tension dans la chaîne des urgences, si le reste du processus de soins fonctionne correctement.

1.4.2.2 Les causes en intra-urgences

La prise en charge des patients aux urgences par un personnel de la santé (médecins, chirurgiens, internes, infirmier(ère)s, aide-soignant(e)s) dépend de divers éléments structurels ou/et organisationnels. Le manque ou le dysfonctionnement d'un de ces éléments aux urgences peut déclencher une saturation dans le processus de soins. D'autant plus que l'effectif des soignants est déterminé en fonction de la dimension du SU ainsi que l'historique des situations de tension constatées. Pourtant, il y a toujours une pénurie des ressources humaines, donc il est crucial de prendre le ratio entre le nombre des patients présents ainsi que le nombre de médecins pour évaluer une situation de tension. Dans ce contexte, c'est l'étape triage qui permet de prioriser les patients les plus graves des moins graves et ainsi les orienter vers les structures adéquates. Un temps d'attente (attente primaire et attente secondaire) accru et excessif peut être la cause d'une détérioration de l'état de santé du patient. Lors d'une situation de tension, l'infirmier(ère) d'accueil et d'orientation (IAO) peut sous ou sur évaluer l'état d'un patient. Cela implique non seulement une erreur d'orientation qui peut augmenter le temps d'attente du patient mais encore la contribution à la saturation du service.

L'organisation et la gestion d'un SU sont complexes à cause de : l'environnement incertain, la multitude des acteurs et des métiers impliqués (gouvernement, compagnies d'assurance, organisation professionnelles, logisticiens, etc.), l'influence de l'extérieur (amont, aval) et les facteurs difficiles à maîtriser. 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. Ainsi, le manque d'outils d'aide à la décision de pilotage pour les professionnels de santé aggrave la situation. Ces outils permettraient d'apporter plusieurs aides aux personnels soignants, comme proposer un ordonnancement dynamique des patients qui prend en considération leur niveau de gravité.

1.4.2.3 Les causes en aval

La saturation de l'aval des urgences est reconnue comme un élément majeur de la tension des SU. Actuellement dans les urgences françaises, les patients sont positionnés sur un brancard en attendant qu'une place se libère en hospitalisation. Le délai d'attente pour un lit d'hospitalisation est l'un des plus pertinents indicateurs pour la tension aux urgences (NOEL, DRIGUES et VIUDES 2018). La saturation de l'aval des SU est due à une inadéquation entre la hausse du nombre d'hospitalisations depuis les SU et la diminution du nombre de lits d'hospitalisation en France. Ce nombre a baissé de 13% entre 2012 et 2015, cette baisse est justifiée par un appel plus régulier à la chirurgie ambulatoire (BERGONZONI et al. 2020). Donc une recherche optimisée avec une anticipation des besoins en lits pour les SU et une coordination entre le SU et le service d'aval, peuvent fluidifier l'aval des urgences. 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. Ces outils ont pour but de prédire et d'anticiper l'hospitalisation d'un patient (disponibilité d'un lit) dès l'arrivée de ce dernier aux urgences (NOEL et al. 2019), (CAMERON et al. 2017), (CAMERON et al. 2015), (KIM et al. 2014).

Dans l'objectif d'affronter les situations de saturation dans les chaînes des urgences, l'agence

régionale de santé (ARS) a recommandé aux patients en Alsace de téléphoner à leurs médecins traitants ou à SOS médecins avant de se rendre aux urgences. Cette solution n'allège pas les saturations dans les SU vu que le nombre des patients qui ont besoin d'être accueillis doivent être transférés rapidement dans des unités d'hospitalisation adéquates (pour assurer la continuité de leur prise en charge).

1.4.3 Quelles sont les conséquences de la tension aux urgences ?

Les situations d'engorgement et de saturation dans les urgences sont "tueurs silencieux" car les conséquences d'un tel phénomène sont parfois dramatiques. La saturation des urgences est introduite dans la littérature américaine depuis 1980, alors que ce phénomène est introduit en Europe dans les années 2000. En effet, il existe une abondante littérature qui expose les différentes conséquences de ces épisodes de tension notamment :

- un temps d'attente long avant la prise en charge : selon une étude américaine (HORWITZ, GREEN et BRADLEY 2010), seuls 67% des patients atteints des maladies aiguës ont été pris en charge dans des délais raisonnables. Différentes études basées sur des observations ont trouvé qu'il y a une liaison entre la tension et la mortalité. Les auteurs dans (PINES et al. 2009) ont étudié les taux de complications des patients atteints du syndrome coronarien aigu dans des situations des tensions et en absence de situation de tension. Ils ont remarqué qu'une hausse significative des complications (environ 6% contre 3% des patients qui décèdent) chez les patients qui se sont présentés pendant 8 épisodes de tension. Ces derniers sont décédés sur un brancard dans un couloir des SU, sans avoir été pris en charge préalablement par un médecin. Cette crainte, une femme de 73 ans l'a subi à Reims. En outre, les prises en charge tardives peuvent avoir comme conséquence un handicap ou un décès. Ces temps d'attente longs peuvent être limités en réduisant le blocage en amont des urgences ;
- une augmentation du nombre d'abandons : plus l'attente est longue, plus le nombre des abandons augmente. Ces patients abandonnent les SU avant leur première consultation avec un médecin. Un certain nombre de ces départs nécessitent une admission ultérieure (BATT et TERWIESCH 2015). Il y a peu de patients atteints d'une maladie grave qui décident de quitter les SU ;
- l'association lit d'aval et durée de séjours : 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) ;
- la tension réduit la qualité des soins et augmente les erreurs médicales : deux types d'erreurs peuvent se produire pendant une situation de tension. (1) des erreurs d'omission puisque le personnel médical doit se concentrer à la fois sur les patients qui sont déjà présents aux urgences et sur les nouvelles urgences qui se présentent (COWAN et TRZECIAK 2004). (2) des erreurs médicamenteuses qui sont de plus en plus fréquentes dans les situations de tension (KULSTAD et al. 2010) ;

- le détournement des ambulances : c'est un indice qui indique que la capacité du système de santé est en saturation. Ce détournement désigne une réorientation d'une ambulance d'un SU à un autre moins encombré. Ceci peut prendre un certain délai, ce qui met la vie des patients en danger ;
- une augmentation de la mortalité : une étude californienne indique que les patients admis au cours d'une situation de tension avaient 5% plus de risques de décès (SUN et al. 2013). Une autre étude dans le CHU de Nîmes, affirme que le taux de surmortalité des patients ayant attendu une hospitalisation est de 7,8% (THIBON et al. 2019). Les auteurs dans (SINGER et al. 2011) ont constaté que le taux de mortalité est de 2,5% pour les patients hospitalisés pendant moins de deux heures, contre 4,5% pour les patients hospitalisés pendant plus de douze heures, également la durée de séjour passe de 5,6 jours à 8,7 jours.

1.4.4 Comment réduire le flux des patients aux urgences ?

Les actions visant à réduire le flux des patients aux urgences et par la suite réduire les situations de tension, doivent concerner toute la chaîne des urgences : de l'amont à l'aval du SU, chaque étape dans le parcours patient contribue à des degrés différents à la tension aux urgences.

1.4.4.1 Les solutions proposées au sein des urgences (intra)

L'organisation et la gestion d'un SU sont complexes vu l'environnement incertain et l'influence de l'extérieur (amont & aval). Ainsi, améliorer l'organisation de l'accueil réduit le temps d'attente des patients. Dans (TAKAKUWA, SHOFER et ABBUHL 2007) les auteurs proposent de réaliser l'enregistrement des patients avant l'entrée aux SU mais cette situation ne peut être réservée qu'à un nombre limité de patients. Dans (OREDSSON et al. 2011) les auteurs proposent de mettre en place soit un circuit ambulatoire soit un médecin organisateur au niveau de l'accueil qui sont des mesures efficaces pour réduire la durée de séjour.

Analyser la capacité de traitement et s'assurer que le professionnel de la santé est formé de manière optimale est une autre solution proposée par (MANDAVIA et SAMANIEGO 2016). En effet, un effectif optimisé garantit que le service dispose des ressources appropriées au moment où il y a une augmentation du flux de patients. Améliorer les durées d'attente longues en ajoutant des lits dans le SU ou en augmentant la taille des SUs est loin d'être idéale selon (KHARE et al. 2009) car l'augmentation du nombre de lits dans le SU ne permet pas une diminution de la tension. En effet, l'augmentation de la taille du SU permet au contraire de garder plus des patients et ainsi d'allonger leur durée de séjour (SAYAH et al. 2016). En outre, les solutions à mettre en place pour anticiper les situations de tension devaient être menées dans une logique de filières de patients et non seulement sur la capacité physique d'accueil.

1.4.4.2 Les solutions proposées en amont et en aval des urgences

Le nombre de patients non urgents (motif de faible gravité) présents et le détournement des ambulances ne sont pas les causes principales de la tension aux urgences. Par contre, il est compliqué de définir ce qu'est une consultation non urgente nommée également consultation inappropriée aux SU (DURAND et al. 2011).

Une récente étude française (NAOURI et al. 2020), indique que 20% à 40% de l'ensemble des consultations aux urgences sont des consultations inappropriées. Ces consultations inappropriées

sont associées aux difficultés à contacter un médecin de ville ou aux difficultés socio-économiques du patient. La détermination d'une consultation inappropriée aux SU peut être réalisée dès l'entrée du patient aux urgences (avant la prise en charge par un médecin) ou à la sortie des urgences (après la prise en charge par un médecin). Dans la première situation, c'est la classification clinique des malades aux urgences (CCMU) ou la french emergency nurses classification in hospitals (grille FRENCH cf. annexe A) qui permettent de fixer le score à 5 (patient de faible gravité). Il est important de noter que la classification de CCMU en France est une classification à l'inverse de la classification internationale, il s'agit d'une classification locale. Cette première situation présente 5% à 10% des arrivées. La deuxième situation correspond au fait que l'inadaptation de la consultation est décelée après l'examen médical, le nombre de passages dans ce cas est d'environ 30% (TABOULET et al. 2019). Finalement, l'amont des urgences n'apparaît pas être la cause principale des situations de tension. Interdire les possibilités de passage aux urgences pour les patients non urgents ne semble pas être la bonne solution pour améliorer l'amont des urgences et surtout que ce n'est pas le rôle d'un service public. Par contre, une meilleure organisation et une meilleure coordination avec la médecine de ville permet de réduire le nombre de passages aux urgences. En plus, l'intégration d'outils plus sophistiqués qui permettent la prédiction des arrivées aux urgences permet d'anticiper l'afflux des patients et ainsi d'anticiper les situations de crise (tension).

La tension dans les SU est liée instantanément à l'organisation de l'aval du SU, et notamment au taux d'occupation des unités d'aval. Le lien entre la saturation des SU et la saturation de l'aval a été clarifié dans (PROUDLOVE, GORDON et BOADEN 2003). Les auteurs expliquent que lorsque les urgences sont saturées, les durées de séjour sont prolongées et ainsi le taux d'occupation des unités d'aval s'aggrave. Si ce taux dépasse 85%, l'attente d'hospitalisation ("*boarding*" en anglais : *le temps d'attente du patient entre la décision d'hospitalisation et son affectation à un lit*) augmente dans les urgences. Dans (PROUDLOVE, GORDON et BOADEN 2003) et (PROUDLOVE 2020) les auteurs illustrent qu'en "lissant" l'activité programmée sur la semaine, organiser les sorties le week-end et réaliser les sorties le matin plutôt que l'après-midi, cela améliore l'efficacité des unités d'aval. L'installation des unités dédiées à l'aval des urgences dans les établissements de soins, destinées à prendre en charge les patients permet d'alléger la tension des SU ainsi que la tension dans les établissements (ELDER, JOHNSTON et CRILLY 2015), (WOODWARD et al. 2019). Ce genre d'unités est nommé différemment : « unité post urgences », « unité d'hébergement temporaire des urgences » ou « unité d'attente d'hospitalisation ». Ces unités sont différentes des « unités d'hospitalisation de courte durée » et de la « zone d'hospitalisation de très courte durée » puisque le rôle de ces unités est de surveiller l'état des patients pour une durée maximale de 24h, avec un retour à domicile envisageable. Selon (PATEL, COMBS et VINSON 2014), (KAWANO et al. 2014) réduire les admissions programmées pour privilégier les admissions non programmées n'induit pas de résultats univoques. À noter que ces résultats n'ont pas été menés dans des situation de tension.

1.5 Problématique de la thèse

La gestion de la chaîne logistique dans le secteur de la santé est primordiale, car elle permet d'offrir une meilleure qualité de soins à moindres coûts. D'ailleurs, les établissements de santé considèrent les activités logistiques comme un vecteur d'économie. La qualité de soins est un facteur clé pour évaluer la performance de la logistique hospitalière, ce facteur associe à la fois le patient et le professionnel de santé. 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 de soins.

Le système de santé en France est à l'heure actuelle en constante évolution, les activités logistiques d'un établissement de santé ont des conséquences directes sur la performance des prestations. Pour bénéficier d'une chaîne logistique hospitalière performante, efficace et opérationnelle, il faut mesurer régulièrement sa performance. Ainsi, le déploiement d'un système de mesure de la performance des différents éléments en interaction, qui composent la chaîne, s'impose au cœur de la démarche nécessaire pour améliorer les bénéfices d'une logistique hospitalière performante.

Dans la gestion de la chaîne logistique hospitalière, le contrôle des situations d'engorgement est un enjeu majeur pour la santé publique. Ce phénomène international impacte le fonctionnement des établissements de santé et met les acteurs de la santé face à des défis. Ces situations d'engorgement sont liées à une mauvaise gestion de la chaîne logistique. En effet, le phénomène de tension intervient principalement dans les urgences puisqu'elles présentent le pilier capital du réseau logistique hospitalier. Les acteurs du secteur hospitalier doivent maîtriser efficacement 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.

Les travaux de cette thèse s'inscrivent au cœur du projet ANR OIILH (ANR-18-CE19-0019)⁵ : optimisation inter et intra logistique hospitalière, et s'appliquent sur le service des urgences adultes (SUA) du CHU⁶ de Lille. Le SUA est un service qui représente particulièrement des situations de tension, vu les longs délais d'attente qui peuvent atteindre plus de dix heures. Ces durées d'attente peuvent être la cause de la détérioration de l'état de santé des patients et ainsi exposer leur vie à un danger. Ces situations de tension mettent les urgences dans des situations critiques. Pour gérer ces crises sanitaires, il faut revoir le processus complet de la chaîne des urgences et notamment son amont et son aval. Il est donc crucial de mettre en place des mesures qui visent à maîtriser non seulement la gestion interne « des urgences » (*intra logistique*) mais aussi la totalité de « la chaîne logistique des urgences » (*amont-intra-aval*). Ces mesures ont pour objectifs de sécuriser, d'améliorer et de perfectionner 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 basés sur **l'obtention, l'analyse et l'exploitation** des données de santé issues du SUA du CHU de Lille :

- l'analyse des données de santé (amont-urgences) : La grande majorité des patients arrivent spontanément aux urgences sans moyen de régulation. L'optimisation de l'amont consiste à anticiper ces flux spontanés des patients à partir de l'analyse des données afin d'adapter en conséquence les ressources internes et la communication avec les services d'amont.
- l'optimisation du parcours patients (intra-urgences) : développer des modèles et des algorithmes d'optimisation en utilisant des techniques issues de l'intelligence artificielle (IA) pour l'ordonnancement des tâches de soins à compétences multiples aux urgences adultes du CHU de Lille.
- l'optimisation de la gestion des lits d'hospitalisation (urgences-aval) : le problème principal qui se pose ici est la gestion de la sortie du patient du service des urgences. Il s'agit de

5. Projet ANR OIILH

6. chu-lille.fr

gérer le plus efficacement possible le flux de sortie des patients de façon à permettre de retrouver un lit d'aval le plus rapidement possible, et à assurer la continuité des soins dans les meilleures conditions dans les unités d'aval.

Par conséquent, la simulation de ces modèles et algorithmes va être réalisée sur des données issues du SUA. Ce service des urgences peut être vu dans une première approche comme un système en interaction avec d'autres systèmes, avec des flux entrants et des flux sortants. Le but de cette thèse est d'étudier et développer un système d'aide à la décision (SAD) centré sur le patient basé sur l'alliance entre les systèmes multi-agents, l'optimisation et l'apprentissage.

1.6 Conclusion

Dans ce chapitre, nous avons présenté la chaîne logistique hospitalière en France et en particulier le service des urgences adultes (SUA) qui est le terrain pratique de notre travail. Ainsi, nous avons expliqué la sensibilité et la complexité de la gestion des acteurs du réseau logistique hospitalier et notamment les services des urgences. Ces difficultés sont dues à leur organisation interne en inter et intra services qu'ils soient ou non au sein de la même structure hospitalière. Également, nous avons souligné le problème de la tension dans les SU en France et nous avons montré que ce problème conduit les urgences vers un dysfonctionnement non seulement en intra mais aussi en amont et en aval.

Un état de l'art sur les diverses approches et outils de modélisation, d'optimisation et d'apprentissage sera présenté dans le prochain chapitre.

État de l'art : outils et approches de modélisation, d'optimisation et d'apprentissage appliqués dans le domaine de la santé

2.1 Introduction

Aujourd'hui, les acteurs de la santé doivent maîtriser les problématiques liées aux flux des activités de soins (les patients, les informations, les plateaux techniques, etc.). Néanmoins, ces acteurs ne sont ni formés, ni préparés pour résoudre de tels problèmes. Il semble qu'ils sont démunis en méthodologies et outils d'aide à la décision et d'orientation adaptés aux exigences qu'impliquent leurs modes de fonctionnement futurs. Dans ce cadre, diverses études et recherches dans la littérature ont contribué pour améliorer la performance des établissements de santé. Les chercheurs dans ce domaine ont fait appel à l'innovation technologique pour répondre aux problèmes des dysfonctionnements dans les hôpitaux. D'ailleurs, ils ont déduit qu'il est nécessaire d'intégrer de nouveaux concepts et outils scientifiques et technologiques, pour assurer la progression de la chaîne logistique hospitalière.

Dans ce chapitre, nous présentons un état de l'art sur les outils et les approches de modélisation, d'optimisation et d'apprentissage dans la chaîne logistique hospitalière, ciblant en particulier la chaîne des urgences.

2.2 La modélisation informatique

La modélisation représente la première étape de toute étude centrée sur l'ingénierie des systèmes. Cette étape est extrêmement primordiale dans le processus de simulation, car elle

affecte les étapes ultérieures du projet. Un modèle conceptuel complet est nécessaire pour la réalisation d'un modèle de simulation robuste et performant. Dans une étude de simulation, la définition explicite des objectifs et des éléments d'un modèle pendant la phase de modélisation réduit considérablement le coût du temps de développement.

Il existe de multiples méthodes de modélisation réservées aux entreprises, qui désignent un large éventail du système industriel dont les hôpitaux. La création d'un modèle théorique permet non seulement la compréhension du fonctionnement du système, mais aussi la détermination d'une méthode de résolution du problème en fonction de sa complexité. En effet, la modélisation permet de simplifier la communication avec les acteurs et ainsi de préciser les indicateurs de performance appropriés pour la simulation d'un système.

La construction d'un modèle dans un milieu hospitalier doit s'appuyer sur la communication et l'intégration des acteurs principaux (i.e. personnel soignant). Il y a globalement trois approches de modélisation dans la littérature (chacune détient un ensemble d'outils) : orientée objet (Unified Modelling Language : UML, Systems Modeling Language : SysML), orientée agent (Agent UML : AUML) et orientée processus (Business Process Model and Notation : BPMN/Workflow). Quelques outils de modélisation, pouvant être appliqués dans le système hospitalier, seront présentés dans ce qui suit.

2.2.1 La modélisation UML : Unified Modelling Language

Les systèmes de santé sont connus pour être complexes et difficiles à analyser. UML a été largement utilisé pour analyser des systèmes complexes dans plusieurs domaines, tels que les systèmes hospitaliers.

UML est un langage de modélisation et de représentation graphique, suffisamment souple pour s'adapter aux différents domaines d'activités existants. Il est le résultat d'une combinaison entre différentes autres méthodes d'analyse orientées objets telles que : OMT (RUMBAUGH 1996), Booch (BOOCH 1996), OOSE (JACOBSON, CHRISTERSON et CONSTANTINE 1994), standardisé par l'object management group (OMG) en 1997. Ce langage graphique s'articule autour de plusieurs diagrammes différents, chacun d'entre eux permet la représentation d'un système logiciel suivant un point de vue spécifique. Également, UML modélise un système via deux types de représentation complémentaires : la première concerne la structure du système au repos et la deuxième concerne sa dynamique de fonctionnement. Afin de comprendre chaque composante du système étudié, la modélisation doit être construite étape par étape. Ces étapes consécutives sont de plus en plus détaillées (de manière progressive), c'est pour cela que tout processus construit sur un modèle doit se munir d'une tactique d'avancement pour renforcer chaque étape de construction de ce modèle. Cette tactique d'avancement itératif est basée sur le processus 2TUP (two tracks unified process) qui permet une vision de moins en moins abstraite. Ce processus en Y (annexe B) permet une division du modèle suivant deux branches : fonctionnelle et technique, et donc UML est le langage de modélisation objet standard du 2TUP (ROQUES et VALLÉE 2004).

Dans le domaine de la santé, UML a été largement utilisé par plusieurs chercheurs (VASILAKIS, LECZAROWICZ et LEE 2009), (LEO et al. 2019). Par exemple, les auteurs dans (LEO et al. 2019) ont adopté une modélisation UML pour la représentation graphique des processus de soins de patients. Dans (VASILAKIS, LECZAROWICZ et LEE 2009), les auteurs utilisent UML pour modéliser et préciser les exigences relatives au processus de soins. Ces chercheurs ont employé le diagramme d'activité pour spécifier le flux de patients, le diagramme de cas d'utilisation pour détailler la fonction de chaque activité dans le diagramme d'activité et le diagramme d'état pour saisir l'état-transition des patients (la dynamique du comportement des patients en décrivant la

transition qui suit chaque état).

D'ailleurs, une récente étude sur les langages, les notations et les standards de modélisation des processus de soins a été réalisée par (MINCARONE et al. 2018) et a indiqué qu'UML et en particulier ses diagrammes de cas d'utilisation et d'activité sont les diagrammes les plus utilisés dans le domaine de la santé.

2.2.2 La modélisation SysML : Systems Modeling Language

Le SysML est une extension de l'UML, il est conçu pour soutenir la modélisation système. Il s'agit d'un langage de modélisation graphique polyvalent pour la spécification, l'analyse, la conception et la vérification (de la faisabilité d'un système avant sa réalisation) des systèmes complexes (GEANTA 2014). Dans ce cadre, il fournit ainsi des représentations graphiques sous forme de diagrammes (figure 2.1) qui sont à la fois liés entre eux (inter-connectés) et ont leur propre description. SysML se base sur :

- des diagrammes UML : diagramme de séquence, diagramme d'état-transition, diagramme de cas d'utilisation et le diagramme de paquetages ;
- des diagrammes UML modifiés : diagramme d'activité, diagramme de définition de bloc, et diagramme de bloc interne ;
- de nouveaux diagrammes : diagramme paramétrique et diagramme d'exigence.

Dans le domaine de la santé, l'utilisation de la modélisation SysML est de plus en plus répandue. Dans (KOTRONIS et al. 2018), les auteurs utilisent la modélisation SysML pour la représentation d'un système de surveillance à distance des personnes âgées. Concernant le diagramme de cas d'utilisation de ce système, les critères de criticité identifiés sont modélisés en tant qu'exigences SysML, tandis que les contraintes SysML et les diagrammes paramétriques sont utilisés pour décrire et vérifier les exigences de criticité quantitative. En plus, dans (CORNS, THUKRAL et THUKRAL 2014) les auteurs utilisent SysML pour la modélisation de l'architecture d'un système d'administration de médicaments.

L'un des objectifs principaux de la modélisation SysML est de fournir des fonctionnalités suffisantes au développement pour les ingénieurs système. Ce langage propose une représentation des modèles conceptuels (indépendamment de toute mise en œuvre) qui pourraient être traduits automatiquement dans toute sorte de programme de simulation en fonction de la mise en œuvre (GRAVES et BIJAN 2011).

2.2.3 La modélisation Workflow BPMN

Le workflow est déployé au quotidien pour la plupart d'entre nous, dans notre vie professionnelle et personnelle sans que nous ne nous rendions compte. Le workflow est un ensemble reproductible d'étapes exécutées de manière séquentielle dans le temps. Il permet ainsi d'atteindre des objectifs. Il correspond à la modélisation visuelle et à la mise en œuvre et l'exécution des processus métiers afin de parvenir à une automatisation et une amélioration. La vérification d'une mise en œuvre efficace de ces flux de travail est le facteur clé de la réussite d'un projet. Le workflow ne représente que la première étape pour la création du système, donc comment les utilisateurs finaux interagissent avec ce workflow? Comment le workflow communique avec les autres systèmes dans l'entreprise? Peut-il être modifié pour répondre à des conditions imprévues? Les éléments de réponse à ces questions se trouvent dans le BPM.

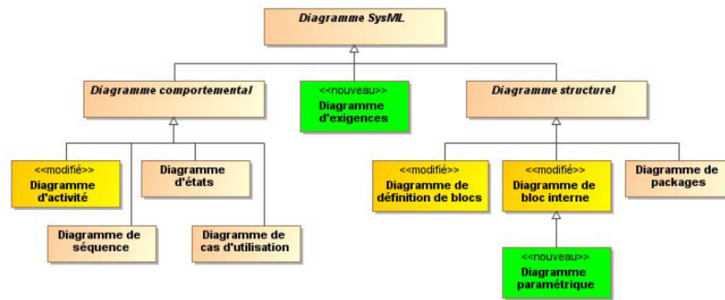


FIGURE 2.1 – Les différents diagrammes SysML (ROQUES 2011)




FIGURE 2.2 – Relation Workflow-BPMN

Le BPM signifie business process management (gestion des processus métiers), au cœur du BPM se trouve le workflow. Il s'agit d'une série d'étapes ou d'activités que les personnes ou les systèmes effectuent selon un cheminement logique jusqu'au déploiement des processus. Selon (VAN DER AALST 2003), le BPM contient les méthodes, les techniques ainsi que les outils pour concevoir, exécuter, manager et étudier les processus opérationnels en s'appuyant sur les différents types d'acteurs.

Dans ce contexte, le BPM propose une notation standard et complète pour la représentation et la modélisation des diagrammes des processus métier. Cette notation est nommée BPMN pour business process model and notation. Le BPMN est implémenté par des nombreux éditeurs et exécutable par la plupart des systèmes de gestion de workflow (figure 2.2). Le langage BPMN est composé de quatre éléments graphiques principaux : les activités, les événements, les transitions et les branchements conditionnels. Il existe de nombreux logiciels qui sont fondés sur ce langage par exemple Bizagi, Bonitasoft, Modelio, etc.

Dans le domaine de la santé, le workflow est utilisé dans plusieurs travaux scientifiques. Par exemple, dans (TODDE et al. 2020), les auteurs ont utilisé le workflow pour évaluer les risques d'un système d'information, indiquant ainsi l'impact de la protection des données dans un processus hospitalier. Dans (ESDAR et al. 2017), le workflow est utilisé pour modéliser la logistique des informations cliniques. Ce travail a montré que le workflow mis en œuvre prend en compte le processus complexe de l'hôpital. Il comprend les multiples professions, les départements et les institutions pour garantir qu'ils étaient qualifiés pour une représentation complète du champ d'application.

2.3 Les systèmes multi-agents (SMA)

2.3.1 La modélisation à base d'agents

La modélisation à base d'agents « *agent based model* » est développée en parallèle avec les notions d'algorithmique distribuée et d'intelligence artificielle (IA) (McCARTHY et HAYES 1981). À partir de ces notions, l'intelligence artificielle distribuée (IAD) et les systèmes multi-agents (SMA) sont apparus. Les modèles basés sur les agents permettent d'analyser et de comprendre les différentes caractéristiques et comportements des systèmes complexes. Par conséquent, la modélisation à base d'agents a été adoptée dans diverses disciplines comme le transport (MGUIS et al. 2012), l'économie (FARMER et FOLEY 2009), la santé (AUCHINCLOSS et DIEZ ROUX 2008), la biologie (THORNE, BAILEY et PEIRCE 2007), l'écologie (VAART, JOHNSTON et SIBLY 2016) et le socio-hydrologie (AERTS et al. 2018).

Ces modélisations sont conçues pour répondre à des questions qui permettent l'explication et la démonstration du système à modéliser. L'auteur dans (MARKS 2013) a classé ces modèles en deux catégories : démonstratifs ou descriptifs. La première catégorie est utilisée pour illustrer les règles et les interactions des modèles et la deuxième catégorie est consacrée à reproduire des phénomènes observés à des fins d'explication, de prédiction, ou les deux. La catégorie des modèles descriptifs inclut à la fois des modèles simples appelés stratégiques et des modèles plus complexes appelés tactiques (HOLLING 1966).

Dans ce contexte, les auteurs dans (TREUIL, DROGOU et ZUCKER 2008) ont défini un modèle à base d'agents comme « *un système composé d'entités multiples ou agents qui évoluent dans un environnement où ils sont localisés. Ces agents sont munis d'attributs, de comportements, et de capacités de perception et de communication. L'ensemble des valeurs des attributs d'une entité à un instant donné représente l'état de cette entité, et la réunion de l'ensemble d'états des entités forme l'état microscopique (état système). Les capacités de perception des entités leur permettent de consulter un sous ensemble de cet état microscopique, habituellement de façon localisée dans l'environnement. Les comportements sont des règles contrôlant à chaque instant l'évolution de cet état, en intervenant sur les états des entités qui les portent ou sur leur existence même (création et destruction), ainsi que sur les états et l'existence des autres entités intervenant dans les éventuelles actions, communications ou interactions décrites dans les comportements.* »

2.3.2 Le concept d'agent

Un agent est défini comme une entité logicielle autonome située dans un environnement réel ou virtuel, capable d'agir sans l'intervention directe d'un autre système. Cette entité logicielle a le contrôle sur ses propres actions et sur son état interne. Chaque agent a son propre processus cyclique, qui est constitué de trois étapes : perception, décision et action. Ce processus lui permet d'adapter son comportement par rapport au contexte. Ces agents qui peuvent être des entités physiques ou virtuelles, sont à la fois réactifs aux changements de l'environnement et pro-actifs pour la satisfaction de leurs objectifs (BADEIG et BALBO 2012). Les différentes propriétés possibles d'un agent sont :

- l'autonomie : chaque agent possède ses propres objectifs et son propre mécanisme de prise de décision. Il agit sans l'aide d'un tiers (humain ou agent), et en fonction de son environnement et de son état interne il choisit ses actions ;




FIGURE 2.3 – Représentation graphique des interactions agent-environnement

- la proactivité : l'agent est pro-actif c'est-à-dire qu'il a une activité dirigée par son but ;
- la réactivité : l'agent est réactif, il ne répond qu'aux stimuli de son environnement. Ainsi l'agent ne possède pas de mémoire, il n'a pas de représentation de l'environnement, des autres agents qui sont présents dans le système. Dans ce cas, les actions de l'agent dépendent directement de ses perceptions ;
- l'adaptation : l'adaptabilité d'un agent implique que ce dernier est capable d'intervenir dans des situations imprévues, modifier le cours de son exécution en conséquence, et ainsi améliorer ses connaissances en fonction des situations rencontrées (apprentissage) ;
- la compétition : l'agent doit être capable d'agir dans un environnement où il y a d'autres agents qui interviennent. L'objectif est le même pour l'ensemble des agents. Par contre un seul agent arrivera à atteindre cet objectif ;
- la délégation : l'agent réalise un ensemble de tâches à la demande d'un tiers.

La figure 2.3, présente l'interaction d'un agent avec son environnement et avec les autres agents du système. Ainsi cet agent est capable d'agir dans un environnement et de communiquer directement avec d'autres agents. Il est essentiel de noter que chaque agent possède ses propres ressources et compétences pouvant ainsi offrir des services. Ces éléments (les ressources, les compétences) sont inclus dans le comportement de l'agent, et en fonction de sa perception ce dernier essaie de satisfaire ses objectifs.

Ces explicitations permettent d'aborder le concept de système multi-agent qui est un système dans lequel des agents autonomes, rationnels et interactifs évoluent.

2.3.3 De l'agent vers les SMA

Du point de vue de l'intelligence artificielle distribuée (IAD), les SMA représentent un réseau d'entités qui travaille ensemble, pour trouver des solutions à des problèmes qui dépassent les capacités ou les connaissances individuelles de chaque entité. En effet chaque agent est associé à un sous-problème (sous-objectif). La coordination des activités de différents agents conduit à atteindre l'objectif collectif. Cet objectif est basé sur la coopération de plusieurs agents, ces derniers ont la capacité d'associer leurs efforts pour augmenter leur intelligence collective. La

propriété de coopération est nécessaire dans l'IAD tout comme la collaboration entre les agents qui se traduit par la communication et la négociation.

Les agents dans un SMA possèdent une vision limitée de leur environnement et des autres agents. Chacun n'inclut qu'une partie de la connaissance et des compétences du système. En effet et afin de parvenir à résoudre collectivement un problème, les agents doivent être dotés des divers mécanismes par exemple la coopération, la coordination et l'organisation :

- la coopération : dans (DURFEE et MONTGOMERY 1991), les auteurs ont défini quatre buts génériques pour réaliser une coopération entre un groupe d'agents : (1) augmenter la rapidité de résolution des tâches grâce à leur parallélisme; (2) accroître le nombre de tâches réalisables par le partage des ressources; (3) augmenter l'éventualité d'accomplir des tâches en les dupliquant (si possible) et en adaptant éventuellement des méthodes de réalisation différentes; (4) diminuer l'interférence entre les tâches en esquivant les interactions défavorables. Dans ce contexte, la coopération est essentielle quand l'agent a besoin d'aide pour atteindre ses objectifs. Le concept de coopération peut éventuellement être statique ou dynamique. Dans le premier cas, la distribution des tâches est effectuée dès la conception du SMA. Dans le deuxième cas, c'est un processus de coopération adéquat, mis en place entre les agents et la distribution des tâches, est géré par un mécanisme d'offre et de demande (KAMOUN 2007).
- la coordination : le concept de coordination est également essentiel pour maintenir cohérent le fonctionnement global du système. Ce concept est lié au concept précédent. C'est-à-dire lorsqu'un groupe d'agents coopère ensemble pour résoudre un problème collectivement, ils partagent les mêmes ressources et chacun d'entre eux contribue à la résolution d'une partie du problème. En effet, ils doivent finaliser des tâches liées au problème (à résoudre) et ainsi coordonner leurs actions. C'est à ce niveau que l'importance de la coordination surgit car les tâches de coordination ne sont pas directement liées à la résolution du problème mais elles permettent au SMA de fonctionner d'une manière cohérente. Par conséquent, le concept de coordination au sein d'un SMA offre un gain de temps, évite les conflits entre les agents et augmente la performance du système (MAMEI et ZAMBONELLI 2006).
- l'organisation : dans une activité collective, les agents doivent interagir, collaborer et bien s'organiser pour atteindre un objectif global. L'organisation devient donc nécessaire à la fois au niveau de l'action réalisée et au résultat de cette dernière. Selon (GUTKNECHT 2001), l'organisation dans un SMA est primordiale et elle peut contribuer autant qu'un outil de conception. Dans (JACQUES 1995) l'auteur a défini l'organisation comme le cadre dans lequel les agents, les ressources, les tâches et les buts coexistent.

L'environnement représente l'espace commun des agents. Il est le centre des interactions de ces agents. Il est ainsi le contexte dans lequel les agents évoluent. Selon (WOOLDRIDGE, JENNINGS et KINNY 2000), un environnement peut être accessible/non accessible; déterministe/non déterministe; discret/continu; statique/dynamique :

- accessible/non accessible : accessible (observable) si l'agent peut déterminer l'état de l'environnement et par la suite peut effectuer une action. Si l'environnement est inaccessible (non observable), dans ce cas l'agent ne possède qu'une connaissance partielle de son environnement. Il faut donc qu'il soit doté de moyens des mémorisations afin d'enregistrer

les modifications qui sont survenues ;

- déterministe/non déterministe : le futur état d'un environnement déterministe est fixé par son état courant et les actions de l'agent ;
- discret/continu : l'environnement est discret si le nombre d'états et d'actions de l'agent est fini ;
- statique/dynamique : l'environnement est statique si et seulement si ce dernier n'évolue pas pendant la prise de décision de l'agent.

Les problèmes les plus complexes sont souvent modélisés avec des environnements non accessibles, non déterministes, continus, dynamiques et où les agents n'ont accès qu'à une partie de l'état de l'environnement. Pour ce type de problème, les agents doivent former et entretenir une représentation locale, cela garantit la robustesse de leurs actions au cours du temps (puisque l'environnement peut évoluer durant leur phase de décision). Le cas des systèmes hospitaliers nous place dans ce type de problématique puisqu'il est à la fois non accessible, non déterministe, continu et dynamique (ZGAYA et HAMMADI 2016). L'approche SMA a également été utilisée pour résoudre des problèmes dans d'autres domaines tels que le transport (BOK, TAVASSZY et THOEN 2020), (ZOLFPUR-AROKHLO et MASHINCHI 2016) et l'économie (ZHAO, YU et ZHAO 2009). Dans (BOK, TAVASSZY et THOEN 2020), les auteurs ont développé un modèle multi-agent pour le transport de marchandises en milieu urbain. Dans ce modèle, ce sont les agents qui prennent les décisions logistiques (stratégiques, tactiques et opérationnelles) du marché de transport des marchandises. Les résultats de cette étude ont conduit à une augmentation de l'efficacité logistique : une plus grande répartition du poids par tournée (voyage), et donc une diminution du nombre de tournées à vide (sans chargement). De même dans (HALINKA, RZEPKA et SZABLICKI 2015), les auteurs utilisent un SMA pour améliorer l'automatisation et la protection des réseaux électriques. Cela a permis une augmentation considérable de l'exactitude de l'identification de l'état du courant alternatif dans le réseau et la fiabilité de l'acquisition des données.

2.3.4 L'approche multi-agent dans le domaine de la santé

Le système de santé est caractérisé par une prise de décision et une gestion partagée et distribuée de soins, ce qui nécessite une communication complexe et diversifiée entre les professionnels soignants (NEALON 2003). L'utilisation des entités autonomes, intelligentes, pro-actives et collaboratives qui interagissent dans un environnement distribué, pourrait apporter de l'aide à la décision efficace pour les problèmes hospitaliers.

Une récente étude (SHAKSHUKI et REID 2015) a souligné le potentiel des SMA dans le domaine de la santé par rapport aux logiciels classiques (modélisation centralisée). Cette étude montre que l'utilisation d'un SMA offre une valeur ajoutée niveau de la réutilisabilité, la fiabilité, la flexibilité, la robustesse et l'adaptabilité.

Dans la littérature, plusieurs études considèrent le paradigme SMA comme une approche puissante et efficace pour la modélisation et la résolution des problèmes de soins. Dans (LIN et al. 2013), une modélisation à base d'agents a été mise en œuvre dans un service de soins à Taïwan, le modèle a été construit et validé sur une base de données statistiques. Les résultats ont montré que le taux d'erreur moyen est de 3,09% (4,48% en ambulatoire et 0,88% en hospitalisation).

Avec le développement de la technologie informatique et l'architecture des systèmes d'information hospitaliers, une conception de haut niveau est nécessaire. Les auteurs dans (LI et HUANG 2016) expliquent qu'une modélisation (architecture) axée sur les agents est préférable à d'autres modèles traditionnels.

Le paradigme multi-agent n'est pas seulement employé pour la modélisation des systèmes complexes, il est également employé pour l'optimisation et l'ordonnancement de ces systèmes (sur la base d'une modélisation distribuée multi-agent). Par exemple, les auteurs dans (BENHAJJI, ROY et ANCIAUX 2015) ont implémenté un SMA pour améliorer la planification et le contrôle du flux patient dans les établissements de soins. Leur approche est basée sur une architecture à deux niveaux (les patients et les ressources partagées). L'objectif principal de cette architecture est de faire du patient (représenté par un agent) le principal acteur de son propre parcours de soins. Ainsi, l'agent "patient" peut négocier avec un agent "ressources personnel soignant" pour résoudre les problèmes éventuels d'ordonnancement des tâches de soins liés à son parcours médical. Dans (REID et SHAKSHUKI 2017), les auteurs utilisent un SMA pour améliorer la qualité de vie des personnes âgées. L'architecture multi-agent ainsi mise en œuvre est capable d'enregistrer et de diffuser un ensemble d'informations biomédicales des patients âgés au profit du personnel soignant. Le système permet de surveiller les signaux biologiques des patients et donc intervenir rapidement selon leur évolution. La surveillance des données est réalisée en interconnectant des capteurs sans fil sur le corps humain, avec un appareil compatible au système d'exploitation Android permettant de capturer des données. Une fois capturées, les données sont examinées par un agent logiciel et stockées pour une utilisation ultérieure. L'approche multi-agent est également utilisée dans le domaine de la santé pour aider le personnel soignant à prendre des décisions cliniques (TABOADA et al. 2011), (SHEN et al. 2015). Ces entités autonomes sont capables de planifier, allouer et coordonner les patients, les ressources, les traitements et les professionnels de santé (VERMEULEN et al. 2007). De même, les SMA ont été employés dans les systèmes d'assistance à l'autonomie à domicile principalement pour les personnes âgées (PARK, CHO et KIM 2016). Dans ce cas, les agents logiciels permettent (entre autres) la coopération entre le patient et l'établissement de santé (e.g. la consultation à distance, la médecine personnalisée, etc.).

Dans ce cadre, diverses études associent l'approche multi-agent non seulement au concept d'optimisation (le SMA combiné aux heuristiques, métaheuristiques et méthodes hybrides) mais aussi au concept d'apprentissage (apprentissage automatique, apprentissage profond, apprentissage par renforcement). Cette alliance a pour objectif d'améliorer le processus de soins, la planification des ressources, l'optimisation de la prise en charge, etc. (POLAP, SRIVASTAVA et YU 2021), (ALELAIWI 2020).

2.4 Le concept et les approches d'optimisation

La recherche opérationnelle (RO) est apparue pendant la Seconde Guerre Mondiale comme une initiative utilisant les mathématiques et l'informatique pour aider les planificateurs militaires dans leurs décisions (FORTUN et SCHWEBER 1993). Aujourd'hui, la RO est largement déployée dans plusieurs domaines comme le transport, la chaîne d'approvisionnement, l'énergie, les finances et l'ordonnancement. Elle permet d'aider les décideurs à résoudre des problèmes combinatoires, aléatoires ou concurrentiels. Dans ce cadre, l'optimisation est considérée comme un ensemble d'opérations effectuées pour obtenir un résultat idéal. Ce concept est primordial

dans de nombreux domaines et c'est pourquoi les algorithmes d'optimisation font de plus en plus partie de sujets d'actualité. Optimiser permet à la fois de mieux gérer les flux physiques du système (flux des patients par exemple) et mobiliser et coordonner les différents services. Dans cette section, nous présentons les différents types de problèmes d'optimisation avec des exemples de problèmes d'optimisation dans le domaine de la santé.

2.4.1 Les problèmes d'optimisation

Un problème d'optimisation $P(X, f)$, est défini par un ensemble réalisable non vide X et une fonction objectif f , les éléments de X sont dits solutions réalisables. La résolution d'un problème d'optimisation $P(X, f)$ revient à trouver une solution parmi les solutions réalisables qui permet de minimiser ou de maximiser f . Pour un problème de maximisation par exemple, il s'agit de trouver une solution $x^* \in X$ telle que $f(x) \leq f(x^*)$ pour chaque élément x dans X . Cette solution notée par $x(X, f)$ est dite optimale.

L'ensemble réalisable X est généralement défini dans \mathbb{R}^n avec n un entier positif qui désigne la taille du problème. Cet ensemble X peut éventuellement être délimité par des contraintes correspondant habituellement à un système d'inégalités.

2.4.1.1 Les problèmes d'optimisation discrète

Les problèmes d'optimisation discrète présentent une classe de problèmes d'optimisation particulièrement étudiée dans la littérature. Lorsque toute ou une partie des variables de décision appartiennent à l'ensemble des entiers, le problème d'optimisation est dit discret. Un problème d'optimisation combinant des variables discrètes et des variables continues est dit mixte. Les ensembles réalisables des problèmes d'optimisation (discrète, continue, mixte) peuvent être infinis. Nous présentons dans la prochaine section les problèmes d'optimisation combinatoire qui sont des problèmes connus NP-difficiles bien qu'ils soient définis sur des ensembles réalisables finis (DAOUDI 2012).

2.4.1.2 Les problèmes d'optimisation combinatoire (POC)

Les POC sont des problèmes d'optimisation dont les ensembles réalisables sont finis mais combinatoires. Le nombre de solutions réalisables des POC augmente exponentiellement en fonction de la taille du problème. Généralement, l'ensemble réalisable X d'un POC est défini comme un sous-ensemble de l'ensemble des parties d'un ensemble fini d'éléments E , $E = \{e_1, \dots, e_n\}$ et $X \subseteq 2^E$. Un POC peut également être formalisé comme un problème d'optimisation en variables binaires. Ce qui implique l'association d'une variable x_i à tout élément de e_i de E , tout sous-ensemble de E peut être représenté par un vecteur $x = (x_1, \dots, x_n)$, avec $x_i = 1$ si $e_i \in$ au sous-ensemble et $x_i = 0$ sinon.

Il est peu probable qu'il existe un algorithme polynomial permettant de résoudre ce type du problème en un temps de calcul (raisonnable) proportionnel à N^n avec N le nombre de paramètres inconnus du problème, et n est un entier tels que le problème de coloration de graphe et le problème de routage de véhicules. C'est pourquoi les POC sont connus comme des problèmes à complexité exponentielle dits NP-difficiles. Ce qui fait la particularité des POC, c'est qu'en plus des formulations en programmes mathématiques, il est souvent possible de les formuler comme des problèmes de la théorie des graphes. Il est essentiel de différencier la difficulté de résolution et la difficulté de formulation des problèmes. La plupart des POC sont

connus pour leur complexité liée à la résolution des problèmes et non celle de formulation, le meilleur exemple à évoquer ici c'est le problème du voyageur de commerce (TSP). Ainsi, pour résoudre un POC, les chercheurs ont tendance à se référer aux méthodes approchées, alors le choix sera entre une heuristique ou une métaheuristique (cf. section 2.4.2.2).

2.4.1.3 Les problèmes d'optimisation combinatoire multi-objectif

Dans cette section, nous rappelons dans un premier temps les notions préliminaires de l'optimisation multi-objectif. Ensuite, nous présentons les caractéristiques d'un POC multi-objectif.

Un problème d'optimisation multi-objectif, par opposition à un problème d'optimisation mono-objectif, est un problème qui contient plusieurs objectifs avec couramment un ensemble de critères contradictoires à satisfaire. Un POC multi-objectif peut être écrit sous la forme du :

$$\min_{x \in X} g(x) = (g_1(x), \dots, g_p(x)) \quad (2.1)$$

où p représente le nombre de fonctions objectifs ($p \geq 2$), g l'ensemble des critères à optimiser et X un ensemble combinatoire. Le but d'un POC multi-objectif est de réussir à optimiser simultanément plusieurs éléments de la fonction objectif et également de trouver les meilleures solutions dans une multitude de solutions possibles. Ces solutions sont appelées *solution de Pareto* (COLLETTE et SIARRY 2011). Après avoir trouvé les solutions du problème multi-objectif, il faut choisir une solution dans cet ensemble. La solution sélectionnée traduit les compromis effectués par le décideur vis-à-vis des différentes fonctions objectif.

2.4.2 Les méthodes de résolution des problèmes d'optimisation

Étant donné l'importance des problèmes d'optimisation, de nombreuses méthodes de résolution sont proposées dans la littérature (figure 2.4) dans les domaines de recherche opérationnelle (RO) et de l'intelligence artificielle (IA). Une grande variété et des différences remarquables au niveau du principe, de la stratégie et de la performance ont été discernés. Cela a permis d'identifier deux classes principales : la classe de méthodes exactes et la classe de méthodes approchées. Plusieurs études utilisent l'hybridation de ces deux méthodes pour la résolution des problèmes d'optimisation combinatoire (ZULKEPLI et ELDABI 2015). Dans ce cadre, une pseudo classe qui associe les deux précédentes classes est apparue dite hybride.

2.4.2.1 Les méthodes exactes

Les méthodes exactes garantissent non seulement la complétude de la résolution mais encore l'optimalité de la solution. Néanmoins, une méthode exacte est généralement gourmande en termes de temps de calcul et d'espace mémoire (HACHIMI 2013). Ces méthodes ne permettent donc pas de trouver une solution optimale d'un POC en un temps raisonnable pour des instances de grande taille. Dans la littérature, il existe de nombreux algorithmes exacts, par exemple : la programmation dynamique, les algorithmes de séparation et évaluation (Branch and Bound, Branch and Cut, Branch and Price, Branch and Cut and Price), l'algorithme de Johnson (pour résoudre les problèmes d'ordonnancement), etc. Notre vocation n'est plus de relater le principe de chacune de ces méthodes exactes mais plutôt d'en citer quelques unes dans ce qui suit.

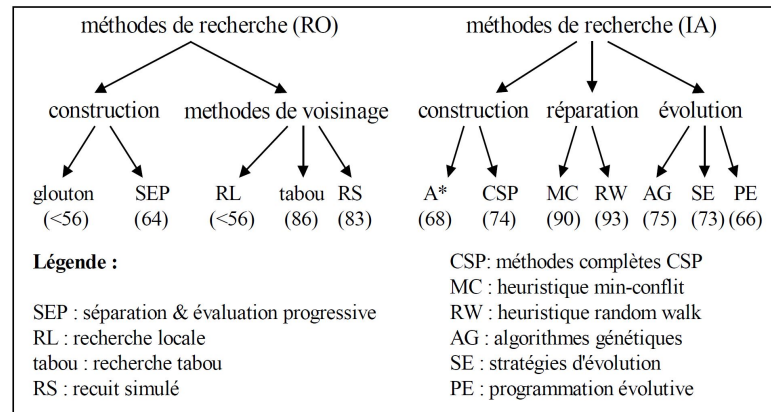


FIGURE 2.4 – Classement des méthodes de résolution, (HAO, GALINIER et HABIB 1999)

- **La méthode Branch and Bound** : la méthode par séparation et évaluation connue sous le nom *Branch and Bound* en anglais est l'une des méthodes exactes qui permettent la résolution des problèmes d'optimisation NP-difficiles (BUNEL et al. 2020). Cette méthode est basée sur deux étapes : la séparation et l'évaluation. Grâce à ces étapes, la méthode Branch and Bound permet une bonne exploitation de l'espace de recherche et donc l'aboutissement à la solution optimale plus rapidement que d'autres méthodes exactes (Ho, LIU et ZABINSKY 2019).

Cette méthode est basée sur la technique « de diviser pour régner ». La division permet de dissocier l'ensemble de solutions réalisables en sous-ensembles. L'évaluation sert à borner l'intervalle de recherche, filtrer et ainsi éliminer les sous-ensembles qui ne contiennent pas de solution optimale.

L'efficacité de cette méthode a poussé les chercheurs à réaliser plusieurs améliorations, ce qui a conduit à la naissance d'autres algorithmes : Branch and Cut (PADBERG et RINALDI 1991), Branch and Price (BARNHART et al. 1998), Branch and Cut and Price (BARNHART, HANE et VANCE 2000).

- **La méthode de Coupes Planes** : connue sous le nom « Cutting Plane » en anglais. Cette méthode a été introduite en 1986 par (SCHRIJVER 1986) et appliquée pour la résolution de problèmes d'optimisation linéaire. Pour pouvoir résoudre un problème d'optimisation combinatoire avec cette méthode, il faut éliminer la majorité des contraintes puis résoudre le problème relaxé. La solution optimale appartient à l'ensemble de solutions réalisables de cette relaxation.

2.4.2.2 Les méthodes approchées

Les méthodes approchées sont des méthodes qui perdent la complétude pour gagner en efficacité. En effet, elles représentent une alternative très avantageuse pour traiter les problèmes d'optimisation de grande taille si l'optimalité n'est pas fondamentale. Ces méthodes approchées peuvent être catégorisées en deux classes : les heuristiques et les métaheuristiques.

Les heuristiques, sachant qu'elles sont situées à mi-chemin entre les méthodes exactes et les métaheuristiques, elles permettent de donner des solutions réalisables de qualité acceptable

(souvent très) proches de l'optimal et déterminées en un temps raisonnable (complexité polynomiale). Face à des méthodes exactes avec une complexité temporelle excessive (particulièrement avec les problèmes de grande taille) et à la spécificité des heuristiques au problème donné, les métaheuristiques construisent une solution moins exigeante. En effet, elles sont considérées comme des méthodes puissantes et générales (REEVES 1993),(AARTS, AARTS et LENSTRA 2003). Elles sont donc applicables sur une grande disparité de problèmes d'optimisation (les POC et également elles peuvent s'adapter aux problèmes continus) de différentes complexités. En plus, elles permettent de donner des solutions de très bonnes qualités (pas forcément optimales) en un temps de calcul raisonnable.

Les métaheuristiques sont représentées principalement par *les méthodes de voisinage* comme la recherche tabou et le recuit simulé, et *les algorithmes évolutifs* comme l'algorithme génétique et les stratégies d'évolution. Ces algorithmes sont apparues à partir des années 1980, avec un objectif commun proposer des solutions approchées pour les problèmes d'optimisation difficiles.

1. **Les méthodes de voisinage** : une méthode de voisinage débute avec une seule solution initiale, puis elle effectue un processus itératif qui réside à remplacer la solution courante par l'une de ses voisines en tenant en compte de la fonction de coût. Le but de ces remplacements locaux est d'explorer le voisinage de la solution actuelle et d'améliorer ainsi peu à peu sa qualité au cours des diverses itérations. Ce processus itératif s'arrête si et seulement si la condition d'arrêt est réalisée. Cette condition d'arrêt est souvent liée au nombre limite d'itérations ou à un objectif à atteindre. La qualité de la solution finale dépend essentiellement des remplacements effectués par les opérateurs de voisinage ainsi que de la stratégie de parcours de ce voisinage. Il est important de noter que le mauvais choix de la solution initiale peut considérablement dégénérer la qualité du processus de recherche de la solution optimale. Ce choix peut donc être accompagné par un algorithme d'optimisation à part entière afin de booster le processus de recherche de l'algorithme principal. Un des atouts des méthodes de voisinage réside particulièrement dans l'éventualité de contrôler le temps de calcul. L'utilisateur est donc libre d'arrêter l'exécution au moment qu'il souhaite. Dans la littérature, de nombreuses méthodes à base de solution unique ont été présentées : le recuit simulé (ABRI, BOUKLI-HACENE et BENDIMERAD 2005), la recherche tabou (TABIA et al. 2014), la recherche à voisinage variable (TODOSIJEVIĆ 2015), etc. Dans ce qui suit nous présentons quelques-unes de ces méthodes :

- **Le Recuit Simulé (RS)** : la méthode RS a été introduite par (KIRKPATRICK, GELATT et VECCHI 1983). Elle s'inspire du processus de recuit physique, ce processus a été utilisé en métallurgie. Les métallurgistes chauffent à blanc le métal, ensuite ils laissent l'alliage se refroidir lentement afin de parvenir à un alliage sans faille. Une baisse soudaine et rapide de la température d'un liquide provoque une reproduction d'un optimum local (une structure amorphe). Par contre, une baisse progressive de la température du liquide permet de parvenir à un optimum global (une structure parfaitement construite). Les origines de cette métaheuristique remontent aux expériences réalisées par (METROPOLIS et al. 1953), dont le principe est le suivant : (1) démarrer par une solution initiale s générée de manière stochastique ; (2) attribuer une valeur initiale à la température T ; (3) calculer la fonction coût (fitness) $f(s)$ de la solution initiale s ; (4) générer une solution s' voisine de s ; (5) calculer la fitness $f(s')$ de s' ; (6) calculer l'écart de qualité entre les deux solutions s et s' comme suivant : $\Delta(f) = f(s') - f(s)$. Si $\Delta(f) \geq 0$ alors $s \leftarrow s'$. Sinon générer un nombre aléatoire $r \in [0, 1]$. Si $r < \exp(-\frac{\Delta(f)}{T})$ alors $s \leftarrow s'$.

Cette métaheuristique basée sur la recherche de voisinage est un algorithme simple,

facile à implémenter et à adapter à un grand nombre de problèmes. Par exemple : problème de sac à dos, problème du voyageur de commerce, problème de traitement d'image, etc. Parmi les avantages du RS, c'est le fait qu'il permette d'éviter l'optimum local et ainsi proposer des solutions de bonne qualité. Cependant, cet algorithme contient plusieurs paramètres à ajuster ce qui rend le temps de calcul lent pour les problèmes de grande taille.

- **La Recherche Tabou (RT)** : la RT a été introduite par (GLOVER 1986), elle est inspirée de la biologie. Cette métaheuristique est une méthode de recherche locale avancée, elle fait appel à un ensemble de règles et de mécanismes généraux pour guider la recherche de manière intelligente (GLOVER et LAGUNA 1997). Contrairement à la RS qui génère de manière aléatoire une seule solution voisine s' à chaque itération, la RT observe de façon attentive un échantillonnage de solutions et retient ainsi la meilleure s' même si cette dernière est moins bonne que s . Ainsi, la RT ne s'arrête pas au premier optimum trouvé. En revanche, cette stratégie, peut créer un phénomène cyclique (par exemple revisiter des solutions parcourues plusieurs fois, $s \rightarrow s' \rightarrow s \rightarrow s' \dots$). Afin d'interdire ce type de phénomène, la RT suggère l'utilisation d'une mémoire à court terme qui stocke les k dernières solutions rencontrées pour éviter les visites de ces k solutions dans les itérations suivantes. Cette mémoire, nommée *la liste tabou*, interdit tous les cycles de longueur inférieure ou égale à k . Cette liste fonctionne comme une pile FIFO c'est-à-dire la solution la plus ancienne sera éliminée pour laisser la place à la prochaine solution rencontrée. La taille de la pile dépend du problème à résoudre et peut varier au cours de la recherche. Pour arrêter une RT, il faut, soit fixer un nombre limite d'itérations comme condition d'arrêt, soit fixer un temps limite après lequel la recherche doit s'arrêter.

Comme le RS, la RT a été largement employée pour la résolution des problèmes d'optimisation difficiles comme le problème de tournée de véhicules et le problème de coloration de graphes. Cette métaheuristique est à la fois facile à mettre en place, donne généralement de bons résultats et évite de se faire piéger dans des optima locaux.

2. **Les méthodes évolutives** : les algorithmes évolutifs sont des algorithmes stochastiques basés sur le principe du processus d'évaluation et d'adaptation des organismes dans un environnement naturel. Ces algorithmes s'adaptent à la résolutions des problèmes qui ont un grand nombre de dimensions et de nombreux optima locaux dans leur espace de recherche (DE JONG et SPEARS 1993). Les trois éléments de base d'un algorithme évolutif sont : (1) une population composée de plusieurs individus ; (2) un mécanisme d'évaluation qui permet d'évaluer l'adaptation de chaque individu de la population envers son environnement extérieur ; (3) un deuxième mécanisme d'évaluation qui est constitué des opérateurs, ces opérateurs ont pour objectifs d'éliminer quelques individus afin de produire de nouveaux individus à partir des individus sélectionnés.

En effet, un algorithme évolutif commence toujours par une population initiale générée souvent aléatoirement. Ensuite, il réitère un cycle d'évolution constitué de trois phases séquentielles : (1) évaluer la qualité de chaque individu de la population grâce au mécanisme d'évaluation ; (2) sélectionner une partie des individus ; (3) composer de nouveaux individus par des recombinaisons d'individus sélectionnés. Ce processus cyclique prend fin quand la condition d'arrêt est vérifiée. Cette condition peut être par exemple un nombre maximum de cycles (générations).

La fonction d'adaptation et l'individu dans les méthodes évolutives correspondent respec-

tivement à la fonction d'évaluation et à la notion de configuration dans les méthodes de voisinage. Par conséquent, la notion de mécanisme d'évolution est proche de celle du mécanisme de parcours du voisinage. Par exemple, une itération d'une méthode de voisinage peut être traduite comme un mécanisme d'évolution portant sur une population réduite à un seul individu. En revanche, les opérateurs sont différents puisque l'algorithme évolutif contient un ensemble d'opérateurs tels que la sélection, la mutation et le croisement (HAO, GALINIER et HABIB 1999).

Ces algorithmes évolutifs ont été employés pour divers problèmes difficiles et complexes, y compris les problèmes d'optimisation continue ou combinatoire. Les algorithmes évolutifs les plus connus sont (présentés ci-dessous) : les algorithmes génétiques, la programmation évolutive et les stratégies d'évolution. Il existe deux points qui différencient ces algorithmes : (1) la manière avec laquelle ils représentent les données ; et (2) la façon de faire évoluer la population d'une génération à une autre (ZITZLER 1999).

- **Les Algorithmes Génétiques (AG)** : l'AG est une célèbre métaheuristique évolutionnaire. Il a été introduit par (HOLLAND JOHN 1975), ensuite (GOLDBERG 1989) a contribué à l'enrichir et à le faire évoluer. Cet algorithme utilise un vocabulaire similaire à celui de la biologie et de la génétique naturelle : gène, chromosome, individu, population et génération. L'AG a comme objectif d'optimiser la fonction coût (*fitness en anglais*) qui est développée par l'utilisateur. Pour ce faire, l'algorithme fait évoluer une population composée d'un ensemble d'individus (appelés aussi chromosomes), pendant un ensemble de générations jusqu'à la vérification du critère d'arrêt. Plusieurs critères d'arrêt sont possibles. Par exemple : le nombre de générations qui peut être fixé ou alors l'algorithme peut être arrêté lorsque la population n'évolue plus rapidement. Le passage d'une population à une autre se fait grâce aux opérations de sélection, de croisement et de mutation.

L'opérateur de croisement est binaire car il nécessite deux individus à croiser (les parents). Il permet ainsi de produire deux nouveaux individus (enfants). Dans la littérature, il existe différentes méthodes de croisement. Par exemple, le croisement à un point ou à plusieurs points (HOLLAND 1962), (REEVES 1995), le croisement partiellement tracé (*PMX, partially mapped crossover*) (GOLDBERG et LINGLE 1985), le croisement par ordre (*OX, order crossover*) (GOLDBERG 1989), le croisement par cycle (*CX, cycle crossover*) (OLIVER, SMITH et HOLLAND 1987) et le croisement par recombinaison d'arrêtes (*ERX, edge recombination crossover*) (WHITLEY, STARKWEATHER et FUQUAY 1989). L'opérateur de mutation est unaire car il consiste à modifier aléatoirement la valeur de certaines variables d'un seul individu.

L'universalité des AG pose des problèmes d'efficacité en pratique (BARNIER et BRISSET 1999). En outre, la version classique en tant que méthode d'optimisation est fondée purement sur des opérateurs « aveugles » ce qui explique une efficacité parfois moins bonne par rapport aux méthodes de voisinage. Pour remédier à ce problème, les auteurs dans la littérature proposent une technique permettant de *spécialiser* l'AG au problème traité. C'est-à-dire au lieu d'utiliser des opérateurs aléatoires, adapter les opérateurs de mutation et de croisement aux connaissances spécifiques du problème. Cette technique rend la recherche mieux guidée et par la suite plus efficace. Une autre piste attirante est proposée pour l'amélioration de l'efficacité de cette méthode. Cette piste consiste à combiner l'AG avec d'autres méthodes de résolution. Ce point est développé dans la section 2.4.2.3. En effet, les AGs spécialisés ou hybrides ont été appliqués dans des nombreux domaines (BLUM et al. 2011), (GÓRRIZ et al. 2006), (REN et SAN 2006).

- **La programmation évolutive (PE)** : cette méthode a été introduite par (FOGEL, OWENS et WALSH 1966). Le codage d'un tel algorithme dépend du problème à résoudre (FOGEL 1994). Par exemple, pour un problème d'optimisation dans le domaine des réels, les individus d'une population sont présentés par des vecteurs de réels. Ces algorithmes ont été conçus pour faire évoluer des structures d'automates à état fini sachant que ces automates sont choisis pour représenter les individus d'une population.
- **Les stratégies d'évolution (SE)** : elles sont introduites par (BACK 1996). Les SE ont été conçues à la base pour résoudre les problèmes d'optimisation continues. Semblable à, la programmation évolutive, cet algorithme n'utilise que la mutation et la sélection. Ces algorithmes ont été adaptés à l'optimisation combinatoire et ensuite ils ont été adoptés pour résoudre de nombreux problèmes (CARTWRIGHT 2004).

2.4.2.3 Les méthodes hybrides

Dans la littérature, les travaux de recherche dans le domaine de l'optimisation sont passés d'une approche plutôt axée sur les algorithmes à une approche davantage axée sur les problèmes. Ce qui a conduit à une conception croisée extrêmement fructueuse de multitudes d'algorithmes d'optimisation. Cette conception croisée a donné naissance à des algorithmes hybrides puissants. Ces derniers ont été obtenus en combinant des composants de plusieurs techniques d'optimisation différentes. En outre, l'hybridation ne se limite pas à la combinaison de différentes métaheuristiques ensemble, elle inclut également la combinaison des métaheuristiques avec des algorithmes exacts ou avec des heuristiques (figure 2.5). Par exemple, l'hybridation d'un algorithme évolutif (méthode basée sur la population) avec des méthodes de voisinage (méthode de recherche locale) est très répandue. Cette hybridation consiste à profiter pleinement, de la puissance de la recherche de méthodes de voisinage et de la recombinaison des algorithmes évolutifs sur une population de solutions. Ce type d'hybridation est appelé algorithme mémétique (MOSCATO 1999), (KRASNOGOR et SMITH 2005).

Les algorithmes hybrides sont certes parmi les méthodes les plus puissantes. En revanche, leur temps de calcul peut devenir excessif à cause par exemple du nombre d'individus manipulés dans la population. Pour remédier à cela, les chercheurs ont proposé deux pistes : le parallélisme et les systèmes distribués (TALBI, HAFIDI et GEIB 1997), (SILVA et al. 2018). Les méthodes hybrides ont permis de fournir d'excellents résultats pour divers problèmes de référence comme : le problème du voyageur de commerce (TSP) (FREISLEBEN et MERZ 1996), (JIANG et al. 2014) et le problème de la coloration du graphe (CHIUSANO et al. 1997), (BEĆIRSPAHIĆ, ĐULOVIĆ et NOSOVIĆ 2013), (LABED, AKRAM et CHIKHI 2018).

2.4.3 L'optimisation dans le domaine de la santé

Optimiser le réseau de soins dans les hôpitaux en général et dans la chaîne des urgences en particulier est un besoin de plus en plus présent aujourd'hui. La difficulté rencontrée dans l'optimisation de la chaîne logistique hospitalière réside dans la complexité des activités de soins. Cette complexité est due à la difficulté de mesurer efficacement la performance que l'on peut y associer et à la difficulté liée aux flux étudiés. C'est pourquoi, la mise en place d'un système de décisions hiérarchiques (stratégiques, tactiques et opérationnelles) est primordiale.

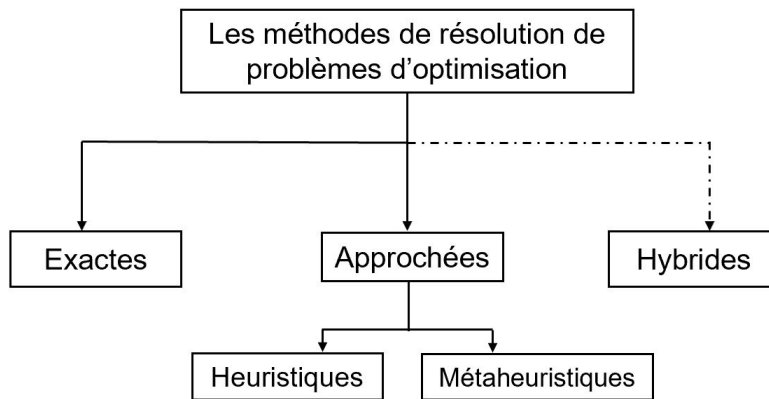


FIGURE 2.5 – Les méthodes de résolution

Chaque niveau de ce système hiérarchique est caractérisé par différents problèmes d'allocation des ressources avec des objectifs, des contraintes et des exigences propres (VISSERS, BERTRAND et DE VRIES 2001). L'objectif principal du premier niveau (long terme) est la répartition du budget et l'utilisation des ressources partagées entre les spécialités chirurgicales (BLAKE et CARTER 2002). Un des objectifs du deuxième niveau de décision (moyen terme) est l'allocation d'une salle d'opération pour chaque chirurgien (BELIËN et DEMEULEMEESTER 2007). Les principaux objectifs pour le niveau opérationnel (court terme et temps réel) concernent les coûts d'hospitalisation, le temps d'attente, l'utilisation de salles d'opération, les préférences des patients et du personnel (JEBALI, ALOUANE et LADET 2006). Dans ce cadre, l'intégration des approches innovantes basées sur les nouvelles technologies peut être un moyen pertinent pour gérer efficacement la chaîne logistique hospitalière.

Dans la littérature, il existe une vaste quantité de travaux appliqués dans le domaine de la santé en général (VOLLAND et al. 2017), (HEJAZI, BADRI et YANG 2019), (BALLARD et SCHWARZ 2019) et dans les services des urgences en particulier (LONG, KOYFMAN et GOTTLIEB 2019). Concernant les services des urgences, les travaux peuvent être distingués en quatre grandes catégories : (1) la gestion des services des urgences (CABRERA et al. 2012), (LEO et al. 2016); (2) l'amélioration des conditions de travail des professionnels soignants (WONG, XU et CHIN 2014), (SVIRSKO et al. 2019); (3) l'aide à la décision (URIARTE et al. 2017), (YOUSEFI et al. 2018); (4) l'anticipation et la résolution des problèmes liés à la tension aux urgences (HUSSEIN et al. 2017), (WANG et al. 2018c), (LEE et LEE 2020). Ces catégories sont interconnectées puisque, les trois premières de celles-ci aident forcément à anticiper les situations de crise dans les urgences. Le phénomène de la tension est à l'origine de plusieurs difficultés dans les SU. Ces difficultés peuvent être mesurées avec des indicateurs de performance tels que le temps d'attente, les durées de séjours, le nombre d'abandons des SU, la réorientation des ambulances, etc. Dans ce cadre, une récente revue (VANBRABANT et al. 2019) propose un examen complet des indicateurs de performance clés, tout en indiquant les relations entre eux et fournissant ainsi des informations sur les options d'amélioration.

2.4.3.1 Les contraintes liées aux ressources humaines et matérielles

Actuellement, les établissements de soins sont confrontés à une pénurie de ressources qui sont non disponibles ou coûteuses. Le taux d'occupation des ressources humaines en général (les médecins, les infirmiers, le personnel logistique, le personnel administratif, etc.) et des infirmiers et des médecins en particulier présente un indicateur clé des engorgements des urgences. Selon (SINREICH et JABALI 2007), les situations des engorgements sont propres à chaque SU et au taux d'occupation de ses ressources humaines. Néanmoins, l'affectation des ressources a une influence directe sur le taux d'admission des patients. Différents modèles de simulation sont développés pour modéliser les besoins en termes de capacité dans les urgences (GUL et GUNERI 2012), (GHANES et al. 2014). Les auteurs dans (WENG et al. 2011) ont adopté une technique de simulation du système pour optimiser l'allocation des ressources humaines dans les urgences. Grâce à cette méthode, la performance des urgences a augmenté de 8%. En outre, une allocation appropriée d'infirmiers et de médecins peut contribuer à une réduction du temps d'attente aux urgences.

L'équipement des urgences se compose entre autres, des appareils de radiologie, des box, des lits, de matériels de laboratoire, etc. Seules des ressources limitées peuvent créer des engorgements, l'utilisation des médicaments ou des appareils de prélèvement sanguin ne représentent pas des indicateurs clés de performance pertinents. Par contre, certains travaux considèrent que le taux d'occupation des lits dans les urgences est un indicateur clé des situations de crise (BELCIUG et GORUNESCU 2015), (HE et al. 2019). Dans ce cadre, divers chercheurs se sont intéressés à ces indicateurs. Par exemple dans (CHAVIS et al. 2016), les auteurs présentent un modèle de simulation à événement discrets d'un système hospitalier qui est composé, d'un service des urgences, d'unités de court séjour et d'unités d'hospitalisation. Ces travaux ont affirmé que les situations de crises dans les urgences dépendent essentiellement des unités hospitalières en aval. Pour conclure, le problème de planification dans les urgences devient de plus en plus complexe. Cela est dû à la dépendance entre les trois éléments de la chaîne des urgences (*amont-intra-aval*) et à son environnement stochastique. Par conséquent, pour résoudre le problème d'affectation, il faut à la fois une affectation efficace des ressources appropriées aux tâches de soins et une vue globale et rationnelle de l'avancement de ces tâches. Cette vision globale peut contribuer à l'amélioration de la chaîne des urgences et ainsi anticiper les situations de crise.

2.4.3.2 Les contraintes liées à la nature des SU

Les SU présentent l'unité de soins aigus annexée à un établissement de santé afin de fournir des traitements médicaux primaires aux patients dont l'état nécessite une intervention immédiate. Ces unités semi-autonomes sont ouvertes et dotées de personnels pluridisciplinaires 24 heures par jour et 365 jours par an, y compris les jours fériés. Lors d'une situation de crise, les SU se trouvent face à diverses difficultés telles que : un flux important de patients dans les zones de traitements, une prolongation des temps d'attente ce qui implique forcément une longue durée de séjours, des soins médicaux dans les couloirs du SU, etc. Pour faire face à ces situations, plusieurs chercheurs accordent une grande attention à ce problème. Ainsi, dans (HUSSEIN et al. 2017), (WANG et al. 2018c) les auteurs expliquent et analysent les causes de tension dans les urgences (en Égypte et à Pékin). Ces travaux indiquent que les principales causes de la tension résident dans :

1. le grand nombre de patients qui se présentent aux urgences pour des maladies mineures ;
2. l'aval des urgences c'est-à-dire l'incapacité de transférer rapidement les patients dont l'hospitalisation est nécessaire d'après les urgentistes (d'où la nécessité de réserver un lit

dans le service adéquat en aval des urgences).

Vu le nombre faible de lits disponibles aux urgences et face au nombre élevé de patients qui peuvent s'y trouver simultanément à un moment donné, les SU se trouvent forcément dans une situation de crise.

Par contre, dans (VANBRABANT et al. 2019) ces auteurs indiquent qu'il est difficile de saisir tous les aspects de la tension dans un seul indicateur. Dans ce contexte, afin de mesurer le degré de tension dans les urgences, il est possible d'utiliser le score NEDOCS (national emergency department crowding scale)¹ ou un indicateur défini par l'utilisateur (en fonction de type de SU).

2.5 L'apprentissage automatique

L'objectif de l'IA est de développer des agents dotés d'excellentes capacités de prise de décision dans des environnements complexes et incertains. Dans ce contexte, l'apprentissage automatique (*machine learning en anglais*) s'est développé de manière spectaculaire au cours des dernières années et a connu de nombreuses applications dans divers domaines industriels. Le but de ce type d'apprentissage est d'implémenter des algorithmes pour rendre les ordinateurs capables d'acquérir de l'expérience à partir de données pour résoudre des problèmes de prédiction. L'apprentissage automatique consiste à modéliser une fonction k afin de fournir la sortie souhaitée (output) grâce aux données d'entraînement qui ont été fournies comme des données d'entrée (input) $k : X \rightarrow Y$. Dans la littérature, l'apprentissage automatique est divisé en trois grandes classes :

- **L'apprentissage supervisé** : est un apprentissage par instruction, il repose sur l'utilisation des données étiquetées. Pour un échantillon d'entrée de taille n , chaque X_i est étiquetée par une sortie Y_i et chaque X_i a un objectif T_i . Le modèle apprend ainsi les corrélations de la data set (X, T) afin de pouvoir associer correctement chaque entrée X_i à sa sortie Y_i . Cette classe d'apprentissage est appliquée dans l'imagerie médicale, par exemple pour résoudre le problème de reconstruction d'imagerie photoacoustique (WANG et al. 2018b).
- **L'apprentissage non supervisé** : est un apprentissage par évolution, il ne repose pas sur l'utilisation des données étiquetées, donc la sortie n'est pas connue a priori. L'exemple le plus connu de ce type d'apprentissage est le partitionnement de données (*cluster analysis ou clustering en anglais*) (PAN, SHEN et LIU 2013).
- **L'apprentissage par renforcement** : ce type d'apprentissage est basé sur l'interaction de l'agent avec son environnement. C'est-à-dire que l'agent apprend à prendre de bonnes décisions de façon autonome en interagissant avec son environnement (HAN et al. 2021). Comment formaliser l'interaction agent-environnement ? Des éléments de réponse à cette question se trouvent dans la section 2.5.2. Dans ce qui suit nous détaillons davantage ce type d'apprentissage.

1. nedocs.org

2.5.1 L'apprentissage par renforcement

L'apprentissage par renforcement est un sous domaine de l'apprentissage automatique. Le processus d'apprentissage de l'agent est entièrement dirigé par un système de récompenses (qui peut être positif ou négatif) et d'observations obtenues depuis son environnement. Des récompenses (appelées aussi renforcements) sont accordées à l'agent après chaque action effectuée dans l'environnement. Un épisode désigne l'ensemble des transitions qu'un agent effectue depuis un état initial vers un état final de l'environnement. Le but de l'agent est d'améliorer son comportement afin de maximiser ses récompenses lors des épisodes et de converger donc vers une politique optimale. L'espace d'états observables et l'espace des actions, définissent respectivement les états dans lequel un agent peut se trouver et les actions qu'il peut réaliser.

La principale caractéristique de l'apprentissage par renforcement est de trouver l'équilibre entre l'exploration et l'exploitation. L'agent doit à la fois exploiter ses connaissances antérieures pour collecter des récompenses. Il doit aussi explorer l'environnement pour trouver la meilleure action pour l'avenir (ALPAYDIN 2020). Ce type d'apprentissage est appliqué dans plusieurs domaines par exemple : la robotique (SCHULMAN et al. 2015), (APOLINARSKA et al. 2021), l'économie (DENG et al. 2016), (TSANTEKIDIS, PASSALIS et TEFAS 2021), les jeux vidéos (KAMALDINOV et MAKAROV 2019), (CHEN, YUAN et LI 2019), la santé (LIU et al. 2019), (CORONATO et al. 2020) et dans d'autres domaines comme présenté dans (ERNST, GLAVIC et WEHENKEL 2004).

Les auteurs dans (KOBER, BAGNELL et PETERS 2013) scindent l'apprentissage par renforcement en deux approches : une approche basée sur la valeur et une approche basée sur les politiques. La première approche basée sur la valeur essaie d'obtenir une politique optimale en trouvant des fonctions de valeur optimale. Ces fonctions sont mises à jour à l'aide de la récompense immédiate et à la valeur actualisée de l'état suivant. Il existe plusieurs méthodes basées sur cette approche parmi lesquelles : Q-learning (MU et al. 2019), SARSA (ZHAO et al. 2016) et TD-learning (TAYLOR et STONE 2005). La deuxième approche basée sur les politiques étudie et applique une politique paramétrée qui maximise la récompense actualisée cumulative. Parmi les techniques utilisées pour rechercher les paramètres optimaux : policy gradient (SILVER et al. 2014), espérance maximisation (expectation-maximization) (BOGERT et al. 2016), et les algorithmes évolutifs (HUANG et al. 2020). L'hybridation de ces deux approches est appelée approche acteur-critique (*actor-critic*) (HEREDIA et MOU 2019).

En effet, l'apprentissage par renforcement a connu un succès remarquable grâce à son adoption rapide des techniques d'apprentissage profond (*deep learning en anglais*) et sa puissance de calcul croissante. Par exemple, dans (LEE et LEE 2020), les chercheurs utilisent l'apprentissage par renforcement profond pour ordonnancer les patients dans un service d'urgences. Ainsi, diverses études récentes ont conclu que l'intégration du réseau de neurones profonds aux algorithmes d'apprentissage par renforcement permet de produire des bonnes performances. Ces performances sont même meilleures que les performances humaines à certaines tâches comme par exemple dans le cadre du jeu Go (SILVER et al. 2016). En revanche, d'autres études indiquent que l'obtention de bonnes performances pour une tâche composée de plusieurs sous-tâches reste un défi majeur pour les algorithmes d'apprentissage par renforcement plats (non hiérarchique). Dans ce contexte l'apprentissage par renforcement hiérarchique a été développé afin d'aborder ce type de problèmes.

L'apprentissage par renforcement hiérarchique décompose un problème d'apprentissage par renforcement en une hiérarchie de sous problèmes. Chaque sous problème est considéré comme un problème d'apprentissage par renforcement à part. Les sous-problèmes identiques peuvent être regroupés dans un groupe et sont contrôlés par une même politique. La particularité de cette décomposition hiérarchique est de représenter le problème sous une forme compacte et

ainsi réduire la complexité de calcul. Dans la littérature, il existe plusieurs approches pour la décomposition de problème d'apprentissage par renforcement comme par exemple, HAMs (BAI et RUSSELL 2017) et MAXQ (MIRZAZADEH, BEHSAZ et BEIGY 2007). Généralement, ces approches sont basées sur un processus de décision semi-markovien (LIMNIOS et OPRISAN 2012). Nombreux chercheurs ont combiné l'apprentissage par renforcement hiérarchique avec le réseau de neurones profonds afin d'améliorer les performances des tâches hiérarchiques (BACON, HARB et PRECUP 2017), (LEE et al. 2017).

2.5.2 Les processus décisionnels de Markov (PDM)

L'interaction agent-environnement est formalisée grâce à un processus de décision de Markov (PDM) (figure 2.6). Dans la littérature, le PDM est considéré comme l'architecture de base de l'apprentissage par renforcement (JIA, SHEN et XUE 2015). Un PDM est un processus stochastique qui satisfait la propriété de Markov (BELLMAN 1957), (PUTERMAN 2014). Un PDM à états et actions discrets avec des récompenses déterministes et un espace d'action indépendant de l'état se formalisent comme un tuple de quatre éléments (S, A, T, R) où :

- S est l'ensemble d'états du système;
- A est l'ensemble d'actions accessibles;
- T est la fonction de transition du système, $P_{s,s'}(a) = P(s'|s,a)$: c'est la probabilité qu'un agent se trouve dans un état $s' \in S$ quand il a effectué l'action $a \in A$ à partir de l'état $s \in S$;
- $R : S \times A \times S \rightarrow \mathbb{R}$, c'est la fonction de récompense immédiate obtenue pour chaque paire état-action. En effet, à chaque fois qu'un agent exécute une action a à partir de son état courant s , il reçoit en retour une récompense $R(s,a)$. Ensuite l'observation de nouvel état s' dépend de la fonction T .

Dans un PDM, la fonction T dépend de la connaissance de l'état courant de l'agent et de l'action que celui ci vient de réaliser. Donc pour la prédiction de l'état suivant, ces deux éléments sont suffisants (la paire état-action actuelle) :

$$\forall s_0, a_0, \dots, s_t, a_t, s_{t+1}, P(s_{t+1}|s_t, a_t) = P(s_{t+1}|s_t, a_t, s_{t-1}, a_{t-1}, \dots, s_0, a_0) \quad (2.2)$$

La politique dans un algorithme d'apprentissage par renforcement est notée π , qui est la probabilité de choisir une action a étant donné un état s : $\pi = P(a|s)$. L'objectif de cet algorithme est de trouver la politique optimale π^* afin de maximiser le nombre total de récompenses. Cette politique peut être stochastique ou déterministe (ZIMMER, BONIFACE et DUTECH 2018).

2.5.3 PDM partiellement observable

Un processus décisionnel de Markov partiellement observable (PDMPO) est une extension du PDM dans lequel l'agent n'a pas de connaissances sur l'état réel du processus. Donc l'agent ne possède pas une observabilité totale sur l'environnement, il n'a accès qu'à une observation partielle de ce dernier (figure 2.7). Un PDMPO est défini comme un tuple de six éléments (S, A, T, R, Ω, O) où :

- S, A, T, R représentent respectivement l'ensemble d'états, l'ensemble d'actions, la fonction de transition et la fonction de récompense dans un PDM;




FIGURE 2.6 – L'interaction agent-environnement dans un PDM




FIGURE 2.7 – L'interaction agent-environnement dans un PDMPO

- Ω représente un ensemble fini d'observations de l'agent ;
- $O : S \times \Omega \rightarrow [0, 1]$ représente la fonction d'observation. Elle correspond à la probabilité d'observer $\omega \in \Omega$ étant donné que l'agent effectue l'action a et atteint l'état s .

Contrairement à un PDM, le PDMPO ne vérifie pas la propriété de Markov. Puisque, la probabilité d'observer ω' dépend non seulement de ω (l'observation précédente) de l'agent et de l'action a qu'il a effectué mais aussi de l'état s dans lequel il se trouvait à l'étape précédente. Ce type de situation est rencontré par exemple en robotique mobile, où les capteurs ne fournissent qu'une vue partielle de la situation ou en diagnostic médical, où l'état du patient n'est connu qu'à travers les résultats d'analyses ou après un traitement médical. Selon (SHANI, PINEAU et KAPLOW 2013), malgré que PDMPO soit l'extension de PDM avec une caractéristique markovienne (vu les états). L'absence d'accès direct à l'état actuel rend PDMPO non markovien par rapport à l'observation. Lors de la décision, l'agent doit garder une trace de l'état initial, des actions précédemment effectuées et des observations précédentes, cela peut être ingérable. Pour remédier à ce problème, un état $b \in B$ qui est une distribution de probabilité sur tous les états est utilisé. Dans un PDMPO $b \in B$ est un vecteur de probabilité d'état (SHANI, PINEAU et KAPLOW 2013) où :

$$\sum_s b(s) = 1 : s \in S, b(s) \in [0, 1] \quad (2.3)$$

2.6 Pourquoi l'IA dans le domaine de la santé?

Optimiser l'efficacité la prise en charge des patients est aujourd'hui une préoccupation majeure. Le déploiement de l'IA dans le domaine de la santé est en forte augmentation. L'IA est utilisée dans ce domaine pour améliorer le quotidien du personnel soignant et plus précisément, améliorer l'efficacité opérationnelle et la qualité des soins. Avec l'aide de l'apprentissage automatique et les réseaux de neurones profonds, les nouveaux dispositifs médicaux dotés d'une IA apportent des avantages sans précédent. Diverses études ont montré que l'utilisation des outils issus de l'IA permet une meilleure gestion puisque les résultats obtenus peuvent être utilisés pendant les étapes de planification et de conception. Ce qui assure une transparence entre les différents services connexes (WAHBA, ASHOUR et GHANNAM 2020), (SCHWALBE et WAHL 2020), (BERTUCCI et al. 2020). Dans (WAHL et al. 2018), les auteurs se sont basés sur l'IA pour réduire la charge de travail du personnel soignant. Dans (CHATTERJEE et al. 2021), les auteurs ont adopté la technique de l'apprentissage automatique pour développer un outil d'assistance qui permet au personnel soignant d'analyser et visualiser de manière informatisée la situation des patients à risque. Par conséquent, l'intégration de divers modèles intelligents pour les applications en santé est à la fois un défi et une énorme opportunité pour l'automatisation rationnelle.

2.6.1 L'automatisation en santé

Les processus de soins déploient une grande quantité de données. Par exemple, l'afflux des données des patients au personnel soignant et le partage d'informations, des instructions et des décisions entre le personnel soignant dans les différents services interconnectés. Il existe également une immense quantité de données générées à partir d'autres segments de l'industrie de santé que les hôpitaux comme par exemple l'assurance maladie, les équipements médicaux, la recherche médicale. Ce volume énorme de données (*appelé également big data*) peut être exploité par des techniques avancées d'analyse comme l'IA incluant entre autres l'apprentissage automatique. En effet, ces techniques sont devenues l'une des atouts les plus précieux pour de nombreuses entreprises et institutions. Ils permettent de transformer les données en informations utiles significatives et exploitables pour : améliorer la prise en charge des patients, aider à la prise de décision, offrir des soins de haute qualité, répondre à des situations en temps réel, optimiser l'utilisation des ressources, sauver plus de vies, diminuer les coûts et voire même prédire les situations de crise.

Dans le service des urgences et vu sa nature imprévisible, le défi est de fournir en temps voulu le processus de prise en charge (triage, consultation, examens complémentaires, orientation) de chaque patient en fonction de son état de gravité. Le déploiement de l'IA permet d'aider à discerner les données collectées et proposer des améliorations dans le processus de soins aux SU (KHAMPARIA et SINGH 2019). Par exemple, l'utilisation de ces techniques permet aux acteurs de la santé d'exploiter la puissance des données non seulement pour l'analyse descriptive (données historiques), mais aussi pour l'analyse prédictive (prédire des résultats futurs : l'affluence de patients, les examens complémentaires, le temps d'attente, etc) dans l'objectif de déterminer à l'avance la meilleure action à prendre pour une situation donnée.

La capacité des systèmes d'IA à réaliser des prédictions basées sur des données réelles peut être bénéfique pour la santé publique. Par exemple, dans (DAGHISTANI et al. 2019) les auteurs présentent un algorithme d'apprentissage automatique pour prédire avec précision la durée de séjour pour les patients atteints d'une maladie cardiaque. Au cours de ces dernières années, les chercheurs se sont également intéressés aux modèles prédictifs afin de pouvoir prédire des mala-

dies telles que l'Alzheimer, le cancer, etc. Par exemple, dans (RICHTER et KHOSHGOFTAAR 2018), une analyse prédictive basée sur l'apprentissage automatique est présentée. Elle permet de déterminer si un patient va développer un cancer ou s'il récidive un dans le futur. Généralement pour la prédiction des maladies, les chercheurs utilisent des techniques différentes : soit des méthodes statistiques classiques comme les modèles de régression (analyse de survie), soit des méthodes d'apprentissage automatique comme les réseaux de neurones artificiels (ANN). Quelques études se basent sur une approche hybride, afin de pouvoir comparer les méthodes d'apprentissage automatique entre elles ou comparer une méthode statistique avec une méthode d'apprentissage automatique. Les travaux dans (KIM et al. 2012), (SINGAL et al. 2013) montrent qu'un modèle d'apprentissage automatique a une meilleure performance qu'un modèle de régression de Cox.

2.6.2 La conciliation IA et le règlement général sur la protection des données (RGPD)

L'avancement de l'IA et la valorisation de ses avantages pour les établissements de soins dépendent en grande partie de l'obtention d'un accès pratique à des données sensibles. Veiller à la protection de la vie privée des patients est essentiel, en particulier pour les personnes qui manifestent des préoccupations importantes quand ils partagent leurs données dans le contexte médical et clinique. Dans ce cadre, et dans le domaine de la santé, seules les solutions d'IA qui respectent pleinement les principes de droit privé sont envisageables. Il est donc primordial de respecter le droit à la protection des données personnelles, notamment via **le règlement général sur la protection des données (RGPD)**. Le délégué de la protection de données a un rôle clé pour s'assurer de la conformité des mesures organisationnelles et techniques. Ce délégué vérifie que le système proposé est conforme aux exigences en matière de protection des données à caractère personnel. En revanche, il n'a pas le droit de porter des jugements sur la validité médicale de la solution algorithmique envisagée. En outre, dès l'étape de la conception, la solution IA doit satisfaire les critères de confidentialité. C'est ainsi que toutes les solutions susceptibles d'affecter directement ou indirectement la sécurité, l'intégrité ou la confidentialité des données des patients sont exclues dès cette étape (PESAPANE et al. 2018), (FORCIER et al. 2019). Dans ce contexte, des études récentes (DOLLEY 2018), (MATUCHANSKY 2019) identifient à la fois les cas d'utilisation dans lesquels le big data a une valeur ajoutée et les risques inhérents à son utilisation en santé publique. Un résumé des études clés discutées dans ce chapitre est présenté dans le tableau 2.1. Les abréviations utilisées dans ce tableau correspondent respectivement à : service des urgences (SU), autre structure hospitalière (Autre SH), systèmes multi-agents (SMA), apprentissage automatique (ML) et apprentissage par renforcement (RL).

2.7 Positionnement

L'intelligence informatique collective est une approche connue pour résoudre les problèmes d'optimisation combinatoire. Elle permet la coordination de plusieurs algorithmes, avec une exploration simultanée de l'espace de recherche (SILVA et al. 2018). Dans ce cadre, plusieurs chercheurs ont souligné l'intérêt de combiner des algorithmes d'optimisation (e.g. les algorithmes de voisinage et les algorithmes évolutifs) avec l'approche multi-agent permettant la coordination distribuées (i.e. SMA) afin de résoudre des problèmes complexes (WANG et al. 2018a). D'ailleurs, **la coordination d'action** : se fait dans le cadre **de la collaboration** lorsque les algorithmes s'entraident pour résoudre simultanément le même problème ou **de la coopération** lorsque chaque

Référence	Domaine d'application		Approche			
	SU	Autre SH	Optimisation	SMA	ML	RL
(POLAP, SRIVASTAVA et YU 2021)		X	X	X	X	
(ALELAIWI 2020)		X	X	X	X	X
(WAHBA, ASHOUR et GHANNAM 2020)		X	X		X	X
(LEE et LEE 2020)	X		X		X	X
(DAGHISTANI et al. 2019)		X	X		X	
(LIU et al. 2019)		X	X		X	X
(RICHTER et KHOSHGOFTAAR 2018)		X	X		X	
(YOUSEFI et al. 2018)	X		X	X	X	
(SHEN et al. 2015)		X	X	X		
(CABRERA et al. 2012)	X		X	X		

TABLEAU 2.1 – Résumé des références clés discutées

algorithme résout localement un sous-problème et qu'ils interagissent ensemble pour créer une solution globale efficace. L'objectif principal est de parvenir à une solution efficace à un problème complexe aussi rapidement que possible grâce à des protocoles de coordination entre un ensemble d'entités autonomes et interactives (agents).

Dans le domaine de l'optimisation, le concept d'agent a été largement employé pour le développement et la résolution de plusieurs problèmes. L'approche basée sur les agents se distingue des autres par sa capacité à modéliser des problèmes de nature distribuée et à exprimer la complexité des relations impliquées grâce à des entités autonomes. Dans la littérature, (AGERBECK et HANSEN 2008) déterminent deux manières dont les SMA sont déployés pour résoudre un problème d'optimisation : (1) en répartissant les contraintes et les variables du problème entre les agents et (2) en tant que liens entre différentes métaheuristiques pour la résolution de problèmes d'optimisation. Néanmoins, ces deux manières ne couvrent pas toutes les différentes possibilités. C'est pourquoi dans (SILVA et al. 2018), les auteurs proposent une classification complémentaire basée sur trois catégories :

- SMA avec décomposition de l'espace de recherche : dans cette catégorie, l'objectif est de diviser les contraintes et les variables du problème entre les agents. Chacun d'entre eux est responsable de l'optimisation de sa perspective locale et, à la fin, les solutions partielles sont combinées pour obtenir une solution globale. Cette approche est utilisée dans plusieurs travaux par exemple dans (JIN et LIU 2002), (ZHENG et al. 2012);
- SMA avec décomposition de métaheuristique : les éléments qui composent la métaheuristique sont définis comme des agents. Ces éléments peuvent être par exemple des heuristiques de bas niveau (heuristiques constructives et améliorantes) ou des stratégies de recherche (stratégies de diversification). Dans cette approche, les métaheuristiques, hybrides ou non (cf. section 2.4.2), peuvent être considérées comme le résultat de l'interaction entre différents types d'agents. Parmi les travaux qui se sont basés sur cette catégorie pour résoudre des problèmes d'optimisation, nous pouvons citer par exemple : (MILANO et ROLI 2004), (AYDIN 2013);
- SMA avec agents métaheuristiques : dans cette catégorie, chaque métaheuristique est considérée comme un agent autonome. Le but est d'explorer les avantages de déploiement d'un SMA pour affiner et combiner les solutions de ces métaheuristiques. Dans ce cadre, chaque agent est responsable de l'exécution de sa propre tâche et, en même temps, utilise

les solutions fournies par les autres agents pour améliorer son résultat. Les agents interagissent et travaillent donc ensemble pour atteindre un objectif prédéfini. (FERNANDES et al. 2009), (SILVA et al. 2014), (SILVA et al. 2015), (AJMI et al. 2020) sont quelques exemples des travaux qui se sont basés sur cette approche.

Il existe un autre aspect important qui associe les métaheuristiques aux SMA. Cet aspect est lié à l'adaptation et l'auto-adaptation de la recherche puisque le choix d'un paramétrage adéquat ou d'une politique efficace de recherche peut être effectué d'une manière dynamique. Un problème d'apprentissage peut donc être posé afin de mettre en place ce dynamisme (JIAO et SUN 2016). Dans la littérature, nombreuses études tentent d'aider le système à atteindre et à améliorer l'adaptabilité globale. D'ailleurs, il y a ceux qui utilisent : l'apprentissage par renforcement (ESFAHANI, KOUROSHFAR et MALEK 2011), (HESTER et STONE 2013); l'optimisation dynamique (YANG, CHENG et WANG 2009); l'algorithme de colonies de fourmis (YU, YANG et YAO 2009). Dans ce cadre, les travaux présentés dans (JIAO et SUN 2016) proposent un mécanisme d'auto-adaptation des SMA. Ce mécanisme est basé sur l'échange d'expériences entre les différents agents. Les auteurs présentent deux types d'expériences : les expériences immédiates que les agents acquièrent pendant qu'ils exécutent des tâches ; et les expériences rétrospectives que les agents déduisent à partir de leurs comportements après avoir accompli leurs tâches (ou atteint leurs objectifs). Ces travaux ont montré que l'échange d'expériences entre les agents dans un environnement dynamique contribue positivement à l'adaptabilité globale du système multi-agent. Par exemple, dans (YOUSEFI et al. 2018), les chercheurs ont étudié le problème d'adaptation et d'auto-adaptation dans le cadre d'un SU Brésilien. Les travaux concernent un outil d'optimisation robuste basé sur une simulation à base d'agents, un apprentissage automatique et un algorithme génétique. L'objectif de cet outil est de diminuer la durée moyenne des séjours, de lutter contre la tension et de déterminer ainsi l'allocation optimale des ressources dans un SU.

Dans cette thèse, nous nous concentrons sur le développement d'un système d'aide à la décision (SAD) doté d'un ensemble d'agents collaboratifs autonomes. Ainsi, nous montrons qu'une technique d'IA supplémentaire telle qu'une méthode d'apprentissage par renforcement peut aider les agents à ajuster leurs paramètres d'optimisation afin d'améliorer les performances du système hospitalier. En effet, l'objectif est de proposer un protocole de collaboration efficace, mettant l'accent sur la manière dont les agents collaborent afin de converger de la manière la plus efficace possible vers la solution optimale. Nous nous focalisons donc dans ces travaux sur le déploiement des techniques collaboratives entre les agents de notre système global et aussi sur l'auto-adaptation de ces agents en intégrant dans leur comportement des techniques d'apprentissage par renforcement, optimisant ainsi la gestion des tensions en inter et intra SUA, ce qui permettra d'améliorer la prise en charge des patients.

2.8 Conclusion

Ce chapitre permet de mettre en évidence les problématiques de modélisation et d'optimisation auxquelles les établissements de soins sont confrontés aujourd'hui. Nous montrons que l'intégration des outils, méthodes et approches issus de l'IA peut être un atout majeur pour améliorer la satisfaction des patients ainsi que celle du personnel soignant. Une étude préalable d'analyse des données de santé est nécessaire pour aider à choisir les outils et modèles adéquats. Dans le chapitre suivant, nous présentons donc deux types d'analyses des données. Ces analyses ont pour objectif d'acquiescer une meilleure compréhension du fonctionnement des urgences. En

complément, nous présentons également une modélisation workflow du parcours patient au sein du SUA et une modélisation SysML pour décrire les différentes fonctionnalités de notre système d'aide à la décision (SAD).

Modèles de prédiction et modélisation du parcours patient dans la chaîne des urgences

3.1 Introduction

Dans ce chapitre, nous présentons tout d'abord une analyse de données statistiques sur un volume important des données réelles fourni par notre partenaire du CHU de Lille. Cette analyse permet de déterminer les aspects les plus intéressants du fonctionnement de la structure des urgences. L'étude statistique réalisée nous permet de faire une étude prédictive pour transcrire la réalité du SUA en utilisant ses données historiques. Cette étude a pour objectif d'anticiper les ressources médicales qui seront nécessaires pour coordonner l'exécution des processus et des activités de soins. Les processus concernés, qui sont liés au parcours patient sont représentés par un workflow. Les processus issus de ce workflow sont pilotés par un système d'aide à la décision (SAD) incluant une phase d'ordonnancement et d'affectation et une phase d'orchestration des tâches de soins. Le fonctionnement, les exigences et les contraintes du SAD sont modélisés par le langage SysML.

3.2 La chaîne des urgences du CHU de Lille

Le SUA du CHU de Lille représente le terrain d'expérimentation de cette thèse. Ce service endure aujourd'hui des périodes de tension durant lesquelles le professionnel de la santé fait face à une surcharge de travail empêchant ainsi le bon fonctionnement du service. Les périodes de tension peuvent se présenter soudainement d'où l'importance de réaliser une étude de prédiction afin de prévoir les événements futurs tels que les périodes de tension aux urgences.

En effet, avant d'élaborer notre modèle de prédiction, il faut étudier en profondeur l'environ-

nement du SUA. Selon le rapport d'activité du CHU de Lille pour l'année 2019¹, une journée typique de ce dernier est caractérisée par : 2100 consultations médicales, 185 interventions chirurgicales, 450 passages aux urgences, 35 interventions SMUR, 2600 appels décrochés au SAMU, 100 examens d'IRM, 31500 actes de biologie, 15 naissances, 630 prises en charge en hospitalisation, 9000 repas produits et 15 tonnes de linge nettoyés.

Le CHU de Lille est considéré comme l'un des plus grands campus santé du nord de l'Europe. Cet hôpital universitaire fournit des soins allant de la proximité aux pathologies très complexes, d'enseignement et de recherche. D'ailleurs, il est reconnu pour son activité de recherche et il se place parmi les cinq premiers CHU de France pour la qualité de sa recherche. En effet, il encourage le continuum de la recherche et les projets collaboratifs d'actualité avec des structures de santé, au bénéfice du patient. Depuis 2009, le CHU de Lille est engagé dans une dynamique de développement durable. Cette action regroupe des acteurs volontaires issus de tous les secteurs et métiers de l'hôpital qui ont pour objectif d'encourager, de sensibiliser et de participer à l'intégration du développement durable dans leurs pratiques professionnelles. Également, le CHU de Lille accorde une priorité à l'innovation en investissant chaque année un budget pour la création et la modernisation des structures d'accueil des patients et des plateaux médico-techniques de haute technologie. Dans ce cadre, en mars 2019 une rénovation structurelle de l'IRM des urgences a été mise en place sachant que les urgences réalisent 8000 IRM par an. Cette rénovation concerne l'intégration de nouvelles avancées technologiques qui permettent une meilleure qualité d'image, ce qui place les urgences du CHU de Lille comme l'une des meilleures plateformes d'imagerie d'urgence européenne.

La figure 3.1 décrit la structure du SUA de Lille qui est composée de trois principaux éléments :

1. l'amont des urgences : représente toute la partie qui précède l'entrée réelle des patients dans le service de soins (i.e. avant l'étape d'enregistrement et l'orientation des patients dans les différents circuits) ;
2. l'intra urgences : est composé d'un accueil administratif, des salles d'attentes (primaire, secondaire), deux box de triage, un circuit court, un circuit long et une zone de transfert (nommée zone E). La zone E est une zone d'attente tampon utilisée par les patients qui ont besoin d'une hospitalisation pour attendre qu'un lit disponible dans les services d'aval concernés leur soit attribué ;
3. l'aval des urgences : qui a pour mission d'accueillir et d'assurer la continuité de soins des patients non programmés.

Dans l'objectif de mieux comprendre le fonctionnement du service des urgences adultes (SUA), nous avons choisi de réaliser une étude statistique sur des données réelles fournies par notre partenaire du CHU de Lille.

3.3 Analyse des données statistiques

Dans cette section, nous présentons une étude statistique des données réelles sur quatre ans « juin 2016 - juin 2020 » (figure 3.2), ces données sont extraites par le logiciel ResUrgences². Cette étude essentielle pour la détermination des indicateurs clés de tension aux urgences, s'appuie sur six axes importants : l'affluence des patients, la durée totale de séjour, le temps d'attente primaire, les examens complémentaires, le moyen d'arrivée et l'orientation des patients.

1. chu-lille.fr

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




FIGURE 3.1 – La structure de la chaîne des urgences (SUA du CHU de Lille)

Num d'ordre	Date	Heure	Informations du passage	Informations du passage	IAO -> motif d'entrée	IAO -> motif de venue	Patient -> d	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	Cardiologie: Phlébite	27	
79312	79311	11/05/2017	10:56:00	jeudi 11 mai 2017 AMBULANCE PRIVEE	Malaise sans PCI. Sensation de chaud-froid	Cardiologie: Malaise	71	
79313	79312	11/05/2017	10:57:00	jeudi 11 mai 2017 MOYENS PERSONNELS	DA axilla C. dir + paresthésie cisse d'	Neurologie: Déficit neurol	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 de	50	RPCD
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 de	53	carcinor
79319	79318	11/05/2017	11:07:00	jeudi 11 mai 2017 AMBULANCE PRIVEE	DA zone déséquilibre diabète avec suspic	Endocrino-métabolisme: I	55	HTA Dia
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 d'	Dermatologie: Urticair	63	
79322	79321	11/05/2017	11:20:00	jeudi 11 mai 2017 MOYENS PERSONNELS	Colique néphrétique	Gastro-entérologie: Doule	28	RAS
79323	79322	11/05/2017	11:22:00	jeudi 11 mai 2017 MOYENS PERSONNELS	Poussée de proriasis. 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 syd ab	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: Traumatis	49	
79326	79325	11/05/2017	11:39:00	jeudi 11 mai 2017 AMBULANCE PRIVEE	DA ZONE malaise ss PCI	Cardiologie: 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	Endocrino-métabolisme: I	61	DNID de
79330	79329	11/05/2017	12:02:00	jeudi 11 mai 2017 MOYENS PERSONNELS	Dir ds les jambes avec instabilité à la mar	Rhumatologie: non traum	23	

FIGURE 3.2 – Extrait de la base de données 2016-2020 du SUA

Ce type d'analyse est essentiel pour la détermination des indicateurs clés de la tension aux urgences.

3.3.1 L'affluence des patients

Nous pouvons penser qu'un état de tension est lié directement à une importante augmentation du nombre d'arrivées de patients au SUA. Afin de vérifier cette relation, une analyse des données sur l'affluence des patients a été effectuée. La figure 3.3 permet une visualisation de la fréquentation du SUA à différentes échelles de temps (heure, jour et mois). Les trois courbes présentent la moyenne de l'affluence des patients sur les quatre ans (2016-2020). La figure 3.3(a) montre une alternance jour et nuit avec des pics journaliers à 11 heures, à 15 heures et à 20 heures. Ensuite nous pouvons constater dans la figure 3.3(b) que la fréquentation est globalement stable tout au long de l'année avec une moyenne d'environ 280 patients accueillis chaque jour dans le service. Concernant l'affluence des patients par mois, la figure 3.3(c) indique que la période critique d'arrivée des patients se situe globalement pendant la période hivernale et une baisse de la fréquentation pendant la période estivale.

La figure 3.4 peut donner l'impression que l'affluence des patients est moins importante en 2016 (48768 patients) et en 2020 (27746 patients) néanmoins, ce constat est tout à fait normal puisque la base de données ne contient que la moitié des données pour ces deux années³. En effet, l'affluence est relativement constante pour les autres années : 86500 patients en 2017, 86526 patients en 2018 et 86713 patients en 2019. Le nombre de patients légèrement plus important

3. les données de l'année 2016 commencent en juin tandis que celles de l'année 2020 se terminent en juin.




FIGURE 3.3 – Résultat de l'étude de l'affluence des patients




FIGURE 3.4 – L'affluence des patients en fonction de l'année

en 2019 pourrait être expliqué par le début de l'épidémie de la COVID-19.

L'étude de l'affluence des patients est intéressante car elle permet d'identifier les périodes d'arrivée les plus critiques dans le SUA. Ainsi, ces données peuvent déjà servir d'indicateurs pour anticiper les besoins en personnel au cours de l'année et selon les horaires de la journée. Cette étude permet également d'identifier les variables utiles pour la prédiction de l'arrivée des patients (cf. section 3.4). Néanmoins, l'utilisation de l'indicateur d'affluence des patients seul ne peut pas prouver l'existence d'une situation de tension sur une période. Par conséquent, nous intégrons dans notre étude d'autres indicateurs pour pouvoir cerner les périodes d'engorgement dans le SUA comme la durée totale de séjour.

3.3.2 La durée totale de séjour

La durée totale de séjour (DTS) représente le temps de passage total d'un patient au SUA, dès son arrivée jusqu'à sa sortie. La figure 3.5 indique que la majorité des patients passe moins




FIGURE 3.5 – La durée de séjours aux urgences




FIGURE 3.6 – La durée de séjours en fonction de CCMU

de dix heures au SUA. Par contre, il y a environ 14% des patients qui passent plus de dix heures aux urgences. Ces patients représentent plus de 45000 cas sur les quatre ans. En effet, la figure 3.6 montre que le niveau de gravité clinique du patient (CCMU : classification clinique des malades aux urgences qui est l'échelle informatisée du triage des patients aux urgences) influence l'indicateur DTS ; plus le patient est dans un état grave, plus la prise en charge est longue. La figure 3.6 montre également qu'un patient de CCMU=5 passe près de trente heures au SUA contre trois heures pour un patient de CCMU=1. Dans cette même figure, nous pouvons constater qu'un patient passe un temps relativement court aux urgences quand il est atteint d'un problème d'ordre psychologique (CCMU=P) et qu'un patient qui est déjà décédé (CCMU=D) à son arrivée, passe plus de 24 heures dans le service. Ces résultats nous permettent de conclure une corrélation entre la durée de séjours du patient et la CCMU.




FIGURE 3.7 – Le temps d’attente primaire

3.3.3 Le temps d’attente primaire

Le temps d’attente primaire (TAP) correspond à la durée d’attente entre l’arrivée du patient et sa première prise en charge. La figure 3.7 montre qu’environ 40% des patients attendent une heure ou moins et 60% attendent plus d’une heure pour être pris en charge. La moyenne du temps d’attente primaire étant deux heures. Cette étude nous permet de constater que plus le temps d’attente primaire est long, plus il y a un risque que l’état de santé du patient s’aggrave.

3.3.4 Les examens complémentaires

La figure 3.8 prouve que la majorité des patients a besoin de réaliser des examens complémentaires dans le cadre de leur prise en charge. Cette figure montre aussi que les patients ont souvent besoin de consulter un spécialiste. En effet, l’avis d’un médecin peut être requis aussi bien quand un patient réalise des examens complémentaires que quand il n’en réalise pas. Les examens complémentaires les plus fréquemment réalisés sont la biologie et l’imagerie. En effet, 30% des patients effectuent les deux types d’examens (figure 3.9). L’étude proposée est utile pour la gestion du service, elle permet d’identifier quel personnel, quelles machines et quels matériels sont les plus sollicités au cours des examens complémentaires afin de prévoir la répartition des ressources.

3.3.5 Le moyen d’arriver et l’orientation des patients

La figure 3.10 indique que 61% des patients arrivent aux urgences en utilisant leurs propres moyens de transport, 23,44% arrivent en utilisant une ambulance privée, 8,73% arrivent par l’intermédiaire des pompiers et 1,47% arrivent via le SAMU-SMUR. Nous nous sommes aussi intéressés à la relation entre le niveau de gravité de l’état du patient (sa CCMU) et son moyen d’arriver. La figure 3.11 montre que quelque soit le mode d’arriver, la CCMU est voisine de 2, vu que le nombre de patients avec une CCMU = 2 est important. Ceci contrebalance les cas où




FIGURE 3.8 – Le nombre de patients ayant recours à des examens complémentaires

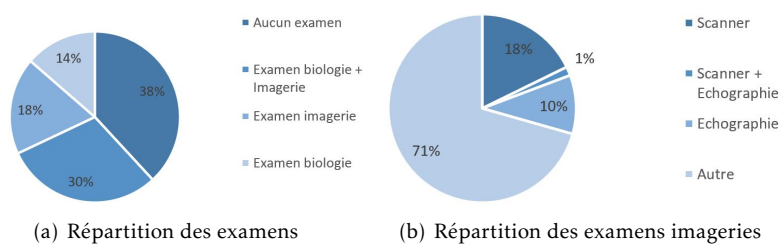


FIGURE 3.9 – La répartition des examens complémentaires




FIGURE 3.10 – Le moyen d’arrivée des patients (2016-2020)




FIGURE 3.11 – Le niveau CCMU moyen en fonction du mode d’arrivée (2016-2020)

les patients ont des CCMU plus importantes. Ainsi, la figure montre également que la CCMU est en moyenne plus importante quand le moyen d’arriver des patients est une ambulance ou hélicoptère.

Concernant l’orientation des patients, la figure 3.12 montre qu’au niveau de la sortie du service, même si la plupart des patients (environ 68%) rentre chez eux après avoir été pris en charge, une part significative des patients (environ 21%) doit être hospitalisée hors du service des urgences, que ce soit dans l’hôpital (transfert interne) ou dans un autre hôpital (transfert externe). Ce constat montre l’importance de travailler sur une solution permettant d’affecter les patients en unité d’aval afin d’éviter les goulots d’étranglement dans la zone de transfert (Zone E). D’ailleurs, nous nous focalisons sur cette partie dans la section 4.6 du chapitre 4.

L’analyse statistique réalisée permet une compréhension progressive et une meilleure connais-




FIGURE 3.12 – L’orientation des patients dans le SUA (2016-2020)

sance du fonctionnement des urgences comme connaître la fréquentation moyenne des patients par jour ou encore la répartition des patients dans le SUA. Suite à nos différentes visites au SUA de Lille et nos diverses réunions avec le personnel médical, nous avons conclu que nous pouvons faire plus que représenter le passé (i.e. analyse statistique). Du fait que, nous disposons 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 de l'apprentissage automatique (machine learning) à des fins de prédiction est intéressante car elle permet d'anticiper les ressources médicales aux urgences. Ceci peut être un facteur d'amélioration de plusieurs indicateurs de performance aux urgences. Par exemple, le temps d'attente, la durée totale de séjour, la charge du personnel soignant, etc.

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

- les examens biologiques éventuels dès l'enregistrement du patient, ceci permet d'anticiper et d'éviter les situations d'engorgement dans le SUA.
- la durée de séjour total à partir des données récoltées par l'IOA (âge, moyen de transport utilisé pour arriver aux urgences, CCMU, antécédents, etc.). Cette prédiction permet d'anticiper les besoins en hospitalisation en aval des urgences.
- 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.
- le temps d'attente primaire, cet indicateur représente généralement une source d'angoisse et de stress pour un patient aux urgences, étant donné que ce dernier ne sera rassuré qu'après sa prise en charge par un médecin. La prédiction de cet indicateur influence positivement la satisfaction du patient et la qualité des soins et permet également d'anticiper les situations de crises aux urgences.

Après plusieurs discussions et analyses des besoins avec notre partenaire du CHU de Lille, nous avons choisi de travailler sur les deux derniers indicateurs à savoir l'affluence des patients et le temps d'attente primaire. La prédiction de ces deux indicateurs permet l'amélioration de la qualité des soins en améliorant à la fois la satisfaction des prestataires de soins (i.e. prédire l'affluence de patients) et la satisfaction des patients (i.e. prédire leur temps d'attente primaire).

3.4 L'étude de prédiction

Se projeter dans l'avenir a toujours été un facteur de réussite important pour assurer une meilleure organisation. Le défi organisationnel est basé sur une problématique mathématique qui consiste à déterminer les occurrences futures d'un événement à partir d'une série d'observations du passé. Actuellement, la demande de soins a considérablement augmenté, la gestion du flux des patients dans les hôpitaux et en particulier dans les urgences est certainement une question clé à prendre en compte. Le service des urgences est la porte d'entrée principale des hôpitaux. Sa mission est légalement définie par : "accueillir sans sélection, 24h/24, tous les jours de l'année, toute personne se présentant en situation d'urgence, y compris psychiatrique,

et la prendre en charge, notamment en cas de détresse et d'urgence vitales". Les situations de tension dans les urgences sont des phénomènes internationaux très difficiles à maîtriser, si ces derniers ne sont pas correctement résolus, ils impactent négativement la qualité des soins et la satisfaction des patients (BOYLE et al. 2012). Dans ce cadre, plusieurs chercheurs ont travaillé sur ce sujet en étudiant des stratégies de prévision des arrivées aux urgences (AFILAL et al. 2016), (KHALDI, EL AFIA et CHIHEB 2019), (ROSTAMI-TABAR et ZIEL 2020) et ils ont conclu qu'un modèle de prévision précis des visites aux urgences est jugé primordial pour gérer efficacement les problèmes d'engorgement, pouvant ainsi permettre une anticipation et une optimisation appropriée des ressources disponibles.

Comme mentionné précédemment, nous étudions dans le cadre de cette thèse la prévision de deux principaux indicateurs : l'arrivée des patients et le temps d'attente primaire. L'objectif de cette étude est d'éviter les situations de crise dans le SUA. Il existe de nombreux types de modèles de prédiction tels que : ARIMA, FBProphet, XGBoost, CNN, etc. Ces modèles sont utilisés dans différents domaines comme la finance, les statistiques, l'économie, la recherche opérationnelle, l'industrie et la santé (POWERS et al. 2017). Dans le cadre de cette thèse, plusieurs modèles de prévision sont testés. Dans ce qui suit, nous présentons une comparaison entre les deux modèles de prédiction FBProphet et CNN, pour chaque indicateur choisi.

3.4.1 Prédiction de l'affluence des patients

Pour prédire l'affluence des patients dans le SUA, nous utilisons le modèle FBProphet et le modèle réseau de neurones convolutifs (CNN).

3.4.1.1 Le modèle FBProphet

FBProphet est un framework open source de Facebook pour la prédiction de séries temporelles basé sur un modèle additif (ROTUNĂ et al. 2019) qui a été ouvert au public en 2017⁴ (TAYLOR et LETHAM 2018). Les tendances non linéaires de FBProphet sont ajustées avec les effets de vacances et la saisonnalité annuelle, hebdomadaire et quotidienne. La fonction FBProphet permet non seulement la prédiction de l'avenir mais également de détecter les anomalies et combler les valeurs manquantes : $y(t) = g(t) + s(t) + h(t) + \epsilon(t)$ où $g(t)$ est une fonction de tendance utilisée pour analyser les changements non périodiques des séries temporelles ; $s(t)$ est un terme périodique qui reflète les changements périodiques par exemple la périodicité d'une semaine ou d'une année ; $h(t)$ est l'influence d'un ou plusieurs jours occasionnels par exemple les jours fériés et $\epsilon(t)$ présente l'erreur du modèle.

En effet, pour prédire le nombre de patients qui se rendent chaque jour aux urgences, nous avons décidé de diviser notre base de données en deux sets comme le montre la figure 3.13 : un set d'entraînement de juin 2016 - juin 2018 (en bleu) et un set de test de juin 2018 - janvier 2019 (en gris). La figure 3.14 montre le résultat de prédiction du modèle sur le set de test après son entraînement sur les données des années précédentes (en gris les données réelles et en jaune la prédiction). Si nous nous focalisons sur le set de test figure 3.15, nous pouvons déduire que notre modèle prédit une tendance générale de l'arrivée des patients. Par contre, notre modèle est incapable de prédire les variations à plus petite échelle (par exemple le jour au jour). Cela est dû à la nature même des données, les arrivées des patients ayant un caractère fortement aléatoire. Afin de relativiser ces résultats, FBProphet fournit en plus de la prédiction, un encadrement sous

4. facebook.github.io/prophet.html




FIGURE 3.13 – Le nombre de patients qui se rendent au SUA par jour




FIGURE 3.14 – La prédiction de l'affluence des patients avec le modèle FBProphet

forme d'intervalle dans lequel se trouve les valeurs possibles de la prédiction. La figure 3.16 montre le résultat de l'encadrement du modèle : en gris les données réelles, en rouge la borne supérieure de la prédiction et en vert la borne inférieure de la prédiction. Cette figure montre également que le modèle arrive assez bien à encadrer le nombre d'arrivées des patients. Grâce à cette fonctionnalité, le modèle fournit aux personnels soignants un indicateur précieux pour anticiper les ressources humaines et matérielles nécessaires. Cependant, l'inconvénient de cette fonctionnalité est que si cet intervalle est trop large, l'information ne sera pas utile. Par exemple, une fourchette de 100 patients est bien trop grande à l'échelle d'une journée sachant qu'en moyenne 280 patients se présentent au SUA. Dans l'objectif d'améliorer ces résultats, nous comparons le modèle FBProphet à un modèle de réseaux de neurones convolutifs, nous utilisons particulièrement la convolution à une dimension car elle est principalement utilisée pour la prédiction des données de séries temporelles (PARK, LEE et SIM 2020).

3.4.1.2 Le modèle de réseau de neurones convolutifs

Le réseau de neurones convolutifs (CNN pour convolutional neural network) a été conçu la première fois pour la reconnaissance des lettres anglaises en 1989. Les études dans la littérature (LÄNGKVIST, KARLSSON et LOUFI 2014), (DZIUGAITE et ROY 2017) ont identifié la puissance de l'architecture des réseaux de neurones convolutifs pour représenter l'apprentissage à partir de données en grille, y compris les données d'images et les séries temporelles. Le CNN est une méthode d'apprentissage automatique qui apprend directement à partir des données, ce qui évite d'extraire les caractéristiques de manière manuelle. Elle a résolu avec succès de nombreux problèmes tels que la classification d'images (XIAO et al. 2015) et elle a montré aussi son efficacité dans la prédiction des maladies (LIN et al. 2016). Cette méthode d'apprentissage automatique est composée de quatre couches :




FIGURE 3.15 – La prédiction de l’affluence des patients avec le modèle FBProphet




FIGURE 3.16 – L’encadrement de l’affluence des patients avec le modèle FBProphet

- la couche de convolution : représente le cœur du CNN, la matrice de données fournie en entrée est divisée en différentes sous-parties de plus petite taille. Chaque sous-partie est multipliée à une matrice appelée « filtres convolutifs » dont les coefficients sont ajustés au fur et à mesure de l'entraînement du modèle. Cette étape de convolution permet d'obtenir une version filtrée de la matrice initiale qui accentue ses caractéristiques importantes. C'est sur ces caractéristiques que s'appuie le modèle pour faire sa prédiction finale.
- la couche de pooling : cette couche permet de réduire la taille de la matrice donnée en entrée tout en préservant les informations importantes qu'elle contient.
- la couche de mise à plat : cette couche permet de concaténer toutes les matrices obtenues par les couches précédentes pour obtenir un unique vecteur final. L'intérêt de cette opération est de mettre en forme les données pour qu'elles soient lisibles par la dernière couche de modèles dite la couche entièrement connectée.
- la couche entièrement connectée : réalise la prédiction en se basant sur l'ensemble des caractéristiques extraites de la matrice initiale par les couches de convolution successives. Cette couche prend une décision et prédit une valeur de sortie.

Dans notre cas, pour la prédiction de l'affluence des patients au SUA, nous utilisons le modèle CNN à une dimension. La matrice fournie en entrée du modèle renseigne pour chaque jour les informations suivantes : le jour de la semaine ; le mois de l'année ; la saison ; l'âge du patient. Dans cette étude, nous choisissons de ne pas supprimer les données de l'année 2020 (contrairement à l'étude réalisée avec le modèle FBProphet) afin de vérifier si le modèle CNN est tout de même capable de prédire ces données malgré leurs caractères inattendus (figure 3.17). Pour réaliser la prédiction, nous entraînons le modèle sur les données des années précédentes : juin 2016-janvier 2019 et nous avons réalisé le test sur les données : janvier 2019-juin 2020. La figure 3.18 montre le résultat de la prédiction obtenue par le modèle CNN (en gris les données réelles et en jaune la prédiction), nous pouvons constater que ce résultat est bien meilleur que le résultat obtenu avec le modèle FBProphet (figure 3.14). En effet, le modèle CNN est capable de prédire la tendance des arrivées de manière fine. Il est capable aussi de prédire la présence des pics au jour le jour, ce dont le modèle FBProphet était tout à fait incapable. En revanche, la figure 3.18 montre que le modèle CNN n'a pas été capable de prédire la chute du nombre d'arrivées due à l'épidémie de COVID-19 puisqu'il n'y avait jamais rien eu de tel dans les données des années précédentes. Par contre, nous pouvons noter que ce modèle a réussi assez rapidement à s'adapter et à reprendre la bonne tendance une fois qu'il a "remarqué" cette anomalie.

En comparant les résultats des deux modèles de prédiction, le modèle CNN semble être meilleur. Afin d'avoir une certitude de la précision de ce modèle, nous avons utilisé deux indicateurs : l'erreur absolue moyenne (MAE : mean square error) et l'erreur quadratique moyenne (RMSE : root mean square error). Ces deux indicateurs peuvent varier de zéro à l'infini, les valeurs inférieures sont meilleures. La différence entre ces deux indicateurs est que la MAE donne en quelque sorte l'erreur moyenne brute, tandis que la RMSE donne plus de poids aux erreurs de prédiction plus graves. Pour la prédiction du nombre d'arrivées des patients, nous avons obtenu une MAE de 22 patients et une RMSE de 31 patients. Le modèle effectue donc des prédictions qui sont précises à l'ordre de 20-30 patients (l'erreur moyenne est de 10%). En effet, les résultats de ce modèle sont tout à fait satisfaisants à l'échelle d'une journée sachant qu'en moyenne 280 patients se présentent chaque jour au SUA. De plus, même dans le cas où un événement




FIGURE 3.17 – L’affluence des patients au SUA juin 2016 - juin 2020




FIGURE 3.18 – La prédiction de l’affluence des patients avec le modèle CNN

imprévisible se produirait, le modèle est capable de s’adapter relativement vite comme nous l’avons constaté dans la figure 3.18 avec la chute des arrivées due à l’épidémie de COVID-19. Le modèle CNN permet donc de faire des prévisions assez fiables de l’affluence des patients au SUA et ces prévisions peuvent être exploitées par le personnel médical. Cette étude de prédiction peut jouer un rôle clé dans le quotidien du personnel soignant. Par exemple, en se basant sur le nombre prédit d’arrivées, les acteurs de la santé prévoient l’ordre de grandeur des ressources humaines et matérielles dont ils auront besoin. Le modèle permettant d’avoir une visibilité sur plusieurs jours, il pourrait donc être intégré comme un module dans un outil d’aide à la décision pour le management de l’hôpital et de ses ressources.

3.4.2 Prédiction du temps d’attente primaire

Dans cette section, nous utilisons la même approche pour prédire le temps d’attente primaire, qui représente le temps d’attente avant la première prise en charge par un médecin.

3.4.2.1 Le modèle FBProphet

Contrairement à l’affluence des patients, le temps d’attente primaire ne semble pas avoir été sensiblement affecté par l’épidémie de la COVID-19. C’est pourquoi nous utilisons l’intégralité des données « juin 2016 - juin 2020 » pour prédire cet indicateur. Comme le montre la figure 3.19, nous avons entraîné le modèle sur les données de juin 2016 à juin 2019 (en bleu) et nous avons




FIGURE 3.19 – Le temps d’attente primaire moyen par jour

tenté de prédire le temps d’attente primaire moyen par jour entre juin 2019 et juin 2020 (en gris). La figure 3.20 montre le résultat de prédiction du modèle FBProphet (en gris les données réelles et en jaune la prédiction) qui sont légèrement meilleurs que la figure 3.15 pour l’affluence des patients. En revanche, le modèle est incapable de prédire les variations du temps d’attente au jour le jour (vu la nature aléatoire de cet indicateur) et ne peut que donner une tendance générale. La figure 3.21 montre l’encadrement de la prédiction du temps d’attente primaire moyen par jour (en gris les données réelles, en rouge la borne supérieure de la prédiction et en vert la borne inférieure de la prédiction). Il est plus pertinent de présenter le temps d’attente primaire sous forme d’intervalle que de chercher à obtenir la valeur exacte, donner un intervalle d’attente pour un patient aux urgences réduit forcément son stress. L’encadrement réalisé par le modèle FBProphet est relativement efficace sauf pour les quatre derniers mois de l’année 2020 où un pic important n’a pas pu être prédit. Dans ce qui suit, nous effectuons la prédiction avec le modèle CNN afin de pouvoir comparer et vérifier son efficacité par rapport au modèle FBProphet.

3.4.2.2 Le modèle de réseau de neurones convolutifs

Pour prédire le temps d’attente primaire avec le modèle CNN, nous avons entraîné le modèle sur les données : juin 2016 à juin 2019 et nous avons tenté de prédire le temps d’attente primaire moyen par jour entre juin 2019 et juin 2020. Nous avons utilisé la même matrice en entrée avec les mêmes variables (le jour de la semaine ; le mois de l’année ; la saison ; l’âge du patient) que pour la prédiction du nombre d’arrivées. La figure 3.22 montre la prédiction obtenue après l’entraînement du modèle sur les données des années précédentes (en gris les données réelles et en jaune la prédiction). Le modèle CNN est plus efficace pour prédire la tendance du temps d’attente primaire et il est capable contrairement à FBProphet de prédire certains pics au jour le jour. D’ailleurs, nous avons obtenu une MAE de 24 minutes et une RMSE de 31 minutes. Le modèle réalise donc des prédictions qui sont précises de l’ordre de 20 à 30 minutes (l’erreur moyenne est de 25%) surtout que le temps d’attente primaire moyen est deux heures (cf. section 3.3.3), les résultats de ce modèle sont donc satisfaisants. L’étude prédictive réalisée dans cette section a permis de transcrire la réalité de notre terrain d’expérimentation en analysant ses données historiques. En effet, grâce à l’apprentissage automatique, nous pouvons d’un côté représenter la réalité et de l’autre côté amener des éléments d’anticipation pour la gestion et la planification du flux patients. En outre, l’anticipation des ressources médicales




FIGURE 3.20 – La prédiction du temps d’attente avec le modèle FBProphet




FIGURE 3.21 – L’encadrement de la prédiction du temps d’attente avec le modèle FBProphet




FIGURE 3.22 – La prédiction du temps d’attente avec le modèle CNN

(humaines et matérielles) est primordiale pour la coordination des activités de soins liée au parcours patient. Dans ce qui suit, nous présentons la modélisation du parcours patient dans la chaîne des urgences à l’aide d’un modèle workflow. Cette modélisation est composée d’un modèle global suivi de deux sous-processus et a pour objectif de déterminer les indicateurs clés à optimiser afin d’améliorer la qualité de soins dans la chaîne des urgences.

3.5 La modélisation du parcours patient

Le workflow est une modélisation informatique des divers flux d’un processus au sein d’un système (cf. section 2.2.3). qui est utilisé pour organiser le processus métier. Les outils de workflow intègrent généralement des fonctions de gestion plus ou moins sophistiqués qui ont pour but de guider les utilisateurs lors de l’exécution du processus (i.e. l’ordre où ces processus doivent être exécutés). Les modèles workflow décrivent les flux de travail des systèmes réels et consistent essentiellement en une structure graphique où les nœuds (généralement sous forme de cadres BPMN⁵) symbolisent les tâches et les flèches représentent les flux entre ces tâches. Le workflow permet ainsi de mieux s’organiser. Il vient en complément d’outils de gestion des tâches, de planification, de stockage et de partage des fichiers. Son intérêt s’explique par les avantages qu’il présente. Par exemple, il permet d’avoir une vision logistique d’un processus, ce qui est très important dans la modélisation de la chaîne des urgences (le terrain d’expérimentation de cette thèse).

Le workflow ne retranscrit pas seulement une vision globale du processus, il précise aussi l’enchaînement des tâches et les ressources disponibles au sein de ce processus. D’ailleurs, les éléments de la modélisation sont articulés les uns par rapport aux autres. Avoir une telle visualisation d’un processus, dont les informations sont traduites de manière pratique, permet alors d’avoir du recul. Cela peut justement permettre de repérer des améliorations possibles et des points qui sont conservables ou non selon les flux à gérer.

La modélisation workflow a été souvent adoptée dans le domaine de la santé (WANG et RUTLE 2014), (AJMI et al. 2018). En effet, l’utilisation des outils de workflow dans ce domaine permet aux établissements de soins de représenter les liens entre des tâches et donc des opérations réalisées dans un ordre donné, en faisant intervenir les acteurs de santé (médecins, infirmiers, internes, etc.) et les ressources matérielles (box, plateaux médico-techniques, etc.) impliqués dans le processus. De plus, le workflow en santé fournit non seulement une modélisation et une gestion des diverses activités médicales et/ou administratives mais aussi une parfaite interconnexion entre les différentes tâches des processus de soins. D’ailleurs, parmi les avantages de la mise en

5. www.bpmn.org

Les caractéristiques	Bizagi	Bonita	Arabdox	Joget
La modélisation de processus métier	3	3	1	2
Les règles métier	1	1	1	1
La gestion des utilisateurs et des autorisations	2	2	2	1
La forme	1	2	2	2
La base de données	2	2	2	1
Le total	9	10	8	7

TABLEAU 3.1 – Comparaison des outils de modélisation (NAFIE 2016)

place d'un tel outil en santé, nous pouvons citer :

- une augmentation de l'efficacité du service en supprimant par exemple les tâches redondantes ;
- une réduction de stress du personnel soignant et du patient grâce à un parcours patient rationnel ;
- une vue orientée sur les flux, ce qui améliore la qualité de soins ;
- un contrôle des flux grâce aux outils collaboratifs qui assurent une meilleure gestion du processus de soins.

Ces points impliquent d'autres intérêts. Par exemple, la flexibilité du processus avec la possibilité de le mettre à jour dynamiquement en faveur du patient et l'automatisation du processus vu que l'ordre des tâches peut être recalculé de manière automatique grâce à des méthodes d'optimisation (AJMI 2019). Dans ce cadre, l'utilisation d'un outil de workflow amélioré pour la gestion du processus de soins est primordiale. Dans cette thèse, la modélisation workflow fournit une vue globale sur la gestion de la chaîne des urgences expliquant ainsi la coopération et la coordination en inter et intra (amont et aval) service.

3.5.1 Choix de l'outil de modélisation

Dans la littérature, plusieurs chercheurs ont réalisé une comparaison entre les différents outils de modélisation workflow tels que : Bizagi, Arabdox, Bonita et Joget. (ELFAKI 2000),(DUNIE et al. 2015),(GJONI 2015) (NAFIE 2016). Ces études ont conduit quasiment aux mêmes résultats. Par exemple, l'étude comparative de (NAFIE 2016) montre que l'outil Bonita, suivi de Bizagi a la meilleure performance par rapport à Arabdox et Joget. L'auteur précise qu'il ne s'agit en aucun cas d'une comparaison complète. Ainsi, en matière de modélisation de processus métier, Bizagi et Bonita ont une qualité bien supérieure à Arabdox et Joget. En revanche, pour les aspects formels Bonita et Joget dépassent Bizagi et Arabdox. Le tableau 3.1 montre le résultat de la comparaison réalisée dans (NAFIE 2016). Cette comparaison permet de conclure que les outils proposés ont des performances satisfaisantes même s'il existe quelques différences entre eux.

Dans le cadre de cette thèse, nous avons choisi de travailler avec l'outil Bizagi vu que c'est un outil de gestion des processus facile à utiliser qui offre à l'utilisateur le moyen de modéliser, de simuler, d'exécuter et d'améliorer les processus d'activités par le biais d'un environnement graphique et sans avoir recours à la programmation. Cet outil a été validé par notre partenaire du CHU de Lille. Bizagi est disponible sous plusieurs éditions afin de répondre aux divers besoins. Parmi ces exemples, l'édition Xpress est composée de trois modules :

- Bizagi Studio : offre aux experts métier tout ce dont ils ont besoin (i.e. depuis la définitions du modèle de données jusqu'à l'intégration de ce dernier) pour transformer les modèles de processus en applications et en workflow réels et opérationnels.
- Bizagi Engine : contrôle et exécute le processus métier automatisé par Bizagi Studio. Il supporte le déploiement en JEE ou .Net et offre un ensemble d'indicateurs de performances indispensables pour l'amélioration des processus.
- Process Modeler : fournit aux experts métier le moyen de concevoir, de documenter et de faire évoluer leurs modèles de processus. Dans ce module, la notation de modélisation utilisée est le BPMN.

Nous utilisons « Bizagi Modeler » pour la modélisation du parcours patient dans le SUA. Cette modélisation permet d'identifier les ressources trop ou peu exploitées (grâce à un outil de simulation intégré); d'avoir un modèle clair de l'organisation; d'estimer le nombre de patients maximal aux SUA avant la saturation du service; d'avoir une visualisation sur la répartition des ressources et du matériel et finalement d'estimer le coût des ressources et le temps passé dans chaque parcours.

3.5.2 Modélisation du parcours patient dans le SUA

Dans cette section, nous présentons la modélisation du parcours patient dans le SUA du CHU de Lille. Cette modélisation se présente sous forme d'un processus global (figure 3.23) en précisant les deux sous-processus CC et CL correspondant respectivement au circuit court et circuit long (figure 3.24 et figure 3.25). Cette décomposition en sous-processus a pour but de décharger visuellement le workflow tout en préservant la complexité des connexions entre les différents éléments du SUA. Cette modélisation workflow a été validée par notre partenaire (i.e. le personnel soignant du SUA).

3.5.2.1 Le modèle global du parcours patient

La figure 3.23 représente le parcours patient dans la chaîne des urgences dès son arrivée jusqu'à sa sortie. Sur la même figure, nous pouvons constater que le parcours patient est scindé en trois parties : **amont**, **intra-SUA** et **aval**. Comme nous l'avons évoqué auparavant, l'amont des urgences représente toute la partie qui précède l'entrée réelle du patient dans le service de soins. Cette la figure 3.23 montre que le patient peut accéder au SUA de Lille via deux entrées différentes : (1) la tâche « Accueil standard », c'est l'entrée par laquelle les patients valides se présentent. À noter que cette entrée n'est pas spécifique aux urgences adultes. Elle représente également l'entrée des urgences pédiatriques; (2) la tâche « Accueil SAMU » représente l'entrée des patients non valides, ces derniers se présentent sur un brancard et ils sont orientés vers des unités de soins adaptés à leur état. Pour ces deux tâches, le personnel de l'accueil effectue l'enregistrement du dossier administratif du patient. À partir du moment où le patient est enregistré, ce dernier va être orienté selon son état vers :

1. la tâche « Déchocage médical (DM) » : fait partie de l'aval des urgences. Dans notre modèle, le DM est représentée par une fin car géographiquement il a lieu hors SUA. l'unité DM prend en charge les patients instables et en détresse vitale;
2. la tâche « Déchocage chirurgical (DC) » : fait partie de l'intra-SUA. À l'instar du DM, le DC a pour rôle de prendre en charge les patients qui ont un état de santé sévère (patients en détresse vitale). Il est important de souligner que même si le déchocage chirurgical

est situé à l'intérieur du SUA, il possède ses propres ressources humaines (une équipe médicale spécifique);

3. la tâche « Attente » : fait également partie de l'intra-SUA de la chaîne des urgences. Pendant cette tâche, les patients attendent que l'infirmie(è)r(e) d'accueil et d'orientation (IOA) leur attribue un motif de recours (i.e. un degré de CCMU). La durée d'attente dépend des flux d'arrivée des patients aux urgences. En fonction de l'état de gravité, le patient est orienté/réorienté soit vers le circuit long (CL) soit vers le circuit court (CC) soit vers le DC ou le DM où sa prise en charge sera réalisée par un médecin urgentiste. Cette tâche présente une passerelle entre la partie amont et la partie intra-SUA. Suite à la prise en charge du patient dans l'un de ces circuits (CL, CC) ou unités (DC, DM), ce dernier peut rentrer chez lui (domicile) ou peut être transféré dans une unité d'aval pour la continuité de ses soins.

Toujours dans la figure 3.23, la tâche « Attente brancard CL » est spécifique aux patients non valides et donc sur brancard. Ces patients doivent patienter dans cette zone jusqu'à la disponibilité d'un box dans le CL. Suite à la prise en charge des patients dans ce circuit et selon leur état, ces derniers peuvent être hospitalisés en aval, c'est-à-dire hors service des urgences (événements de fin) ou en intra-SUA dans une unité d'hospitalisation de courte durée (tâche « UHCD »). Cette unité est un service à part entière dans les urgences qui contient 25 lits. Les patients hospitalisés dans cette unité ont besoin d'une surveillance médicochirurgicale et d'une prise de décision pour leur orientation finale en moins de 24 heures. Les événements de fin représentent les hospitalisations en aval des urgences. Nous pouvons distinguer les possibilités suivantes :

- domicile : le patient rentre chez lui suite à sa prise en charge dans les urgences ou après une hospitalisation en UHCD ;
- service adapté : le patient est hospitalisé dans un service spécialisé adéquat à sa pathologie afin d'assurer la continuité des soins et d'éviter le retour aux urgences ;
- post-urgences : ce service est pris en charge par les internes et n'autorise l'hospitalisation qu'aux patients provenant des urgences ;
- hospitalisation hors CHU : ceci signifie l'orientation des patients dans un autre hôpital ou une clinique puisque il n'y a plus de place pour accueillir de nouveaux patients ;
- hospitalisation inadaptée : dans une situation de tension, les patients peuvent être hospitalisés dans un service inadapté à leur pathologie.

Notre modèle présente deux types de branchements : exclusif et complexe. Les branchements exclusifs sont utilisés pour créer des chemins alternatifs dans le processus (i.e. un seul chemin est choisi). Les branchements complexes permettent de continuer vers le prochain point du processus lorsque, une condition devient vraie. Pour la modélisation, un branchement complexe précède toujours un branchement exclusif s'il existe plusieurs entrées. Un branchement exclusif est utilisé s'il y a une seule entrée. En effet, les branchements exclusifs présentés dans notre modèle sont décisionnels. Ces branchements graphiques sont employés pour contrôler et vérifier le comportement des flux de séquence dans le processus. Le tableau 3.2 détaille et explique chaque point de décision présenté dans le modèle global.

Point de décision	Description
PD1	indique le type d'arrivée du patient, s'il s'agit d'un patient valide ou d'un patient non valide.
PD2	contrôle l'orientation du patient selon sa gravité soit vers le déchocage chirurgical ou l'attente ou le déchocage médical.
PD3	ce point de décision permet de savoir le nombre de patients par circuit (CL et CC) il représente un premier point d'étranglement dans le modèle.
PD4	ce point représente le deuxième point d'étranglement dans le modèle. À partir de ce point le patient est orienté dans les soins appropriés en fonction de sa pathologie.
PD5	à partir de ce point le patient peut rentrer chez lui ou être réorienté dans le CL si son état ça s'est aggravé.
PD6	à partir de ce point le patient est orientés soit vers l'une des unités d'aval soit il rentre chez lui.

TABLEAU 3.2 – Description des branchements conditionnels du modèle global

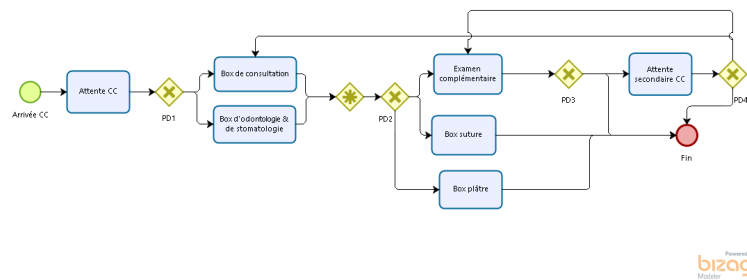


FIGURE 3.24 – Le circuit court « CC » du SUA

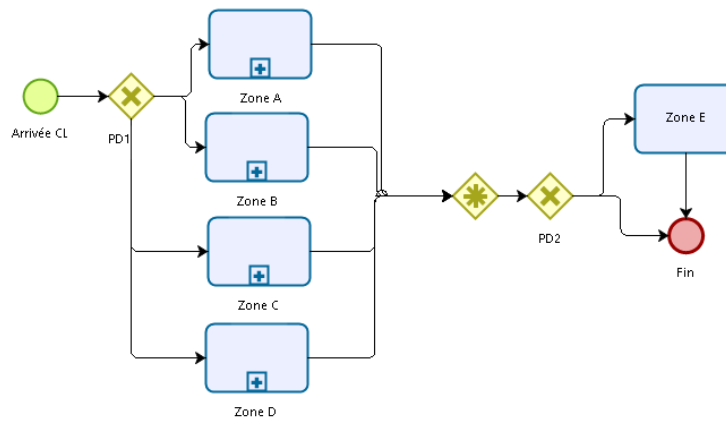


FIGURE 3.25 – Le circuit long « CL » du SUA

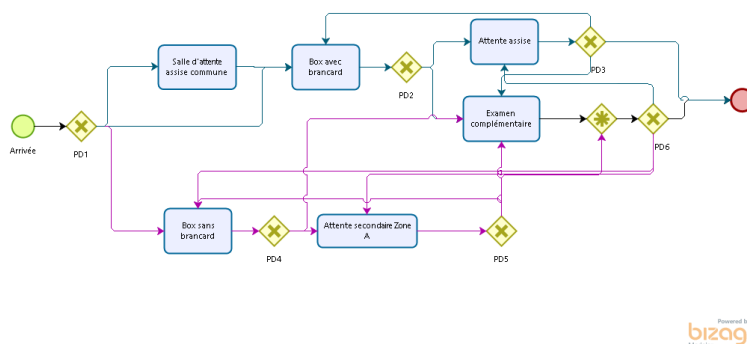


FIGURE 3.26 – Le circuit long du SUA : zone A

Point de décision	Description
PD1	selon la pathologie et les besoins en soins du patient, ce dernier est orienté dans le box de consultation ou dans le box d'odontologie et de stomatologie.
PD2	suite à l'action choisie dans le PD1 et selon la pathologie du patient, ce dernier est orienté soit vers le box suture ou le box plâtre ou vers les « examens complémentaires ».
PD3	en fonction des résultats des examens complémentaires et de la pathologie du patient, ce dernier peut soit quitter le CC, soit patienter dans la salle d'attente pour une autre consultation ou pour effectuer des nouveaux examens complémentaires.
PD4	à partir de ce point de décision, le patient quitte généralement le CC. Il est possible aussi qu'à partir de ce point de décision, le patient refasse une consultation ou des examens complémentaires.

TABLEAU 3.3 – Description des branchements conditionnels du CC

3.5.2.2 Les sous-processus du parcours patient

Comme précisé précédemment, nous représentons les deux circuits : le circuit court (CC) et le circuit long (CL) par deux sous-processus dans le modèle global. Le but ici est de simplifier la vue du modèle global du workflow. Ainsi, dès l'arrivée du patient (ici l'instance du workflow qui représente le patient qu'on appelle "jeton") à l'étape correspondant au CC ou au CL dans le modèle global (figure 3.23), l'événement de début du sous-processus correspondant sera déclenché. Ce qui permet de démarrer le processus correspondant du CC (figure 3.24) ou du CL (figure 3.25). Dès la fin du parcours du patient dans le CC ou dans le CL, ce dernier continue son parcours de soins dans le processus global.

Le CC présenté dans la figure 3.24 a pour rôle de désengorger le service des urgences. Il est composé d'un box de consultation, d'un box d'odontologie et de stomatologie, d'un box de suture et d'un box de plâtre. Les patients valides de moins de 65 ans qui n'ont besoin ni d'un brancard ni d'analyses biologiques poussées sont pris en charge dans ce circuit. Généralement le temps de passage moyen dans ce circuit est inférieur à deux heures. Les branchements graphiques utilisés dans la figure 3.24 sont expliqués dans tableau 3.3.

La figure 3.25 représente le circuit long (CL) des urgences. Ce circuit a pour rôle de prendre en charge principalement les patients qui ont un état de santé compliqué. Comme le montre la figure 3.25, le CL est composé de quatre zones (A, B, C et D), une salle d'attente commune et une salle d'attente secondaire dédiée et intégrée à chaque zone. Si le patient est orienté vers le CL, il est pris en charge dans une de ces zones. Chaque zone est munie de huit box dont un box avec

Point de décision	Description
PD1	permet l'orientation du patient vers la zone où il était envoyé depuis le modèle global.
PD2	permet l'orientation du patient vers la zone E (zone de transfert) ou à la fin du CL.

TABLEAU 3.4 – Description des branchements conditionnels du CL

Point de décision	Description
PD1	indique le type d'arrivée du patient. Le patient valide est orienté soit vers la salle d'attente assise commune ou vers un box avec brancard. le patient non valide est orienté vers un box sans brancard.
PD2	suite à la prise en charge du patient valide, il est orienté soit vers la salle d'attente assise soit vers les « examens complémentaires ».
PD3	ce point permet au patient de refaire des examens complémentaires ou de revenir dans un box (si besoin) ou de quitter le CL.
PD4	permet au patient non valide de réaliser des examens complémentaires ou de patienter dans la salle d'attente secondaire de la zone A.
PD5	permet au patient non valide de refaire des examens complémentaires ou de de revenir dans un box (si besoin) ou de quitter le circuit
PD6	à partir de ce point de décision, il existe différentes possibilités des flux patients par exemple, ce dernier peut quitter le circuit ou il peut revenir dans un box en fonction de son état de santé.

TABLEAU 3.5 – Description des branchements conditionnels de la zone A du CL

brancard qui permet la prise en charge des patients valides. Chaque zone comporte également un médecin, un interne, un(e) infirmier(e)r(e) et un(e) aide-soignant(e). Nous avons choisi de présenter chaque zone par un sous-processus à part entière, non seulement afin de distinguer les différentes salles d'attentes secondaires de la salle d'attente commune de ce circuit, mais aussi pour différencier le parcours patient valide du parcours patient non valide. La figure 3.26 présente la zone A du CL, les flux en bleu et en rouge modélisent respectivement le parcours patient valide et le parcours patient non valide. De même, les tableaux 3.4 et 3.5 expliquent les différents points de décision de CL.

Pour conclure, notre modélisation workflow⁶ tient compte de tout type de soins et d'orientation au sein du SUA. Cette modélisation nous offre une cartographie pour n'importe quel parcours patient possible. Afin que notre modèle traduit une image fiable et adéquate de la réalité, nous avons choisi de différencier les diverses étapes d'attente. Ainsi, nous avons distingué l'attente primaire et l'attente secondaire : les tâches « Attente », « Attente brancard CL », « Attente CC » et « salle d'attente assise commune » représentent l'attente primaire, et les tâches « Attente secondaire CC », « Attente assise » et « Attente secondaire Zone A » pour représenter l'attente secondaire.

Cette modélisation workflow déployée nous permet d'identifier trois zones de blocage dans le SUA :

- à l'entrée du SUA : avec la possibilité d'un afflux important de patients, la zone d'attente primaire peut se remplir très vite ;
- en intra-SUA : le CL et le CC sont complets la plupart du temps. L'occupation de ces circuits est souvent due aux pathologies des patients présents (des pathologies qui nécessitent un temps de consultation assez long). Celles-ci ralentissent l'avancement des prises en charge des patients et rallongent ainsi leur temps d'attente ;

6. la modélisation inclut les quatre modèles proposés

- à la sortie du SUA : la difficulté de trouver un lit d'hospitalisation influence forcément le fonctionnement des urgences. Les patients qui ont besoin d'une hospitalisation sont bloqués dans la zone de transfert (zone E cf. figure 3.24).

Afin de maîtriser ces points de blocage, il faut déterminer les principaux indicateurs clés à optimiser pour améliorer la chaîne des urgences. Dans ce cadre, la modélisation workflow décrite précédemment nous permet de déterminer quelques indicateurs tels que : le temps d'attente primaire et le temps d'attente secondaire, le nombre des patients dans l'UHCD et dans la zone E et le flux d'arrivée des patients. La prédiction du nombre d'arrivées des patients en amont des urgences peut être donc un facteur clé pour optimiser le temps d'attente et par conséquent optimiser la durée de séjour des patients. L'utilisation d'un outil d'aide à la décision dans la chaîne des urgences joue un rôle primordial à la fois pour l'ordonnancement des patients en intra-SUA et pour anticiper le besoin en aval et ainsi diminuer le temps d'attente pour trouver un lit d'hospitalisation disponible.

La modélisation workflow présentée dans cette section comprend une multitude de points de décisions. Ces derniers représentent des points d'indéterminisme du modèle qui ont besoin d'être arbitrés. La phase d'arbitrage est développée par l'intermédiaire d'un module d'aide à l'ordonnancement des tâches de soins (cf. chapitre 4) qui est inclus dans notre SAD. Afin que les urgentistes du CHU de Lille soient une partie prenante de la constitution de ce SAD, nous avons donc réalisé un modèle de fonctionnement de ce SAD par le langage SysML qui est compréhensible par tous. Les différents diagrammes SysML relatifs à ce SAD sont présentés dans ce qui suit.

3.6 La modélisation SysML du SAD proposé aux urgences

Dans la littérature, plusieurs recherches sont réalisées permettant d'expliquer l'objectif de la modélisation (CLAVEL, MAHULEA et SILVA 2019), (FAYOUMI et WILLIAMS 2021). Ces recherches ont montré que le but de la modélisation est de concevoir et de connaître les mécanismes qui lient les phénomènes à leurs causes en se référant à la réalité. En effet, le choix de l'approche de modélisation et de l'outil approprié doit se faire en fonction de la complexité du système étudié et des objectifs recherchés. D'ailleurs, le développement et la réalisation d'un système innovant et moderne nécessite principalement une ingénierie des exigences (cf. section 2.2.2). Ainsi, dans le cadre de développement du SysML, l'international council on systems engineering (INCOSE) et l'object management group (OMG) ont intégré la notion d'exigence et de contrainte. Un diagramme ainsi qu'une table des exigences sont introduits par la suite. Ces exigences sont liées avec le diagramme comportemental et le diagramme structurel (cf. figure 2.1).

Dans notre cas, la phase de recueil des exigences et des contraintes représente une étape primordiale pour la mise en place de notre système d'aide à la décision (SAD). Cette étape permet de faire une représentation et une traduction des besoins des acteurs impliqués (patients, médecins, infirmier(e)s, personnel paramédical, etc.) en se basant sur un formalisme plus minutieux qu'un cahier des charges classique (BELLOIR, BRUEL et FAUDOU 2014). Dans cette thèse, nous choisissons d'utiliser l'outil Cameo Systems Modeler⁷ pour la modélisation des exigences et des contraintes liées à la chaîne des urgences. Cet outil de modélisation UML, SysML et BPMN est un outil de développement dynamique et polyvalent qui facilite l'analyse et la conception des systèmes orientés objets. Afin de mieux traduire les différentes exigences liées à la réalisation de

7. www.magicdraw.com




FIGURE 3.27 – Diagramme de contexte du SAD chaîne des urgences

notre SAD et suite aux diverses réunions et discussions avec le personnel soignant, nous avons décidé de développer deux diagrammes structurels (le diagramme de contexte et le diagramme de bloc) et un diagramme comportemental (le diagramme de cas d'utilisation). Le niveau de détail de ces diagrammes a été validé par notre client (i.e. le personnel du SUA de Lille).

3.6.1 Le diagramme de contexte

Ce type de diagramme permet de représenter l'environnement général du SUA de Lille. Il a pour objectif non seulement d'identifier les acteurs et les éléments environnants du système considéré mais aussi d'identifier les frontières recherchées et d'indiquer les étapes du cycle de vie dans laquelle se situe le système. Ce diagramme non normalisé⁸ exige de mettre le système étudié au centre et de le relier ensuite par son environnement. La figure 3.27 représente le système étudié « SAD : chaîne des urgences » et l'ensemble des éléments qui le compose. Ce SAD est destiné à être utilisé par le personnel soignant et il va agir sur le patient, et plus particulièrement sur son temps d'attente.

Le diagramme de contexte permet de représenter le cadre opérationnel, environnemental de notre SAD. Néanmoins, il ne permet pas d'analyser les besoins en termes de fonctionnalités. En effet, la description fonctionnelle d'un système donné est réalisée via le diagramme de cas d'utilisation.

3.6.2 Le diagramme de cas d'utilisation

Un diagramme de cas d'utilisation (CU) est graphiquement composé de trois éléments de base : (1) les cas d'utilisation représentés par des ellipses libellées du nom de cas d'utilisation ; (2) les acteurs extérieurs (acteurs principaux et/ou acteurs secondaires) et (3) le système étudié qui est représenté par un rectangle englobant les différents cas d'utilisation. Ces éléments sont

8. pour sa construction il faut utiliser la forme de diagramme de définition de bloc (BDD) ou la forme de diagramme de bloc interne (BDI).




FIGURE 3.28 – Diagramme de cas d'utilisation du SAD chaîne des urgences

reliés entre eux par des liens de communication représentés par des traits pleins. Entre les différents cas d'utilisation il existe deux types de relations standardisées : « include » & « extend ». La relation « include » est employée pour indiquer que le cas d'utilisation source (départ de la flèche) contient toujours le cas d'utilisation inclus. Ce dernier est indispensable pour la réalisation du cas d'utilisation d'origine. C'est dans les limites de la relation d'extension que d'autres cas d'utilisation pourront étendre « extend » le comportement initial de cas d'utilisation source. La relation « extend » permet de présenter une fonctionnalité optionnelle.

La figure 3.28 présente le diagramme de CU de notre système où chaque cas d'utilisation représente une fonctionnalité souhaitée par les différentes parties prenantes. En effet, la réalisation du cas d'utilisation « optimiser et coordonner les activités de soins » dépend étroitement de la réalisation des deux cas d'utilisation suivants : « optimiser la prise en charge des patients » et « optimiser la gestion des lits en aval ». En outre, les différents personnels soignants peuvent utiliser le SAD pour consulter leur planning en temps réel et pour coordonner leurs activités de soins.

3.6.3 Le diagramme de définition de bloc

En SysML, le diagramme de définition de bloc (BDD) est un diagramme qui modélise la structure d'un système logiciel, matériel ou fonctionnel. Il peut représenter un système complet, un sous-système ou un composant élémentaire. C'est un diagramme architectural contenant des blocs décomposables et peut posséder un comportement pour représenter le système complet. Un bloc permet de décrire également les flots (matériels, informationnels, énergétiques) qui circulent à travers un système. Chaque bloc comporte plusieurs compartiments tels que le nom du bloc, les opérations qui détaillent les actions réalisées par bloc, les paramètres qui définissent les instances du bloc (parties, références, valeurs, propriétés) et les « constraint » qui permettent de définir les contraintes de la fonction. Les propriétés sont les caractéristiques structurelles de base des blocs. Elles peuvent être de deux principaux types : (1) Les valeurs (value properties) représentent les caractéristiques quantifiables en termes de value types (domaine de valeur, dimension et unité optionnelles); (2) les parties (part properties) représentent la hiérarchie de décomposition du bloc en termes d'autres blocs.




FIGURE 3.29 – Diagramme de définition de bloc du SAD pour l'optimisation de la chaîne des urgences

Toutefois, chaque bloc définit un ensemble d'instances partageant les propriétés du bloc, mais possédant chacune une identité unique. En effet, la différence entre un bloc et une instance est qu'un bloc est un ensemble d'éléments, alors qu'une instance est la réalisation concrète de ces éléments. La figure 3.29 représente le diagramme BDD de notre système, il existe trois relations possibles :

- la composition : un bloc représente le contenant et l'autre présente le contenu, néanmoins le contenant n'a pas de raison d'être sans le contenu. Par exemple dans notre diagramme, le bloc « SAD : chaîne des urgences » a nécessairement besoin de trois sous-blocs « Amont urgences », « Intra urgences » et « Aval urgences ». La relation de composition est représentée par un losange plein ;
- l'association : modélisée par un trait simple. Elle relie deux blocs similaires ;
- l'agrégation : est équivalente à la composition, sauf que le contenu a une existence sans le contenant. La relation d'agrégation est représentée par un losange vide.

3.6.4 Le diagramme des exigences

Ce diagramme permet d'identifier, de collecter et d'organiser les différentes exigences du système fonctionnel, environnemental et légal. Il présente les choix décrits dans le cahier des charges du système. Il a pour but de visualiser et de détailler au mieux ces choix, dans l'objectif de souligner les exigences les plus importantes, évitant ainsi d'encombrer le modèle et de dévier l'objectif du système. D'ailleurs, la satisfaction de ces exigences permet de valider le système complet.

Graphiquement une exigence est présentée sous la forme d'un rectangle portant l'en-tête « requirement » ainsi que l'intitulé de l'exigence. Chaque cadre d'exigence dispose de deux propriétés principales : (1) un texte descriptif de l'intitulé de l'exigence, qui doit être court et concis (2) un identifiant « id » unique à chaque exigence, il permet sa traçabilité. Cette traçabilité est liée à la gestion des exigences permettant de définir et de suivre les exigences d'un système au cours de

sa conception. Elle permet aussi d'un côté de s'assurer de la cohérence entre ce que fait réellement le système et ce qu'il doit faire et de l'autre côté de faciliter l'analyse d'impact en cas de changement. Le diagramme des exigences permet tout au long de la période de la modélisation de relier les exigences avec d'autres exigences et avec d'autres types d'éléments SysML (diagramme de cas d'utilisation, diagramme de bloc) grâce aux types de relations suivantes :

- la relation de vérification qui relie l'exigence d'origine à l'exigence qui permet sa vérification, graphiquement c'est un lien accompagné du stéréotype « verify »
- la satisfaction qui relie l'exigence d'origine à l'exigence qui le satisfait, cette satisfaction est représentée par un lien accompagné du stéréotype « satisfy ».

La figure 3.30 montre un exemple de traçabilité SysML. Cette traçabilité permet de vérifier la cohérence de notre SAD. Par exemple, l'exigence « optimiser le parcours patient » dans la figure 3.31 est reliée à trois types d'éléments SysML : le cas d'utilisation « optimiser la prise en charge des patients » (cf. figure 3.28); le bloc « améliorer la prise en charge des patients » (cf. figure 3.29) et système contexte « SAD : chaîne des urgences » (cf. figure 3.27). En effet, notre SAD « SAD : chaîne des urgences » doit vérifier l'exigence « optimiser le parcours patient ».

La figure 3.31 présente une vue globale de l'ensemble des exigences de notre SAD. Ce diagramme permet d'identifier les hiérarchies (symbole \oplus) des exigences ainsi que leurs relations de raffinement, de contenance et de dérivation. Ces relations expliquent les liens entre ses différentes exigences. La relation raffinement consiste à apporter plus de précision à l'exigence source. Graphiquement c'est un lien pointillé accompagné du stéréotype « refine ». Dans notre diagramme, nous utilisons deux fois cette relation : la première fois pour apporter plus de précision à l'exigence « étude de prédiction » et la deuxième pour apporter plus de précision à l'exigence « optimiser la gestion des lits ». La relation de contenance permet de décomposer une exigence composite en plusieurs sous-exigences unitaires et la relation de dérivation relie les exigences de niveaux différents. En effet l'exigence qui est à l'origine de la flèche est déduite à partir d'une autre exigence qui se trouve au bout de la flèche. Graphiquement la dérivation correspond à un lien pointillé accompagné du stéréotype « deriveReq ».

Dans cette thèse, le diagramme d'exigence doit prendre en considération les exigences de trois parties de la chaîne des urgences (amont, intra, aval).

3.7 Conclusion

Dans ce chapitre, nous présentons une étude statistique dont l'objectif est d'acquérir une compréhension progressive et une meilleure connaissance du fonctionnement des urgences. Cette étude est suivie d'une étude de prédiction qui permet de transcrire la réalité de notre terrain en utilisant ses données historiques. En outre, le parcours patient du SUA est modélisé par workflow, accompagné par des diagrammes SysML pour décrire les différentes fonctionnalités de notre SAD.

Dans le chapitre suivant, nous présentons la mise en place d'une approche hybride par agents auto-adaptatifs pour l'optimisation de l'ordonnancement des tâches de soins. Cet ordonnancement représente un module principal du SAD proposé aux urgences.

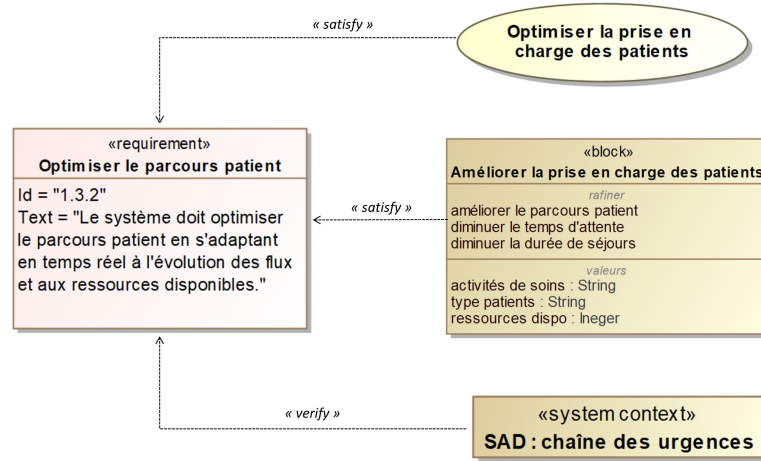


FIGURE 3.30 – Exemple de traçabilité SysML

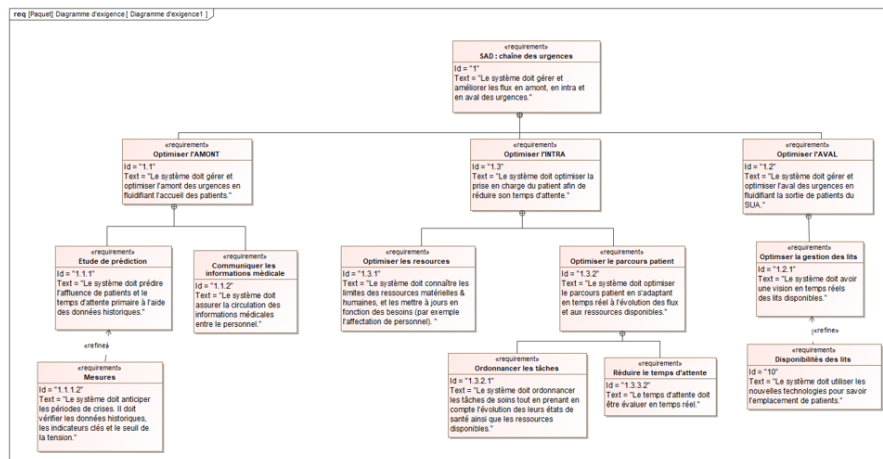


FIGURE 3.31 – Diagramme d'exigences du SAD chaîne des urgences

Approche hybride et auto-adaptative pour l'aide à l'ordonnancement des tâches de soins à compétences multiples

4.1 Introduction

Nous proposons dans ce chapitre une approche d'optimisation hybride et auto-adaptative pour l'aide à l'ordonnancement des tâches de soins à compétences multiples. Cette approche est basée sur une architecture informatique de résolution à base d'agents optimisateurs permettant à ces derniers de s'auto-adapter afin d'accélérer la convergence vers de bonnes solutions. L'auto-adaptation des agents est assurée par un algorithme d'apprentissage par renforcement. Ce choix d'algorithme est justifié par le besoin de diriger la recherche vers des zones plus prometteuses dans l'espace de recherche de solutions. Dans ce cadre, l'idée directrice de ce chapitre est de développer une approche alliant l'optimisation, les systèmes multi-agents et l'apprentissage dans le but de minimiser le temps d'attente global moyen des patients aux urgences. En outre, dans la dernière partie de ce chapitre, nous présentons des algorithmes pour la gestion des lits d'aval. Ces algorithmes ont pour objectif de garantir une meilleure continuité de soins pour les patients tout en optimisant leur temps d'attente dans la zone de transfert, appelée aussi zone E. Cette dernière représente la passerelle entre les urgences et les services d'aval.

4.2 Formulation mathématique du problème d'ordonnancement en intra-SUA

Les deux types de modélisation (modélisation workflow et SysML) présentés dans le chapitre précédent sont soumis à des contraintes (par exemple des contraintes de précédence) et à des

exigences (par exemple des exigences de ressources matérielles et humaines). Dans l'objectif de satisfaire ces contraintes et ces exigences, l'élaboration d'un système d'aide à l'ordonnancement des tâches de soins à compétences multiples est indispensable. Ce type de problème d'ordonnancement est connu comme un problème d'optimisation combinatoire NP-difficile (cf. section 2.4.1.2). Il existe une similitude entre le problème d'ordonnancement étudié et le problème d'ordonnancement de type job-shop flexible où les tâches sont les soins de santé des patients; les machines sont les ressources humaines et matérielles (médecins, box, lits, etc.) et les séquences d'opérations sont les parcours des patients en fonction de leurs pathologies. L'approche d'ordonnancement proposée doit à la fois assurer l'attribution appropriée du personnel soignant aux tâches de soins et offrir le séquençage de ces dernières avec la détermination de leurs dates de début d'exécution. Ceci doit être réalisé tout en prenant en compte diverses contraintes et en optimisant un certain nombre de critères. Dans cette section, le critère à optimiser est le temps d'attente global moyen des patients.

En outre, le problème d'ordonnancement traité doit tenir compte de l'interférence entre les trois types de patients : les patients programmés (PP), les patients non programmés (PNP) et les patients urgents non programmés (PUNP). Cette interférence exige une articulation efficace entre les différents types de patients afin d'optimiser leur prise en charge dans le SUA. Dans ce qui suit, nous présentons la formulation mathématique des différents paramètres, variables, contraintes et critères indispensables pour l'obtention d'un ordonnancement réalisable et optimal.

4.2.1 Les paramètres et variables de décision

Les paramètres, les notations et les variables de décisions de notre formulation sont énumérés ci-dessous :

Les paramètres et les notations

- NP : un ensemble de n patients à traiter, $NP = \{P_1, P_2, \dots, P_n\}$;
- MS : un ensemble de m membres de personnel soignant, $MS = \{M_1, M_2, \dots, M_m\}$;
- TP : un ensemble de types de patients, $TP = \{PP, PNP, PUNP\}$ avec PP les patients programmés, PNP les patients non programmés et $PUNP$ les patients urgents non programmés;
- PF : un sous-ensemble de patients ayant au moins une opération de soins fractionnables, $PF \subseteq NP$;
- PNF : un sous-ensemble de patients ayant des opérations de soins non fractionnables, $PNF \subseteq NP \setminus PF$;
- B : l'ensemble de tous les lieux de soins du SUA;
- C_b^B : la capacité du lieu de soins b , $b \in B$;
- T : le nombre de périodes du créneau horaires dans l'horizon d'optimisation H , où le créneau $T + 1$ indique que la période de créneau est située en dehors de l'horizon d'ordonnancement en cours H ;
- w_z : pénalité liée au déplacement du patient entre divers lieux du SUA;
- w_c : pénalité liée à l'utilisation du couloir c ;
- w_t^b : pénalité liée au dépassement de la capacité du lieu b à la période t .

Les variables de décisions

- V_{otb} : le nombre de patients de type o avec $o \in TP$, ayant des opérations de soins fractionnables placées à la période t dans un lieu b ;
- X_{jtb} : booléen, mis à 1 si une opération de soins du patient j est placée à la période t dans un lieu b , 0 sinon;
- Y_{jmt} : booléen, mis à 1 si le personnel soignant m effectue une ou plusieurs opérations du patient j placées à la période t , 0 sinon;
- C_{lk}^{ab} : booléen, mis à 1 si les membres du personnel soignant k et l ayant en commun des patients, sont placés dans deux lieux distincts a et b , à deux périodes consécutives ou avec un décalage, 0 sinon;
- C_{jtc} : booléen, mis à 1 si un ou plusieurs membres du personnel soignant réalisent une ou plusieurs opérations de soins à une période t au patient j dans le couloir c , 0 sinon;
- C_{jtb} : booléen, mis à 1 si plusieurs patients sont pris en charge à la période t dans le lieu b , dont la charge ne dépasse pas la capacité du lieu, 0 sinon;
- ta_j : la date d'arrivée du patient j ;
- t_{ij} : la date de début d'exécution de la tâche de soins i du patient j ;
- f_{ij} : la date de fin d'exécution de la tâche de soins i du patient j ;
- I_j : le nombre total de tâches de soins à réaliser pour le patient j ;
- S_{ij}^t : booléen, mis à 1 si la tâche de soins i du patient j est programmée à la période t , 0 sinon;
- M_{jk}^t : booléen, mis à 1 si le personnel soignant k traite le patient j à la période t , 0 sinon;
- L_j^t : booléen, mis à 1 si le lieu de consultation l est disponible à la période t , 0 sinon.

4.2.2 Les contraintes

La mise en place des contraintes permet de vérifier la faisabilité de la solution proposée. Ainsi, établir un ordonnancement réalisable, c'est définir un ordre d'exécution de l'ensemble des tâches qui satisfait les contraintes. Dans notre cas, ces tâches sont soumises à des contraintes de différents types :

1. **Les contraintes rigides** : elles conditionnent la faisabilité et la réalisabilité de la solution.

- l'équation 4.1 vérifie que la somme des opérations fractionnables allouées dans un lieu de traitement b à la période t ne doit pas dépasser la capacité de ce lieu :

$$\forall b \in B, \forall t \in T, \sum_{o \in TP} V_{otb} \leq C_b^B \quad (4.1)$$

- l'équation 4.2 vérifie qu'une opération de soins non fractionnable doit être effectuée dans un seul lieu de traitement :

$$\forall j \in PNF, \sum_{t \in T} \sum_{b \in B} X_{jtb} = 1 \quad (4.2)$$

- l'équation 4.3 vérifie que deux membres du personnel soignant k, l qui ont des patients en commun ne peuvent pas être affectés à la même période ou dans les deux périodes de chevauchement t et u :

$$\forall j \in NP, Y_{jkt} + Y_{jlu} \leq 1 \quad (4.3)$$

- l'équation 4.4 vérifie qu'un lieu de traitement ne doit pas être employé pour deux patients en deux périodes de chevauchement t et u :

$$\forall j_1, j_2 \in NP, \forall b \in B, X_{j_1tb} + X_{j_2ub} \leq 1 \quad (4.4)$$

2. **Les contraintes flexibles** : elles permettent d'évaluer la robustesse de la solution.

- l'équation 4.5 permet d'appliquer une pénalité de déplacement C^{ab} à chaque fois que les traitements sur les mêmes patients sont effectués dans deux périodes consécutives ou avec décalage par deux membres du personnel soignant différents k et l dans deux lieux différents a et b :

$$C^{ab} = w_z \sum_{k,l \in MS} C_{lk}^{ab} \quad (4.5)$$

- l'équation 4.6 permet d'appliquer une pénalité C^c à chaque fois qu'un ou plusieurs patients sont pris en charge dans les couloirs du SUA :

$$\forall t \in T, C^c = w_c \sum_{j \in NP} C_{jtc} \quad (4.6)$$

- l'équation 4.7 permet d'appliquer une pénalité E^b à chaque fois que deux ou plusieurs patients sont pris en charge à la même période t et dans le même lieu b :

$$\forall t \in T \text{ et } \forall b \in B, E^b = w_t^b \sum_{j \in NP} C_{jtb} \quad (4.7)$$

4.2.3 Le critère temps d'attente aux urgences

Le temps d'attente est un indicateur de qualité à la fois complexe et pertinent, la figure 4.1 montre un exemple de discrétisation de ce temps d'attente dans les structures des urgences. À partir de la même figure, nous pouvons déduire que la gestion de ce dernier doit être réalisée avec délicatesse étant donné la présence de l'interférence entre les trois types de patients (PP, PNP et PUNP). Cette interférence impacte forcément les durées du temps d'attente dans le SUA. En effet, pour chaque type de patient, il existe un intervalle de temps avant lequel il est recommandé de le prendre en charge pour que son état ne s'aggrave pas et que sa vie ne soit pas mise en danger. En revanche, cet intervalle de temps ne doit pas être déraisonnable pour les patients présentant des signes de faible gravité pendant que les patients présentant des signes de gravité plus élevée sont servis. Dans ce cadre, la question qui se pose est alors la suivante : pourquoi le critère temps d'attente aux urgences est-il complexe ?

La principale explication de cette complexité repose sur la spécificité du parcours patient aux urgences qui comporte plusieurs étapes indispensables. Dans chacune de ces étapes, il existe obligatoirement une période d'attente (cf. figure 4.1) :

- étape 1 (temps d'attente subi) : le patient doit tout d'abord se signaler à l'accueil pour remplir les formalités administratives. Ensuite il doit être orienté par l'infirmier(ère) d'accueil et d'orientation (IAO) qui évalue son état de gravité et organise sa prise en charge. L'ordre de passage dépend non seulement de la gravité de l'état de santé du patient mais également de celle des autres patients présents dans le service. Ce temps d'attente au moment de l'accueil et du triage correspond à 4,5% du temps d'attente global aux urgences.
- étape 2 (temps d'attente subi) : le patient doit attendre son tour pour qu'il soit examiné par un médecin. Ce temps d'attente représente 17,4% (mise en box) + 13,5% (consultation) du temps d'attente global aux urgences.
- étape 3 (temps d'attente voulu) : le médecin va prodiguer les soins nécessaires au patient et demander si besoin des examens complémentaires (e.g. bilan sanguin, radios, scanner, IRM, échographie) nécessitant du temps pour les organiser mais également pour obtenir les résultats. Ce temps d'attente au moment de la réalisation des examens complémentaires correspond à 25% du temps d'attente global aux urgences.
- étape 4 (temps d'attente voulu) : dès l'obtention des résultats, le patient est revu par le médecin. Ce dernier l'oriente si besoin vers un service hospitalier ou vers une consultation par un spécialiste, lui prescrit éventuellement un traitement ou lui fournit une attestation de sortie. Ce temps d'attente correspond respectivement soit à 11,9% ou 11,9% + 5% ou à 11,9% + 5% + 4,4% du temps d'attente global aux urgences.
- étape 5 (temps d'attente subi) : pour assurer la continuité de la prise en charge, le patient doit attendre jusqu'à l'obtention d'un lit d'aval disponible. Ce temps d'attente représente le temps d'attente moyen entre la décision d'admission par le médecin et l'admission effective dans un service d'aval. Au CHU de Lille, le patient attend sur un brancard à un horaire fixé dans la zone E. Ceci correspond à 12,5% (attente pour un lit) du temps d'attente global aux urgences.
- étape 6 (temps d'attente subi) : suite à la décision du médecin, le patient peut attendre dans la zone E son transfert hors établissement faute de lits. Ce temps correspond à 12,5% (attente pour un lit) + 1,2% (attente du transport) du temps d'attente global aux urgences.
- étape 7 (temps d'attente subi) : correspond au temps d'attente pour remplir les formalités administratives de sortie. Il représente 4,6% du temps d'attente global aux urgences.

L'objectif principal de ce chapitre est d'utiliser des algorithmes à base d'IA pour optimiser à la fois le temps d'attente global moyen des patients (premier critère) et le temps d'attente pour obtenir un lit d'aval disponible (deuxième critère). Dans ce cadre, nous développons une approche collaborative d'aide à l'ordonnancement des patients. Cette approche a pour objectif d'optimiser le premier critère en intra-urgences, formalisé par l'équation 4.8 correspond au temps d'attente global moyen W . Les solutions d'ordonnancement manipulées par cette approche sont représentées par un modèle hypercubique détaillé dans la section suivante (cf. 4.3).

$$W = \text{Min} \left(\frac{\sum_{j=1}^n (\max(0, t_{1,j} - ta_j) + \sum_{i=1}^{I_j} \max(0, t_{i+1,j} - f_{i,j}))}{n} \right) \quad (4.8)$$




FIGURE 4.1 – La discrétisation du temps d'attente aux urgences

Pour optimiser le deuxième critère, une évaluation des indicateurs permettant d'améliorer la gestion des lits d'aval aux urgences est nécessaire. Ces indicateurs portent essentiellement sur des données récoltées aux urgences. Leur évolution ne dépend pas seulement de l'aval mais elle permet au "bed manager" face à des flux des patients non programmés d'obtenir une vision globale de l'évolution de la disponibilité des lits. Dans ce cadre, nous développons des algorithmes (cf. section 4.6) qui permettent de remplir en temps réel un tableau de bord (cf. section 5.3). Ce dernier a pour rôle de suivre l'évolution de l'ensemble des informations liées aux services d'aval. Les informations suivantes peuvent être retenues :

- le temps d'attente moyen entre la décision d'admission et l'admission effective dans un service d'aval ;
- le nombre de patients sur un brancard en attente de lit à un instant donné ;
- le nombre de patients transférés hors établissement par manque de lit.

4.3 Modèle hypercubique de la solution d'ordonnancement

Afin de présenter des solutions exploitables directement par les professionnels de santé avec prise en compte des aspects temporels, organisationnels et spatiaux, nous choisissons de modéliser notre solution d'ordonnancement par un modèle hypercubique à quatre dimensions. Ces dernières sont représentées par quatre axes interconnectés : (1) le personnel soignant ; (2) le patient ; (3) le lieu des opérations de soins et (4) le temps (figure 4.2(a)). L'axe temps est défini par des horizons temporels, divisés en plusieurs périodes qui sont à leur tour subdivisées en plusieurs créneaux horaires. Les périodes n'ont pas nécessairement la même longueur et le nombre de créneaux dans chaque période peut être différent. La figure 4.3 représente un exemple d'horizon temporel où chaque créneau horaire contient la liste des opérations de soins à réaliser. Cette liste contient à la fois l'affectation du personnel soignant aux opérations et le lieu de leur prise en charge. Par exemple, la figure 4.2(b) montre une affectation parallèle de deux membres du personnel soignant m_1 et m_2 respectivement aux patients j' et j dans les périodes 2 et 3 dans les Box_1 et Box_2 . La même figure 4.2(b) présente l'exemple d'un patient qui nécessite deux compétences pour le soigner. En effet le patient j a besoin des compétences m_2 et m_3 pour la réalisation de son traitement dans le même créneau et dans le même box (Box_2).




FIGURE 4.2 – Modèle hypercube à quatre dimensions




FIGURE 4.3 – Représentation d'un horizon d'optimisation

4.4 Approche métaheuristique hybride à base d'agents

Les approches hybrides ont gagné en popularité car elles ont permis l'obtention des meilleurs résultats pour divers problèmes d'optimisation combinatoire (SILVA et al. 2018). Dans la littérature, il existe plusieurs stratégies pour élaborer une hybridation entre deux méthodologies (cf. section 2.4.2.3). Dans cette section, nous présentons une approche hybride qui combine les métaheuristiques avec le système multi-agents pour résoudre les problèmes d'optimisation de la prise en charge des patients en intra-SUA. L'utilisation des systèmes multi-agents dans le contexte de l'optimisation est une option cruciale dans le processus d'hybridation permettant ainsi le développement de structures génériques (AJMI et al. 2020). Ces dernières favorisent l'interaction entre les métaheuristiques indépendamment des problèmes à traiter. Il existe ainsi, trois stratégies pour l'hybridation des métaheuristiques par les agents (cf. la section 2.7) : le SMA avec décomposition de l'espace de recherche ; le SMA avec décomposition de métaheuristique et le SMA avec agents métaheuristiques. Dans le cadre de cette thèse, nous testons la troisième stratégie à savoir : le SMA avec agents métaheuristiques, dans laquelle chaque métaheuristique est implémentée sous la forme d'un agent autonome interagissant d'une manière coopérative dans l'environnement. Cette interaction entre les agents est réalisée par l'échange d'informations dans l'espace de recherche de solutions pour atteindre un objectif prédéfini. En effet, nous choisissons trois métaheuristiques pour résoudre le problème d'ordonnancement des tâches de soins à compétences multiples, qui sont : la recherche tabou (RT, cf. algorithme 1), le recuit simulé (RS, cf. algorithme 2) et l'algorithme génétique (AG, cf. algorithme 3) dont les opérateurs de croisement (cf. algorithme 4) et mutation sont contrôlés pour générer des solutions viables. La figure 4.4 montre un exemple de croisement. Ces trois métaheuristiques manipulent une solution complète du problème (chromosome) modélisée par un hypercube (cf. section 4.3). L'incorporation de chacune de ces métaheuristiques dans le comportement d'un agent permet d'atteindre une performance et une qualité élevées dans la résolution de notre problème d'ordonnancement. Chaque agent-métaheuristique est responsable de l'exécution de son algorithme et en même temps, peut utiliser les solutions/critères fournis par les autres agents-métaheuristiques pour améliorer les paramètres de son algorithme. Il s'agit ici d'une optimisation collaborative, dans

		Parent 1							Parent 2							
		0-5	5-10	10-15	15-20	20-25	25-30	30-35	0-5	5-10	10-15	15-20	20-25	25-30	30-35	
P1		0	0	1	1	0	0	1	P1	1	1	0	0	1	0	0
P2		1	1	0	0	0	0	0	P2	0	0	0	0	1	1	0
P3		0	1	0	0	1	1	1	P3	1	0	0	1	1	1	0
P4		0	0	1	1	1	0	1	P4	0	1	1	1	0	0	1
P5		1	1	1	0	0	0	0	P5	0	0	1	1	1	0	0
P6		1	0	1	0	0	0	0	P6	0	1	0	0	0	0	1

		Fils 1							Fils 2							
		0-5	5-10	10-15	15-20	20-25	25-30	30-35	0-5	5-10	10-15	15-20	20-25	25-30	30-35	
P1		0	0	1	1	0	0	1	P1	1	1	0	0	1	0	0
P2		0	0	0	0	1	1	0	P2	1	1	0	0	0	0	0
P3		1	0	0	1	1	1	0	P3	0	1	0	0	1	1	1
P4		0	1	1	1	0	0	1	P4	0	0	1	1	1	0	1
P5		1	1	1	0	0	0	0	P5	0	0	1	1	1	0	0
P6		1	0	1	0	0	0	0	P6	0	1	0	0	0	0	1

FIGURE 4.4 – Exemple de croisement

laquelle une équipe de trois agents-métaheuristiques travaillent ensemble et utilisent leurs expériences et leurs connaissances de l'environnement pour résoudre efficacement le problème d'ordonnancement des tâches de soins. Nous présentons également un protocole de collaboration à deux modes entre ces agents : un mode "amis" et un mode "ennemis" (cf. section 4.4.2).

Dans ce cadre, nous présentons en premier lieu un protocole de collaboration générique entre les agents-métaheuristiques : AAG, ART et ARS et en deuxième lieu, les deux instantiations de ce protocole qui correspondent aux modes "amis" et "ennemis".

Algorithme 1 : Recherche Tabou

```

1 Input
2  $x$  : solution initiale;
3  $N$  : taille maximale de la liste tabou;
4  $iter_{max}$  : nombre maximal d'itération sans amélioration de la meilleure solution trouvée;
5 Output
6  $x_{best}$  : la meilleure solution trouvée;
7 initialization
8  $iter \leftarrow 0$ ;
9  $TabuList \leftarrow []$ ;
10  $x_{best} \leftarrow x$ ;
11 while ( $iter < iter_{max}$ ) do
12    $iter \leftarrow iter + 1$ ;
13    $SNS \leftarrow$  Générer_solutions_voisines( $x, 4$ ), (cf. algorithme 7);
14    $x' \leftarrow$  le meilleur élément de  $SNS$  qui n'existe pas dans  $TabuList$ ;
15   if ( $f(x') > f(x)$ ) then
16     ajouter  $x$  à la  $TabuList$ ;
17   end
18   if  $length$  of  $TabuList > N$  then
19     supprimer le premier élément de  $TabuList$ ;
20   end
21   if ( $f(x) < f(x_{best})$ ) then
22      $x_{best} \leftarrow x$ ;
23      $iter \leftarrow 0$ ;
24   end
25 end

```

Algorithme 2 : Recuit Simulé

```

1 Input
2  $x$  : solution initiale;
3  $T_0$  : température initiale;
4  $\alpha$  : coefficient de refroidissement;
5  $iter_{max}$  : nombre maximal d'itération;
6 Output
7  $x_{best}$  : la meilleure solution trouvée;
8 initialization
9  $K \leftarrow False$ ;
10  $x_{best} \leftarrow x$ ;
11  $T \leftarrow T_0$ ;
12 while not  $K$  do
13    $iter \leftarrow 0$ ;
14    $K \leftarrow True$ ;
15   while ( $iter < iter_{max}$ ) do
16      $iter \leftarrow iter + 1$ ;
17      $SNS \leftarrow$  Générer_solutions_voisines ( $x, 4$ ), (cf. algorithme 7);
18      $x' \leftarrow$  le meilleur élément de  $SNS$  ;
19      $\delta f \leftarrow f(x') - f(x)$ ;
20      $proba \leftarrow \exp(-\delta f/T)$ ;
21     choisir  $p$  aléatoirement dans  $[0, 1]$ ;
22     if ( $\delta f > 0$  or  $p < proba$ ) then
23        $x \leftarrow x'$ ;
24        $K \leftarrow False$ ;
25     end
26     if ( $f(x) < f(x_{best})$ ) then
27        $x_{best} \leftarrow x$ ;
28        $iter \leftarrow 0$ ;
29     end
30   end
31    $T \leftarrow \alpha T$ ;
32 end

```

4.4.1 Protocole de collaboration générique

Afin de modéliser notre protocole de collaboration générique pour l'optimisation (PCG) d'une manière précise et non ambiguë, nous choisissons d'utiliser le formalisme de spécification des systèmes à événements discrets (*Discrete Event System specification* DEVS). Cette spécification est complémentaire à la représentation graphique donnée par la modélisation Agent UML (AUML) (WAGNER 2003). Nous adoptons donc en plus la modélisation AUML pour une représentation graphique complémentaire à la forme formelle afin de donner un aspect visuel au PCG. À un instant donné (t), nous avons un ensemble de N agents $A = \{A_1, A_2, \dots, A_N\}$. Chaque agent A_i ($i \in [1, N]$) est modélisé comme un DEVS atomique car il encapsule à la fois sa structure et son comportement : $A_i = \langle X, I, Y, S, \delta_{int}, \delta_{ext}, \lambda, ta \rangle$, le tableau 4.1 décrit la signification de chacun de ces symboles.

4.4.1.1 Le raisonnement interne de l'agent-métaheuristique

Il existe deux types d'événements : internes et externes. Les événements internes sont générés par la dynamique interne de l'agent (i.e. le comportement intra agent) alors que les événements externes/exogènes sont indépendants (i.e. l'interaction avec les autres agents du système). Un événement externe peut être un événement d'entrée non généré par l'agent ou un événement de sortie représentant la réaction de l'agent. L'état d'un agent correspond à un statut basé sur un certain nombre de composants mentaux tels que : la mémoire, les perceptions, les engagements, les attentes, les buts, les croyances et les intentions. Dans notre PCG, nous distinguons les états

Algorithme 3 : Algorithme Génétique

```

1 Input
2  $P$  : population initiale;
3  $N$  : nombre d'individus sélectionnés à chaque génération;
4  $N_g$  : nombre de génération;
5  $p_m$  : probabilité de mutation;
6  $p_c$  : probabilité de croisement;
7 Output
8  $x_{best}$  : la meilleure solution trouvée;
9 initialization
10 for  $g = 1$  to  $N_g$  do
11    $S \leftarrow N$  individus choisis d'une manière aléatoire de  $P$ ;
12   while  $S$  n'est pas vide do
13      $q_1 \leftarrow$  un élément aléatoire de  $S$ ;
14     supprimer  $q_1$  de  $S$ ;
15     choisir  $p$  aléatoirement dans  $[0, 1[$ ;
16     if  $p < p_c$  then
17        $q_2 \leftarrow$  un élément aléatoire de  $S$ ;
18       supprimer  $q_2$  de  $S$ ;
19        $r_1, r_2 \leftarrow$  croisement( $q_1, q_2$ ) (cf. algorithme 4);
20       ajouter  $r_1$  et  $r_2$  dans  $P$ 
21     end
22   end
23    $S \leftarrow N$  individus choisis d'une manière aléatoire de  $P$ ;
24   while  $S$  n'est pas vide do
25      $q \leftarrow$  élément aléatoire de  $S$ ;
26     supprimer  $q$  de  $S$ ;
27     choisir  $p$  aléatoirement dans  $[0, 1[$ ;
28     if  $p < p_m$  then
29        $r \leftarrow$  Générer_solutions_voisines( $q, 1$ ) // mutation ( $q$ ) (cf. algorithme 7);
30       ajouter  $r$  dans  $P$ 
31     end
32   end
33 end
34  $x_{best} \leftarrow$  le meilleur élément de  $P$ ;

```

Algorithme 4 : Croisement (q_1, q_2)

```

1 Input
2  $q_1 \leftarrow S_p 1_{i,j}^t$  : parent 1;
3  $q_2 \leftarrow S_p 2_{i,j}^t$  : parent 2;
4 Output
5  $SS_e 1, SS_e 2$  : les solutions enfants obtenues suite au croisement de deux parents;
6 initialization
7 choisir  $(p_1, p_2)$  aléatoirement dans  $\llbracket 1, J-1 \rrbracket^2$  tels que  $p_1 < p_2$ ;
8  $S_e 1 \leftarrow S_p 1$ ;
9  $S_e 2 \leftarrow S_p 2$ ;
10 for  $j \leftarrow p_1$  to  $p_2$  do
11    $\forall i, t$   $S_e 1_{i,j}^t \leftarrow S_p 2_{i,j}^t$ ;
12    $\forall i, t$   $S_e 2_{i,j}^t \leftarrow S_p 1_{i,j}^t$ ;
13 end
14  $SS_e 1 \leftarrow$  Générer_Ord_Valide ( $S_e 1$ ) (cf. algorithme 5);
15  $SS_e 2 \leftarrow$  Générer_Ord_Valide ( $S_e 2$ ) (cf. algorithme 5);

```

Algorithme 5 : Ordo_Valide

```

1 Input
2  $S_{i,j}^t$  : liste des patients ordonnancée;
3 Output
4  $SS = \{S_{i,j}^t, M_m^t, L_j^t\}$  : solution complète d'ordonnancement et d'affectation des ressources aux patients;
5 initialization
6  $SMCT \leftarrow$  ensemble de toutes les tâches de soins médicaux à effectuer;
7  $M_m^t \leftarrow$  planning vide du personnel soignant;
8  $L_j^t \leftarrow$  planning des salles d'opération disponibles;
9 while  $SMCT \neq \emptyset$  do
10    $mct \leftarrow$  sélectionner la tâche de soins qui commence au plus tôt dans  $SMCT$ ;
11    $viable = True$ ;
12   for chaque compétence  $c$  nécessaire pour réaliser  $mct$  do
13     if un personnel soignant avec la compétence  $c$  est disponible pour exécuter  $mct$  then
14       trouver un personnel soignant  $m$  avec la compétence  $c$  disponible durant  $mct$ ; marquer  $m$  non disponible
15       durant  $mct$ , mettre à jour  $M_m^t$ ;
16     else
17        $S_{i,j}^t$  n'est pas viable;
18        $viable = False$ ;
19     end
20   if une salle d'opération est disponible pour réaliser  $mct$  then
21     trouver une salle d'opération  $op_r$  disponible durant l'exécution de  $mct$ ;
22     marquer  $op_r$  non disponible durant  $mct$ , mettre à jour  $L_j^t$ ;
23   else
24      $S_{i,j}^t$  n'est pas viable;
25      $viable = False$ ;
26   end
27   if  $viable = True$  then
28     supprimer  $mct$  de  $SMCT$ ;
29   end
30 end

```

Symbole	Signification
X	Ensemble d'entrées externes
I	Ensemble d'entrées internes
Y	Ensemble de sorties
S	Ensemble d'états séquentiels
$\lambda : S \rightarrow Y$	Fonction de sortie
$s \in S$	Un état séquentiel : contient les principales informations sur l'état de l'agent et notamment son état entre deux événements successifs
$ta : S \rightarrow \mathbb{R}_0^+$	Pas de temps de simulation
Q	L'ensemble d'états $Q = \{(s, e, LD) s \in S, 0 \leq e \leq ta(s)\}$
$\delta_{int} : Q \times I \rightarrow S$	La fonction de transition interne
$\delta_{ext} : Q \times X \rightarrow S$	La fonction de transition externe
e	Le temps écoulé depuis la dernière transition
LD	La loi de décision utilisée par l'agent pour décider de son action en fonction de ce qu'il perçoit dans son environnement (les offres reçues).
$q \in Q$	L'état total q

TABLEAU 4.1 – Description des symboles du formalisme utilisés (AJMI et al. 2020)




FIGURE 4.5 – La dynamique interne de l'agent

suivants :

- l'état de repos (QUIESC) à $t < t_{i0}$, avec t_{i0} le temps de démarrage de l'agent A_i et t_0 le temps de démarrage du système multi-agents.
- l'état du processus d'optimisation (OPTM).
- l'état d'analyse de la situation actuelle (ACS).
- l'état de déclenchement de DIC (déroulement d'interaction collective) et le choix de l'un de deux modes (i.e. amis ou ennemis).
- l'état de recherche des meilleurs paramètres (BPS).

L'état d'un agent évolue en fonction du déclenchement d'un événement interne ou externe à travers les fonctions de transition interne (δ_{int}) ou externe (δ_{ext}). La Figure 4.5 montre l'état dynamique de l'agent lorsqu'il collabore avec les autres agents d'optimisation. Nous pouvons remarquer ici que l'agent possède un comportement cyclique lui permettant d'être attentif à son environnement. Ce comportement est similaire au comportement "d'un chien de garde" : il est endormi si rien ne se passe et se réveille dès que l'agent perçoit quelque chose dans son environnement (i.e. événement externe). Lorsque $t < t_{i0}$, l'agent est dans un état de repos (QUIESC). Dès que le système le sollicite pour résoudre un problème d'optimisation combinatoire (POC), l'agent se réveille, initialise les paramètres de sa métaheuristique en fonction du POC à résoudre puis commence son activité à t_{i0} si l'événement X_{i0} correspond à l'ensemble des entrées de cet agent. Dans notre cas, X_{i0} contient le POC à résoudre et ses caractéristiques. Ensuite, dans l'intervalle $[t_{i0}, t_{i1}]$, A_i sélectionne sa meilleure solution courante (cur_sol_i) puis effectue une transition à t_{i1} (événement t_{i1}) vers l'état ACS sachant qu'à t_{i1} , il peut également recevoir les meilleures solutions courantes d'autres agents A_j du système. À $[t_{i1}, t_{i2}]$, l'agent A_i , commence l'état ACS, vérifie s'il a amélioré sa solution courante en calculant l'écart entre les deux dernières meilleures solutions α et β (avec la meilleure solution courante est α). Cet écart est noté par ϕ et calculé comme un taux de stagnation appartenant à son état interne : $\phi = (\beta - \alpha)/\alpha$.

Ce taux est comparé à un paramètre seuil noté ϵ . La transition suivante se produit à t_{i2} : si $\phi \leq \epsilon$, l'agent déclenche l'état DIC et selon le choix du mode d'interaction, le processus d'aide peut avoir lieu. En effet, cet agent envoie sa meilleure solution à l'agent A_j si elle est meilleure que cur_sol_j . Sinon, A_i injecte la cur_sol_j dans son processus d'optimisation. Si $\phi > \epsilon$, cela signifie que l'agent a amélioré (significativement) sa solution. Si l'agent A_i améliore sa solution ou si elle

est meilleure que celle de l'agent A_j , il passe à l'état BPS pour stocker la configuration actuelle qui sera utilisée plus tard, puis à l'état OPTM pour rechercher les réglages de paramètres les plus efficaces qui lui permettent d'améliorer sa solution actuelle.

4.4.1.2 La loi de décisions : LD

L'état total $q = (s, e, LD) \in Q$ dépend de l'état (s), du temps (e) écoulé depuis la dernière transition et de la loi de décision LD utilisée par l'agent pour sélectionner et classer les offres reçues d'autres agents et pour décider de son action. La dynamique de nos agents collaboratifs est pilotée par les lois de décisions suivantes :

- LD0 : l'agent se réveille, identifie le POC avec ses caractéristiques et décide de participer au processus d'optimisation collaborative;
- LD1 : l'agent déclenche le processus d'optimisation;
- LD2_A : l'agent envoie sa meilleure solution actuelle en fonction d'une valeur de taux d'aide TA (i.e. exprimer l'égoïsme d'un agent, mode "ennemi" cf. section 4.4.2) ou prend en compte la solution reçue dans son processus d'optimisation;
- LD2_B : l'agent met à jour ses propres paramètres ou demande l'interaction avec les autres agents par l'intermédiaire de DIC;
- LD3_A : l'agent sélectionne les meilleurs paramètres pour l'étape d'optimisation suivante;
- LD3_B : l'agent déclenche l'état DIC (cf. paragraphe ci-dessous)
- LD4 : l'agent poursuit le processus d'optimisation.

4.4.1.3 Le déroulement d'interaction collective : DIC

Dans le domaine SMA et dans le contexte d'une interaction directe, nous appelons agent initiateur, l'agent qui initie une conversation et déclenche ainsi un protocole. Les agents répondants sont appelés les agents participants. Il existe deux types de messages entre les agents dans le cadre d'une interaction directe : synchrones et asynchrones. Un message synchrone bloque l'agent expéditeur jusqu'à ce qu'il reçoive une réponse à son message et un message asynchrone permet à l'agent expéditeur de poursuivre son travail en attendant une réponse à son message. Les messages asynchrones sont clairement plus appropriés à notre système permettant aux agents de continuer à optimiser localement leur solution courante respective en attendant une réponse à leur demande d'aide.

Dans le PCG, les agents interagissent avec le langage de communication standard FIPA ACL¹ utilisé par la plateforme choisie pour les expérimentations (cf. chapitre 5). Un message entre deux agents A_i et A_j a obligatoirement un type, appelé performatif (e.g. REQUEST, REQUEST_WHEN, REFUSE, AGREE) et peut contenir des informations comme la solution actuelle trouvée par l'agent.

En effet, la figure 4.6 présente le protocole de collaboration entre agents. Ce protocole fonctionne comme suit : dès que l'agent A_i décide de demander de l'aide aux autres agents A_j ($j \neq i$ et $j \in [1, N]$), A_i envoie à A_j un message REQUEST_WHEN demandant de l'aide si et seulement si le message courant de l'agent A_j (cur_sol_j) est meilleur que (symbole >>) son

1. www.fipa.org




FIGURE 4.6 – Le DIC proposé

propre message courant (cur_sol_i) transféré en paramètre. Si c'est le cas, l'agent A_j propose sa solution courante (cur_sol_j) à l'agent A_i et refuse sinon. Si l'agent A_j propose sa solution courante (cur_sol_j) à l'agent A_i , ce dernier vérifie si son éventuelle nouvelle solution courante est meilleure que la solution reçue puisque les agents continuent à optimiser en attendant les réponses des autres (messages asynchrones). Si c'est le cas, l'agent refuse la solution reçue (en la proposant à l'agent A_j) et accepte sinon (performatif AGREE).

4.4.2 Instantiation du PCG : amis et ennemis

Les modèles d'instantiation du PCG sont générés en utilisant des règles simples qui les provoquent. Dans la communauté des systèmes multi-agents il existe un modèle connu sous le nom de "Héros et Lâches" (Heroes and Cowards) (SWEENEY et MEADOWS 2010), (WILENSKY et RAND 2015) utilisé pour illustrer comment des règles simples peuvent produire des comportements collectifs complexes. Ces comportements sont très difficiles à reproduire en utilisant des techniques de modélisation classiques. Les modèles d'instantiation "amis" et "ennemis" sont des modèles globaux complexes par les interactions entre les agents qui suivent des règles comportementales simples et partagent le même espace mémoire (EMP) de solutions. Avant de détailler ces modèles, nous présentons les différentes caractéristiques de l'EMP.

L'espace mémoire partagé (EMP) : Les bonnes solutions d'ordonnancement trouvées par chaque agent-métaheuristique sont proposées pour être stockées dans l'EMP et peuvent être

mises à disposition à d'autres agents à la fin de chaque itération.

La taille maximale de l'EMP est un paramètre du problème et l'ajout de nouvelles solutions d'ordonnancement est contrôlé par l'algorithme 6, afin de réguler sa mise à jour et de maintenir la diversité des solutions. L'objectif principal de l'algorithme 6 est de faire en sorte que les agents-métaheuristiques évitent une convergence prématurée en diversifiant autant que possible les solutions partagées dans l'EMP. En même temps, la meilleure solution existante (élite) dans l'EMP est toujours mise à jour à chaque insertion, et son élimination est interdite.

Mode amis : dans ce mode, les trois agents-métaheuristiques collaborent en tant qu' "amis", cela signifie que l'interaction passe par l'échange d'informations spécifiques entre eux dans l'environnement de recherche de solutions. Les informations partagées dans ce mode sont donc : la solution complète du problème et sa valeur de critère. Ces informations sont stockées dans un espace mémoire partagé (EMP) en utilisant un algorithme original permettant la vérification de la diversité des solutions (cf. algorithme 6). À chaque fois qu'un agent-métaheuristique est exécuté, il prend en entrée la meilleure solution dans l'EMP. S'il arrive à trouver une solution meilleure que la solution initiale, il intègre cette nouvelle solution dans l'EMP. Après chaque itération du processus de recherche l'EMP est mis à jour (l'état BPS du PCG). En effet, chaque agent-métaheuristique effectue d'une manière autonome son processus de recherche particulier (i.e. son schéma métaheuristique) tout en utilisant de manière coopérative les solutions produites par les autres agents. Par conséquent, ce mode amis permet aux agents d'interagir pour atteindre un objectif global qui représente : l'identification de la valeur de critère et de la solution optimale global du problème d'optimisation.

Mode ennemis : dans ce mode, les agents-métaheuristiques fonctionnent sous la forme d'un système en compétition. Ils ne partagent plus leurs solutions mais ils partagent uniquement la meilleure valeur courante de critère d'optimisation. Donc chaque agent-métaheuristique cherche la solution viable de manière "égoïste" sans la communiquer aux autres agents-métaheuristiques. Si la valeur de critère de l'agent-métaheuristique est meilleure que celle reçue, il renvoie un message à l'émetteur contenant sa valeur de critère afin de réévaluer et d'affiner à nouveau sa solution. Si la valeur de critère reçue est meilleure, l'agent récepteur met à jour ses paramètres afin d'améliorer sa solution. En effet, l'objectif de l'agent-métaheuristique est de battre le record de l'agent-métaheuristique précédent (i.e. ils sont en compétition). Après plusieurs itérations, les agents doivent trouver un consensus pour décider collectivement de la solution ainsi que de la valeur de critère qui sont stockées dans l'EMP (l'état BPS). Ce mode favorise donc le comportement individualiste de chaque agent-métaheuristique non seulement pour trouver la meilleure solution mais aussi, pour améliorer continuellement cette solution.

Dans chaque mode (amis ou ennemis), chaque agent-métaheuristique peut jouer le rôle d'initiateur ou le rôle de répondeur de la conversation (cf. section 4.4.1.3). Le choix du rôle est déterminé d'une manière aléatoire. Les objectifs du protocole de collaboration "amis" et "ennemis" sont de guider la recherche vers des zones plus prometteuses dans l'espace de recherche de solution, d'améliorer le résultat final et d'accélérer la convergence (figure 4.7). Face à un environnement dynamique tel que les urgences, nous souhaitons augmenter l'autonomie de nos agents-métaheuristiques. Pour se faire, nous avons décidé d'intégrer une méthode d'apprentissage automatique dans notre approche collaborative. L'intégration de cette technique d'IA supplémentaire permet à nos agents-métaheuristiques de s'auto-adapter face à des situations imprévues.

Algorithme 6 : Contrôler la diversité de l'EMP

```

1 Input
2  $CS$  : solution courante à insérer dans l'EMP;
3  $NB$  : nombre des solutions dans l'EMP;
4  $R$  : nombre minimum de créneaux différents (contenant des tâches de soins différentes) pour qu'une solution soit considérée
différente d'une autre solution;
5  $DT$  : niveau de diversité;
6  $Max_{EMP}$  : le nombre maximum de solutions pouvant être incluses dans l'EMP;
7  $S_{i,j}^t$  : booléen, égal à 1 si la tâche de soins  $i$  du patient  $j$  est programmée dans le créneau  $t$  et égal à 0 sinon;
8  $S_{k,i,j}^t$  : est la solution  $S_{i,j}^t$ ; numéro  $k$  dans l'EMP;
9 Output
10 l'insertion éventuelle de  $CS$  dans l'EMP;
11 Begin
12  $d \leftarrow 0$  // le nombre de solutions dans l'EMP différent de  $CS$ ;
13 for  $k = 1$  to  $NB$  do
14   // parcourir toutes les solutions dans l'EMP;
15    $\lambda\_slot = 0$  // le nombre de créneaux contenant différentes tâches de soins dans l'EMP par rapport aux  $CS$ ;
16   for  $t = 1$  to  $T$  do
17     for  $j = 1$  to  $J$  do
18       for  $i = 1$  to  $I$  do
19         if  $(|CS_{i,j}^t - S_{k,i,j}^t| = 1)$  then
20            $\lambda\_slot = \lambda\_slot + 1$ 
21   if  $(\lambda\_slot \geq R)$  then
22      $d = d + 1$ 
23 if  $(\lambda\_slot = 0)$  then
24   La solution existe déjà dans l'EMP;
25 else
26   if  $(d/NB \geq DT)$  then
27     if  $(fitness(CS)$  est meilleure que la  $fitness$  de la pire solution dans l'EMP) then
28       if  $(NB < Max_{SMS})$  then
29         insertion de  $CS$  dans l'EMP;
30       else
31         éliminer la plus mauvaise solution dans l'EMP;
32         insérer  $CS$  dans l'EMP;
33 end

```

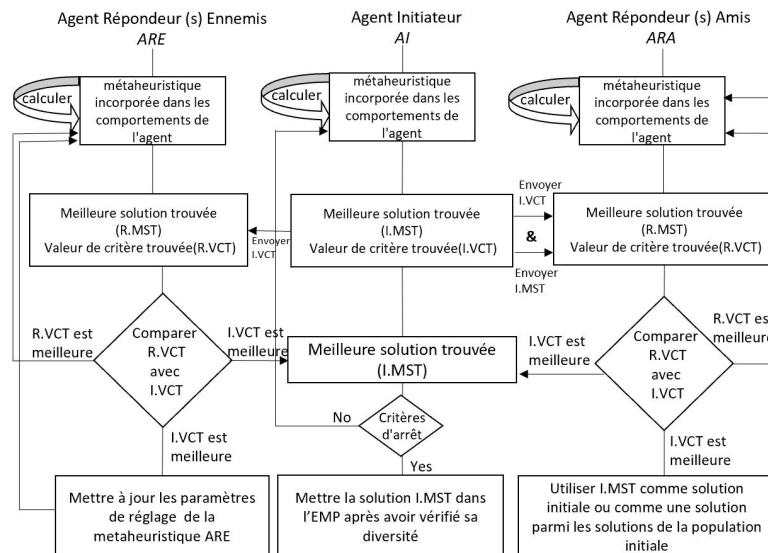


FIGURE 4.7 – Les modes d'interaction entre les agents

4.5 Auto-adaptation des agents par l'apprentissage

Dans cette section, nous présentons l'aspect auto-adaptatif de nos agents-métaheuristiques. Cet aspect utilise l'apprentissage par renforcement (cf. section 2.5.1), basé sur l'algorithme Q-Learning. Ce dernier permet de configurer un ensemble recyclé des règles d'exploration et d'exploitation pour produire de nouveaux schémas d'optimisation. Dans cette méthode d'apprentissage, il n'y a pas de données d'entrée/sortie, les données d'entraînement proviennent donc directement de l'environnement. L'idée est que les agents tirent parti de leurs expériences pour sélectionner un environnement en fonction d'actions et de tâches prédéfinies afin d'améliorer leurs performances. Le caractère stochastique de l'environnement des urgences qui, bien qu'un peu négligé dans la littérature, est important en pratique. En effet, cet environnement peut être étudié comme un processus de décision markovien (PDM) où un agent prend des décisions avec des résultats aléatoires. Ce PDM est considéré comme l'architecture de base de l'apprentissage par renforcement. Un PDM est décrit par un tuple de (ES, EA, R, T, γ) avec ES l'espace d'état, EA l'espace d'action, R la récompense, T la probabilité de transition et γ le facteur d'actualisation.

4.5.1 Formulation de l'espace d'états

L'espace d'états (ES) est composé d'un ensemble de solutions voisines dont chacune représente une solution complète du problème d'ordonnancement des patients. Pour générer ces états nous avons construit l'algorithme 7 en utilisant la variable NS comme un type énuméré contenant une structure à quatre voisinages : $NS = (MID, MIS, SDMS, SSMS)$:

- MID : insertion multiple dans différents corps médicaux (cf. figure 4.9);
- MIS : insertion multiple dans le même personnel soignant (cf. figure 4.10);
- $SDMS$: permutation entre différents personnels soignants (cf. figure 4.11);
- $SSMS$: échange des tâches dans le planning d'un personnel soignant (cf. figure 4.12).

Nous utilisons l'équation 4.9 pour vérifier la faisabilité et la réalisabilité de chaque solution d'ordonnancement. Cette équation s'assure qu'à chaque fois qu'une tâche de soins i d'un patient j est programmée dans un créneau t , un personnel soignant m et un box l lui sont assignés dans le même créneau pour la réalisation de cette tâche.

$$1 \leq \sum_{t=1}^T \sum_{j=1}^n S_{i,j}^t = \sum_{t=1}^T \sum_{l=1}^{card(B)} L_l^t \leq \sum_{t=1}^T \sum_{k=1}^m M_{k,j}^t \quad (4.9)$$

La figure 4.8 montre une solution d'ordonnancement de quatre patients. Le traitement du patient 1 nécessite quatre tâches de soins et pour chacun des 3 autres patients, seules trois tâches de soins sont nécessaires. Nous disposons de quatre ressources médicales (4 médecins) et de quatre box de consultation. Nous notons que l'ordonnancement dans la figure 4.8 est admissible car il vérifie l'équation 4.9. De plus, nous remarquons que lorsque les tâches de soins sont ordonnancées dans des périodes de créneaux successives, elles sont effectuées dans la même salle d'opération avec le même médecin.

La figure 4.13(a) est un exemple d'un graphe complet de cinq états générés suite à l'exécution de plusieurs itérations de l'algorithme 7, $ES=\{A, B, C, D, E\}$, dont chacun élément est décrit de la manière suivante :

- **l'état A**, l'affectation des tâches de soins aux différents membres du personnel soignant : cette fonction réalise la réaffectation de la tâche de soins du patient d'un personnel soignant à un autre personnel soignant. Par exemple, dans la figure 4.8, la troisième tâche de soins du patient 3 qui est assignée au médecin $m3$ peut être réassignée au médecin $m4$.
- **l'état B**, l'affectation des tâches de soins successives à différents membres du personnel soignant : cette fonction réalise la réaffectation des tâches de soins successives des patients à un autre membre du personnel soignant. Par exemple, dans la figure 4.8, les trois tâches de soins du patient 3 qui a déjà été assigné au médecin $m3$ peuvent être réassignées au médecin $m2$.
- **l'état C**, l'insertion d'une tâche de soins dans le planning du travail du personnel soignant : cette fonction de voisinage effectue le déplacement d'une tâche de soins vers une autre position dans le planning du personnel soignant. Par exemple, dans la figure 4.8, la première tâche de soins du patient 2 change de position, passant du créneau périodique [30-35] au créneau périodique [20-25]. Par conséquent, le créneau [30-35] du médecin $m2$ ainsi que le box 2 sont mis à jour (créneau [20-25]).
- **l'état D**, l'échange de deux tâches de soins entre différents membres du personnel soignant : cette fonction de voisinage effectue l'échange d'une tâche de soins d'un membre du personnel soignant à un autre. Par exemple, dans la figure 4.8, les deux premières tâches de soins du patient 1 seront assignées au membre du personnel soignant $m1$. Par conséquent, les deux premières tâches de soins du patient 4 seront attribuées au membre du personnel médical $m2$, les box changent en conséquence.
- **l'état E**, la permutation des tâches assignées au même membre du personnel soignant : cette fonction de voisinage effectue le changement de position d'une ou plusieurs tâches de soins dans le plan de travail du membre du personnel soignant. Par exemple, dans la figure 4.8, la dernière tâche de soins du patient 4 change de position, passant du créneau [90-95] au créneau [80-85] avec le même membre du personnel soignant $m4$.

4.5.2 Formulation des actions

L'objectif du modèle d'actions est d'ordonner les patients aux urgences, et donc la prise de décision qui consiste à sélectionner un ordonnancement représenté par un état du graphe. Une action est donc représentée par un arc qui relie deux noeuds. Un noeud est représenté par un état (fonction de voisinage). L'ensemble d'actions (EA) peut correspondre à un graphe complet dont les sommets sont adjacents deux à deux, c'est-à-dire que toute paire de sommets disjoints est reliée par un arc. Un exemple de graphe complet modélisant la relation entre les fonctions de voisinage (états) et les actions est présenté dans la figure 4.13(a). La table Q correspondant à cet exemple est présentée dans la figure 4.13(b). Les dimensions de la table Q se présentent sous la forme d'une matrice carrée de dimensions $(N * N)$, dans laquelle N est le nombre d'états.

$S_{i,j}^t$	Slot period	Slot period																		
		0-5	5-10	10-15	15-20	20-25	25-30	30-35	35-40	40-45	45-50	50-55	55-60	60-65	65-70	70-75	75-80	80-85	85-90	90-95
Patient																				
patient 1		1	1	0	0	0	0	0	0	0	1	1	0	0	0	0	0	0	0	0
patient 2		0	0	0	0	0	0	0	1	0	0	0	0	0	0	0	1	1	0	0
patient 3		0	0	0	0	0	0	0	0	0	0	0	1	1	1	0	0	0	0	0
patient 4		0	0	0	0	1	1	0	0	0	0	0	0	0	0	0	0	0	0	1

$M_{k,j}^t$	Slot period	Slot period																		
		0-5	5-10	10-15	15-20	20-25	25-30	30-35	35-40	40-45	45-50	50-55	55-60	60-65	65-70	70-75	75-80	80-85	85-90	90-95
Medical staff																				
m 1		0	0	0	0	1	1	0	0	0	1	1	0	0	0	0	0	0	0	0
m 2		1	1	0	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0
m 3		0	0	0	0	0	0	0	0	0	0	0	1	1	1	0	0	0	0	0
m 4		0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	1	0	0	1

L_l^t	Slot period	Slot period																		
		0-5	5-10	10-15	15-20	20-25	25-30	30-35	35-40	40-45	45-50	50-55	55-60	60-65	65-70	70-75	75-80	80-85	85-90	90-95
Operation room																				
room 1		1	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
room 2		0	0	0	0	0	0	1	0	0	0	0	0	0	0	1	1	0	0	0
room 3		0	0	0	0	1	1	0	0	0	0	0	1	1	1	0	0	0	0	0
room 4		0	0	0	0	0	0	0	0	0	1	1	0	0	0	0	0	0	0	1

FIGURE 4.8 – Exemple de solution d'ordonnancement pour quatre patients

4.5.3 Formulation de la récompense

La récompense (R) basée sur la valeur de fitness $reward(x)$ de la solution x et est évaluée sur la base de la fonction objective W (équation 4.8) du problème.

4.5.4 Formulation de la fonction de transition

Pour la probabilité de transition (T) d'un état s vers un nouvel état s' par une action a , nous utilisons la politique de contrôle définie par $\Pi(s,a)$. Cette dernière représente la probabilité d'effectuer l'action a dans l'état s . $\Pi(s,a)$ évolue en fonction de l'expérience que l'agent acquiert par des interactions avec l'environnement et avec d'autres agents. Le processus d'apprentissage s'exprime donc par la convergence vers la politique optimale Π^* .

4.5.5 Formulation du facteur d'actualisation

Le facteur d'actualisation γ montre l'importance de la récompense future par rapport à l'état actuel. Si γ est proche de 0, l'agent n'est intéressé que par la récompense actuelle et si γ est proche de 1, l'agent considère les récompenses futures aussi importantes que la récompense actuelle.

Nous utilisons par la suite l'algorithme Q-Learning qui est une technique d'apprentissage par renforcement adaptée au problème étudié car il ne nécessite aucun modèle initial de l'environnement (BUFFET 2003).

Algorithme 7 : Générer_solutions_voisines

```

1 Input
2  $SS$  : solution actuelle respectant le modèle de solution hypercube;
3  $N_{max}$  : nombre maximal de solutions de voisinage requises;
4  $NS = (MID, MIS, SDMS, SSMS)$ ;
5 Output
6  $SNS$  : ensemble de solutions de voisinage avec  $card(SNS) = N_{max}$ ;
7 begin
8  $N \leftarrow 0$ ;  $SNS \leftarrow \emptyset$ ;
10 while ( $N < N_{max}$ ) do
11    $mode = random(NS)$ ;
12   if  $mode = MID$  then
13      $SS_1 \leftarrow$  insertion multiple d'une tâche de soins  $(i, j)$  choisie aléatoirement dans  $SS$  d'un personnel soignant  $m$  à un
14     autre personnel soignant (cf. figure 4.9);
15     mettre à jour  $S_{i,j}^t, M_{k,j}^t, L_l^t$ ;
16     vérifier l'équation 4.9;
17   else if  $mode = MIS$  then
18      $SS_1 \leftarrow$  insertion multiple de la tâche de soins  $(i, j)$  choisie aléatoirement dans  $SS$  dans le planning du même
19     personnel médical  $m$  (cf. figure 4.10);
20     mettre à jour  $S_{i,j}^t, M_{k,j}^t, L_l^t$ ;
21     vérifier l'équation 4.9;
22   else if  $mode = SDMS$  then
23      $SS_1 \leftarrow$  déplacement d'une tâche de soins  $(i, j)$  choisie aléatoirement dans  $SS$  du personnel soignant avec une tâche
24     de soins  $(i, j)$  d'un autre personnel soignant (cf. figure 4.11);
25     mettre à jour  $S_{i,j}^t, M_{k,j}^t, L_l^t$ ;
26     vérifier l'équation 4.9;
27   else if  $mode = SSMS$  then
28      $SS_1 \leftarrow$  déplacement d'une tâche de soins  $(i, j)$  choisie aléatoirement dans  $SS$  du personnel soignant avec une autre
29     tâche de soins  $(i, j)$  du même personnel soignant (cf. figure 4.12);
30     mettre à jour  $S_{i,j}^t, M_{k,j}^t, L_l^t$ ;
31     vérifier l'équation 4.9;
32    $N \leftarrow N + 1$ 
33    $SNS \leftarrow SNS \cup \{SS_1\}$ 
34 return  $SNS$ ;
35 end

```




FIGURE 4.9 – Exemple d'insertion multiple dans différents corps médicaux (cf. algorithme 7)




FIGURE 4.10 – Exemple d’insertion multiple dans le même personnel soignant (cf. algorithme 7)




FIGURE 4.11 – Exemple de permutation entre différents personnels soignants (cf. algorithme 7)




FIGURE 4.12 – Exemple d’échange des tâches dans le planning d’un personnel soignant (cf. algorithme 7)

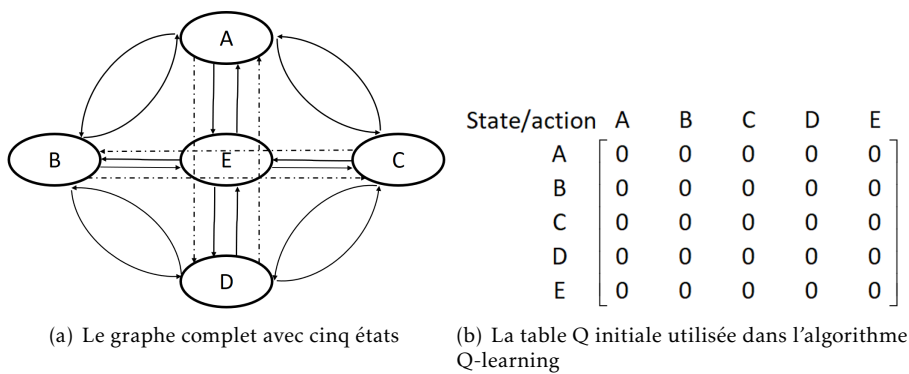


FIGURE 4.13 – Le graphe d’états complet et la table Q

4.5.6 L'algorithme Q-Learning en santé

L'algorithme Q-Learning est l'algorithme d'apprentissage par renforcement le plus connu et le plus utilisé en raison des preuves formelles de convergence et des applications existantes (VAN HASSELT, GUEZ et SILVER 2016). Notre objectif est de trouver une politique optimale pour le problème d'ordonnancement des patients aux urgences afin de minimiser leur temps d'attente global moyen. Cet algorithme nous permet de suivre une politique qui indique quelle action a à entreprendre à partir de l'état s du système. Cela fonctionne par l'apprentissage d'une fonction de valeur état-action, notée Q , qui définit le gain potentiel, c'est-à-dire la récompense à long terme apportée en effectuant une certaine action a dans un certain état s et en suivant une politique optimale π .

$$Q_{\pi}(s, a) = E_{\pi} \left\{ \sum_{i=0}^{\infty} \gamma^i r_{t+k+1} \mid s_t = s, a_t = a \right\} \quad (4.10)$$

Dans l'équation 4.10, E_{π} est la récompense attendue en suivant la politique π . Lorsque la valeur état-action est connue par l'agent, la politique optimale peut être construite en sélectionnant l'action ayant la valeur maximale pour chaque état, c'est-à-dire en sélectionnant l'action a qui maximise la valeur $Q(s, a)$ lorsque l'agent est dans l'état s . L'agent suit une politique quelconque afin de mettre à jour sa fonction de valeur. l'algorithme Q-Learning permet, pour tout processus de décision de Markov (MDP) fini, de trouver une politique d'actions optimale. L'objectif est, à chaque étape d'un épisode, de maximiser la valeur de la fonction $Q(s, a)$ définie comme : $Q'(s, a) = Q(s, a) + \alpha(r + \gamma \max_{a'}(s', a') - Q(s, a))$.

Le facteur d'apprentissage α représente le taux d'apprentissage et détermine dans quelle mesure la nouvelle fonction de valeur calculée Q surpasse l'ancienne. Si $\alpha = 0$ l'agent n'apprend rien, et si $\alpha = 1$ l'agent ne considère que la dernière information qu'il a apprise ($0 < \alpha < 1$). Le facteur d'actualisation γ détermine l'importance des récompenses futures. Un facteur de 0 rend l'agent myope en ne considérant que les récompenses actuelles alors qu'un facteur proche de 1 impliquerait plus de récompenses futures. Si le facteur d'actualisation est proche de 2 ou égal à 1, la valeur de Q peut diverger.

Comme le montre l'algorithme 8, la table-Q converge vers la fonction-Q optimale. En effet, l'algorithme planifiera la prochaine action pour le prochain état selon $Q(s, a)$ pendant les itérations et mettra à jour la nouvelle $Q(s', a')$. L'itération du Q-Learning maximisera la récompense et produira la politique optimale.

Les résultats de simulation des différents scénarios d'ordonnancement des tâches de soins à compétences multiples sont présentés dans le chapitre 5. Ces simulations ont pour objectif de montrer l'impact et l'intérêt de l'approche hybride auto-adaptative d'optimisation proposée dans le service des urgences.

L'une des principales causes de dégradation du critère temps d'attente global des patients optimisé auparavant (intra-urgences) est l'attente des lits d'aval disponibles. En effet, l'attente d'hospitalisation (ou "boarding") est le temps d'attente du patient entre la décision d'hospitalisation et l'admission effective dans un lit d'aval. Une des difficultés rencontrées pour qualifier le boarding est l'incapacité des systèmes d'informations hospitaliers (SIH) à le mesurer. Dans ce cadre, nous développons une approche conjointe qui permet l'ordonnancement et l'affectation des patients non programmés aux lits d'aval disponibles le plus rapidement possible. Cette approche est présentée dans la section suivante et elle permet le remplissage en temps réel d'un tableau de bord contenant à la fois des informations statiques et dynamiques.

Algorithme 8 : Agent auto-adaptatif : basé sur l'algorithme Q-Learning

```

1 Input
2  $x_0$  : solution courante;
3  $\alpha$  : le taux d'apprentissage;
4  $\gamma$  : le facteur d'actualisation;
5 Output
6  $x$  : learning solution;
7 begin
8 Use  $(Q(s, a), \forall s, a)$ 
9  $\forall a, (Q(S_{final}, a) \leftarrow 0)$ 
10  $x_{min} \leftarrow x_0; x \leftarrow x_0$ 
12 while (solution non améliorée) do                                ▶ Start Episode;
13     initialiser l'état  $s$ ;
14      $r = 0$ ;
17     while ( $s$  n'est pas la solution finale) do
18         if  $r > 0$  then
19              $s' \leftarrow \text{SelectAction}(s, True)$  (algorithm 9);
20             // une action  $a'$  de  $s$  en utilisant une politique spécifique de Q ( par exemple :  $\epsilon$ -greedy).
21         else
22              $s' \leftarrow \text{SelectAction}(s, False)$  (algorithm 9);
23             // pas d'amélioration : exploration d'autres solutions.
24          $x \leftarrow \text{bestNeighbour}(s', x)$ 
25         if  $x$  est meilleur que  $x_{min}$  then
26              $r \leftarrow ((x_{min}.\text{getwaitingTime}) - (x.\text{getwaitingTime}))$ ;
27              $x_{min} \leftarrow x$ ;
28          $Q(s', a') = Q(s, a) + \alpha(r + \gamma \max_{a'}(s' a') - Q(s, a))$ ;
29          $s \leftarrow s'$ ;
30          $a \leftarrow a'$ ;
31 return  $x$ ;
32 end

```

Algorithme 9 : SelectAction

```

1 Input
2  $e$  : état courant;
3  $b$  : paramètre boolean;
4 Output
5  $next\_e$  : état suivant;
6 Begin
7 if ( $b = true$ ) then
8      $next\_e \leftarrow \text{MaxAction}(e)$ ; //  $\epsilon$ -greedy exploitation
9 else
10     $next\_e \leftarrow \text{randomAction}(e)$ ; // exploration
11 return  $next\_e$ ;
12 end

```

4.6 Les problèmes de gestion des lits d'aval : une cause majeure de saturation

L'organisation de l'aval en général et la disponibilité des lits d'hospitalisation pour les patients non programmés en particulier sont associées directement aux situations de crise aux urgences. Dans le SUA de Lille, les patients qui ont besoin d'une hospitalisation attendent dans la zone E jusqu'à l'obtention d'un lit disponible dans le service d'aval adéquat. Actuellement, l'équipe de "bed manager" gère l'attribution des patients aux lits d'hospitalisation en utilisant la communication téléphonique. Cette procédure est considérée comme une activité chronophage car elle permet d'augmenter le temps d'attente des patients et ainsi de diminuer leur satisfaction. Le manque des lits et l'absence d'informations en temps réel sur la disponibilité de ces derniers provoquent un blocage des flux patients. La saturation d'un service d'aval a donc un impact direct et persistant sur la tension des urgences. Dans l'objectif de soulager l'intra-urgences et de faciliter l'admission des patients aux unités d'aval, il est primordial d'automatiser l'information sur l'état de disponibilité des lits d'aval. Une gestion efficace des lits nécessite à la fois une communication, une coopération et un partage opportun des informations et des ressources entre les différents services.

Dans ce qui suit, nous présentons une approche efficace pour contribuer à la bonne gestion des lits dans les structures d'aval. Cette approche est mise en place grâce à deux algorithmes. Le premier algorithme nommé CLS (cf. 4.6.1), permet de vérifier dans chaque service i la suffisance des ressources matérielles notamment en termes de nombre de lits. Le deuxième algorithme nommé AIDL (cf. 4.6.2), a pour objectif de fournir les informations sur la disponibilité des lits d'aval d'une manière automatique et en temps réel grâce à la technologie de Beacons. La gestion des lits d'aval ne se résume pas à la seule application de ces deux algorithmes, qui donnent en temps réel une visualisation des lits disponibles. La question de gestion des lits concerne aussi l'ensemble de l'institution et se décline d'une manière plus large à tous les niveaux de l'établissement. Par exemple, le SUA participe au "bed management" en indiquant la meilleure orientation souhaitée pour le patient, ainsi que les destinations éventuelles alternatives en adéquation avec une prise en charge correcte et sécurisée du patient.

4.6.1 Contrôle de nombre de lits nécessaires dans un service : Algorithme CLS

Dans l'objectif d'éviter les situations d'engorgement dans la zone E et par conséquent dans l'ensemble du SUA, un algorithme CLS basé sur un algorithme génétique (AG) est mis en place. Cet algorithme a pour but de vérifier dans chaque service i la suffisance des ressources matérielles notamment en termes de nombre des lits. Donc pour contrôler ce nombre dans chaque service et pour la réalisation de cette approche, nous nous référons à un modèle de file d'attente. Ce modèle est employé dans (GORUNESCU, McCLEAN et MILLARD 2002) et (BELCIUG et GORUNESCU 2015) pour optimiser l'utilisation des ressources hospitalières. Dans ce cadre, nous désignons les paramètres suivants :

- $\omega_{i,d}$: la durée moyenne de séjour du patient par service i par jour d ;
- σ_i : le flux d'arrivée moyen par service i ;
- θ_i : le nombre de lits en service i ;
- ε_d : le coût d'un lit vide par jour d ;

- τ : le coût de pénalité par patient réorienté.

Un modèle de file d'attente est généralement défini par deux types de paramètres : (1) les paramètres objectifs qui ne peuvent pas être modifiés par le professionnel de santé comme $\omega_{i,d}$ et σ_i néanmoins, ces paramètres peuvent changer dans certaines circonstances tels qu'une épidémiologie. (2) les paramètres subjectifs qui peuvent être modifiés par le professionnel de santé dans certaines circonstances comme θ_i et ε_d . Selon le modèle de file d'attente, il est possible de calculer la probabilité A_i (équation 4.11) que tous les lits soient occupés (i.e. la fraction des patients réorientés). Cette probabilité est basée sur la formule de perte d'Erlang connue également sous le nom formule d'Erlang B.

$$A_i = \frac{\frac{(\sigma_i \omega_{i,d})^{\theta_i}}{\theta_i!}}{\sum_{k=0}^{\theta_i} \frac{(\sigma_i \omega_{i,d})^k}{k!}} \quad (\text{Formule de perte d'Erlang}) \quad (4.11)$$

En se basant sur la probabilité A_i , la fonction fitness f_i est calculée comme suit :

$$f_i(\omega_{i,d}, \sigma_i, \theta_i, \varepsilon_d, \tau) = \tau \sigma_i A_i + \varepsilon_d \{\theta_i - \sigma_i \omega_{i,d} [1 - A_i]\} \quad (4.12)$$

Dans l'équation 4.12, nous considérons $\tau \sigma_i A_i$ est le coût des patients réorientés et $\varepsilon_d \{\theta_i - \sigma_i \omega_{i,d} [1 - A_i]\}$ le coût des lits non utilisés. Minimiser f_i signifie l'identification des valeurs optimales des paramètres $(\omega_{i,d}, \sigma_i, \theta_i, \varepsilon_d, \tau)$ afin d'estimer le nombre optimal de lits dans chaque service i . Dans notre cas, nous nous concentrons sur la recherche des valeurs optimales de θ_i tout en gardant un compromis entre $\omega_{i,d}$, σ_i , ε_d et τ .

Nous utilisons un AG avec un codage réel des chromosomes, pour estimer les valeurs optimales des paramètres, en particulier le nombre optimal de lits dans chaque service i . L'idée principale est d'appliquer les différentes étapes de l'AG, en choisissant un intervalle de recherche empirique pour chacun des paramètres ci-dessus. La performance de notre AG dépend de ses composants tels que la population initiale (chromosomes), le nombre de générations, la méthode de sélection (tournoi, roulette, un mélange des deux, etc.) et la probabilité des opérateurs de croisement et de mutation. Le pseudo-code de CLS basé sur l'AG est présenté dans l'algorithme 10.

Algorithme 10 : Pseudo-code de CLS

```

1 Input :  $\omega_{i,d}, \sigma_i, \theta_i, \varepsilon_d, \tau$ 
2 Output : la meilleure solution minimisant  $f_i$ 
3 Initialisation :
4 1. coder le chromosome sous forme d'un vecteur  $(\omega_{i,d}, \sigma_i, \theta_i, \varepsilon_d, \tau)$ ;
5 2. ensemble de chromosomes  $n$  de la population initiale dans lequel les paramètres sont choisis aléatoirement dans un intervalle empirique et pour chaque chromosome  $i$  calculer la fonction fitness  $f_i$ .
6 while (le critère d'arrêt n'est pas satisfait) do
7   Step 1 : utilisation de l'opérateur de sélection tournoi. Le chromosome ayant le meilleur score (équation 4.12) est sélectionné pour la reproduction (jusqu'à ce que la nouvelle population soit complète, un chromosome peut apparaître plusieurs fois dans cette population);
8   Step 2 : en utilisant la probabilité de croisement : une paire de chromosomes est sélectionnée aléatoirement, un des paramètres  $(\omega_{i,d}, \sigma_i, \theta_i, \varepsilon_d, \tau)$  de ces chromosomes est sélectionné au hasard et échangé avec cette paire de chromosomes. Les deux nouveaux descendants sont ajoutés à la population;
9   Step 3 : en utilisant la probabilité de mutation, l'un des paramètres du chromosome sélectionnés  $(\omega_{i,d}, \sigma_i, \theta_i, \varepsilon_d, \tau)$  est choisi au hasard pour changer de valeur. Si la fitness du mutant est meilleure que la fitness du chromosome d'origine, alors le mutant remplace l'original dans la population;
10  Step 4 : mettre à jour la population avec les  $n$  meilleurs individus sélectionnés.
11 end

```

4.6.2 Automatisation de l'information sur la disponibilité des lits : Algorithme AIDL

Comme il est mentionné auparavant, le SIH ne peut pas mesurer le temps de boarding des patients. Il faut en effet, que le système soit capable de noter un point-temps dès l'instant où le médecin urgentiste signale que le dossier du patient j est complètement terminé et donc prêt à quitter le SUA pour son lit d'hospitalisation (**premier point-temps** : PPT_j). D'autre part, il faut que le traçage informatique du patient soit réalisé dès son départ physique (**deuxième point-temps** : DPT_j). La soustraction entre ces deux points-temps permet de définir le temps de boarding. Or suite aux différentes visites et à nos discussions avec les urgentistes, nous découvrons que ce premier point-temps n'existe pas dans la plupart du SIH. Nous remarquons également qu'en période de tension, les équipes ont des difficultés à actualiser à temps le deuxième point-temps dans le SIH, rendant ainsi difficile le calcul correct du temps de boarding. Dans ce qui suit, nous proposons deux méthodes de calcul de PPT_j et DPT_j de chaque patient, ainsi nous pourrions calculer le temps d'attente moyen (TAB, cf. équation 4.13) des patients qui attendent dans la zone E pour l'obtention d'un lits d'aval.

$$TAB = Min \left(\frac{\sum_{j=1}^{JB} (\max(0, DPT_j - PPT_j))}{JB} \right) \quad (4.13)$$

avec, JB : le nombre total de patients dans la zone E en attente de Boarding

4.6.2.1 Méthode de calcul du premier point-temps

La détermination du premier point-temps est un défi majeur dans le SUA de Lille puisqu'il n'existe pas actuellement de moyen pour le calculer. Nous proposons dans cette section une méthode qui permet de déterminer d'une manière précise ce premier point-temps. Pour la réalisation de notre solution, nous aurons besoin de deux éléments : le dossier patient informatisé (DPI) et un QR-code. Pour chaque DPI, un QR-code est créé et accessible par le personnel soignant. Ce QR-code contient l'information sur l'heure et la date auxquelles le médecin a signalé que le patient doit être hospitalisé. En effet, grâce à un DPI-QR-code, le professionnel de santé peut visualiser l'heure de commencement exacte **de premier point-temps**. L'utilisation de ce genre de technologie dans les établissements de soins s'inscrit dans l'évolution de la médecine et de l'informatique médicale. En revanche, cette technologie exige une communication et une coopération entre les différents acteurs de santé puisque le développement, la mise en œuvre et la maintenance du DPI dans un environnement tel que les urgences sont des challenges à relever.

4.6.2.2 Méthode de calcul du deuxième point-temps

L'algorithme AIDL (algorithme 11) permet d'une part de calculer d'une manière automatique le deuxième point-temps, et d'autre part de réduire le temps de boarding en mettant à disposition des urgentistes l'information en temps réel sur la disponibilité de lits d'aval. Cette information est donnée grâce à l'utilisation de la technologie des Beacons. Cette dernière est un dispositif omniprésent qui permet non seulement de fournir des services de transfert de données, mais aussi de se positionner et de naviguer en intérieur (i.e. Indoor). Dans notre cas, les Beacons assurent la transmission d'informations de disponibilité des lits en temps réel grâce aux signaux

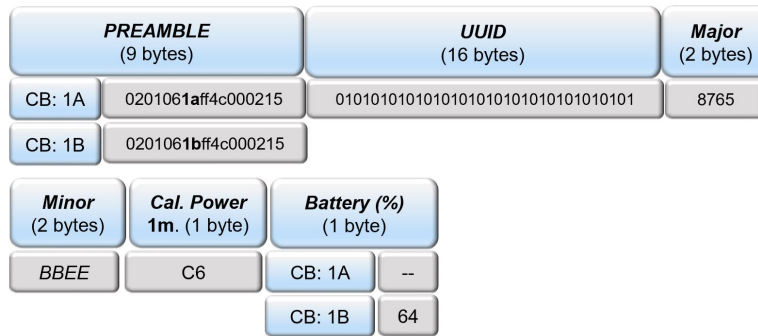


FIGURE 4.14 – Les formats de trames essentiels

émis constamment contenant un identifiant universel unique (UUID) (cf. figure 4.14). Pour recevoir ces informations, une application Android a été développée, doit être installée par la suite sur le smartphone du patient.

Grâce à la connexion créé entre Beacons-lit et patient-application Android, l'algorithme AIDL remplit en temps réel le tableau de bord qui pourrait être partagé entre les différents services du CHU de Lille. Deux types d'informations sont affichés dans ce tableau de bord : les informations statiques telles que le nom du service, le nombre de lits par service et les informations dynamiques telle que l'état des lits en question. Un lit peut avoir quatre états : libre (i.e. le lit est propre et prêt à recevoir un patient), occupé (i.e. un patient utilise le lit), réservé (i.e. un médecin a réservé un lit disponible pour pouvoir l'affecter à un de ses patients) ou en attente (i.e. le lit doit être nettoyé). La mise en place de ce tableau de bord dans le CHU de Lille permet aux professionnels de santé en général et aux professionnels des services des urgences en particulier d'orienter plus rapidement les patients vers les structures qui peuvent les accueillir et par conséquent, réduire la charge de travail de l'équipe de "bed manager".

Dans l'algorithme AIDL, les patients sont ordonnancés selon un ordre de priorité prédéfini en utilisant un algorithme de liste. L'originalité de cet algorithme est sa capacité à s'adapter à des situations hospitalières dynamiques (i.e. situation normale ou situation de crise). Lors d'une situation de crise, l'algorithme AIDL autorise l'affectation des patients à des services inadaptés pour la continuité de leurs soins et pour soulager la situation dans le SUA. Dans l'algorithme AIDL, chaque patient p a un score individuel S_p qui reflète son besoin d'être assigné. Le S_p est calculé à l'aide de l'équation 4.14 où CCMU, LOS et CEN représentent respectivement la classification clinique du patient, la durée de séjour et le nombre de cycles attendus. Ce score S_p est considéré comme une règle dynamique et à chaque étape de l'algorithme AIDL, le calcul de S_p peut donner un nouveau score pour chaque patient. Pour cette raison, une pondération donnée successivement à ces paramètres $\alpha = 0.4$, $\beta = 0.2$, $\mu = 0.4$, qui sont choisis par les médecins du SUA. Plus le score S_p est élevé, plus la priorité d'affectation du patient p est élevée.

$$S_p = \alpha \frac{CCMU_p}{AverageCCMU} + \beta \frac{LOS_p}{AverageLOS} + \mu \frac{CEN_p}{AverageCEN} \quad (4.14)$$

Algorithme 11 : Pseudo-code d'AIDL

```

1 Input
2 S_pat : l'ensemble des patients qui attendent un lit d'aval disponible dans la zone E;
3 Tab_A_Patient : un tableau contenant un nombre optimal de lits nécessaires pour l'activité de soins du service;
4 Tab_AV_b : une matrice  $(i, j)$ ,  $j = 1..x$ ,  $x$  est le nombre maximum de services dans l'hôpital et  $i = 1..y$ ,  $y$  est le nombre maximal
   de lits dans le service. Cette matrice considère que chaque lit a un identifiant unique de Beacons (UUID) et qu'il est mis à
   jour en temps réel dans notre tableau de bord.  $Tab\_AV\_b[i, j] = 1$  si, le lit  $i$  dans le service  $j$  est disponible sinon,
    $Tab\_AV\_b[i, j] = 0$ ;
5 Output  $S\_pat = \emptyset$  chaque patient de l'ensemble  $S\_pat$  obtient un lit d'hospitalisation disponible pour poursuivre ses soins;
6 Begin
7  $Ass\_pat\_wait = \emptyset$ ;
8 appeler l'algorithme CLS // le  $\theta_i$  optimal pour chaque service  $i$ ;
9 mettre ces informations dans  $Tab\_A\_Patient$  :  $Tab\_A\_Patient[i] = \theta$  ceci signifie que  $\theta$  lits sont nécessaires pour le service  $i$ ;
10 while  $(S\_pat \neq \emptyset)$  ou  $(S\_pat\_wait \neq \emptyset)$  do
11     1. calculer le score de priorité  $S_p$  équation 4.14 en utilisant les patients dans  $S\_pat$  et  $S\_pat\_wait$ ;
12     2. utiliser l'algorithme de liste pour ordonner les patients qui attendent dans la zone E (selon la règle dynamique  $S_p$ );
13     3. identifier le service  $j$  correspondant à l'affectation du patient  $p$  qui a le score  $S_p$  maximum;
14     4. mettre à jour ( $Tab\_AV\_b$ ) avec les informations reçues par les Beacons;
15      $Ass = false$ ;
16      $Ass\_wait = false$ ;
17      $i = 1$ ;
18     while  $(not\ Ass)$  and  $(not\ Ass\_wait)$  and  $(i \leq Tab\_A\_Patient[j])$  do
19         if  $(Tab\_AV\_b[i, j] == 1)$  then
20             affecter le patient  $p$  au lit  $i$  dans le service  $j$ ;
21             if  $(patient\ p \in S\_pat)$  then
22                  $Ass = true$ ;
23                  $S\_pat = S\_pat \setminus \{patient\ p\}$ ;
24             else if  $(patient\ p \in S\_pat\_wait)$  then
25                  $Ass\_wait = true$ ;
26                  $S\_pat\_wait = S\_pat\_wait \setminus \{patient\ p\}$ ;
27         else
28              $i = i + 1$ 
29     if  $(not\ Ass)$  then
30          $S\_pat = S\_pat \setminus \{patient\ p\}$ ;
31          $S\_pat\_wait = S\_pat\_wait \cup \{patient\ p\}$ ;
32     if  $(i > Tab\_A\_Patient[j])$  then
33         aucun lit disponible trouvé dans le service  $j$ , en situation de tension l'algorithme cherche à trouver un lit disponible
           dans un autre service  $k$ ;
34          $j = k$ ;
35 end

```

4.7 Architecture informatique du SAD proposé

Les approches décrites ci-dessus présentent les éléments de base de notre système d'aide à l'ordonnancement. Ce dernier permet la simulation du raisonnement médical en appliquant de nouvelles méthodes basées sur la technologie de l'IA. En effet, notre SAD est doté d'une architecture informatique à base d'agents permettant d'optimiser la prise en charge des patients. L'objectif de cette architecture est de garantir une optimisation collaborative qui génère des meilleures actions d'ordonnancement à adopter. Ces actions sont mises à jour par la coordination, la communication, la négociation et l'organisation entre les différents agents en inter et intra SUA. L'intégration de l'apprentissage par renforcement dans l'architecture proposée permet de rendre notre approche plus robuste face aux différentes instances du problème. Ainsi il permet la réalisation d'une optimisation collaborative efficace. La figure 4.15 illustre l'architecture auto-adaptative de notre SAD :

1. la première couche correspond aux modèles et formulations mathématiques (contraintes et critères) et algorithmiques (métaheuristiques et heuristiques).
2. la deuxième couche est la couche organisationnelle qui présente l'organisation, les rôles et les interactions entre les différents agents. Par exemple, les agents analysent la situation dans le SUA puis prennent la bonne décision en temps réel afin de proposer une solution d'ordonnancement optimale. Cela est effectué grâce à l'approche hybride auto-adaptative proposée (cf. section 4.4 et 4.5).
3. la troisième couche représente le terrain d'expérimentation SUA, dont le parcours patient est présenté par un workflow. Ce niveau est analysé par les agents du second niveau. L'objectif est d'orchestrer le parcours patient représenté par le workflow en cours d'exécution.

L'architecture proposée est une architecture évolutive puisqu'il est possible d'ajouter de nouveaux agents optimisateurs sans impacter les agents existants. Ces nouveaux agents peuvent être équipés d'autres algorithmes et heuristiques pour enrichir l'environnement et pour augmenter la diversité des solutions (EMP). Chaque agent a des actions qui définissent la vision globale qu'il a de l'environnement. Il ne dispose pas d'une connaissance complète de l'environnement. L'objectif est d'utiliser, en même temps, les forces et les avantages de chaque métaheuristique grâce au travail collaboratif des agents.

4.8 Conclusion

Dans ce chapitre, nous avons étudié les problèmes d'ordonnancement des patients aux urgences avec prise en compte des contraintes d'aval. Pour ce faire nous avons proposé premièrement une approche hybride auto-adaptative pour l'ordonnancement des patients en intra-urgences. Cette approche hybride auto-adaptative évolue grâce à deux protocoles d'interaction "amis" et "ennemis". Deuxièmement, nous avons proposé une approche conjointe d'ordonnement et d'affectation des lits d'hospitalisation aux patients non programmés. Cette approche a pour objectif d'assurer la continuité d'une prise en charge de qualité aux patients. Elle garantit également une meilleure continuité de soins, en continuant à minimiser le temps d'attente pour obtenir un lit d'hospitalisation dans les services d'aval. Des résultats de simulation utilisant une base de données réelles du SUA et prouvant l'intérêt des approches proposées seront présentés dans le chapitre suivant. Dans la dernière partie de ce chapitre, nous présentons un exemple d'implémentation du SAD global proposé.




FIGURE 4.15 – L'architecture informatique du SAD

Expérimentations et Résultats

5.1 Introduction

Dans ce chapitre, nous présentons les différents résultats d'expérimentations des approches proposées précédemment. Ces approches ont pour objectif de minimiser le temps d'attente global moyen des patients en utilisant une base de données réelle fourni par notre partenaire du CHU de Lille. Cette base de données porte sur quatre ans (juin 2016 - juin 2020) et a été extraite par le logiciel ResUrgences¹. Des courbes de résultats sont présentées pour prouver à la fois l'intérêt de l'approche d'optimisation collaborative pour l'ordonnancement des patients en intra-urgences et de l'approche d'automatisation de l'information sur la disponibilité des lits en aval des urgences.

5.2 Expérimentations et résultats de l'approche hybride auto-adaptative proposée

Dans cette section, nous décrivons les expérimentations ainsi que les résultats de notre approche d'optimisation hybride auto-adaptative. Dans ce contexte, une étude comparative est proposée pour évaluer l'indicateur de performance temps d'attente global moyen des patients dans le SUA. Cette étude compare l'approche hybride auto-adaptative proposée à celle du fonctionnement actuel aux urgences. Pour le développement, nous utilisons Mesa qui est un framework de modélisation à base d'agents sous licence Apache2 en Python². Mesa est lancé en 2013, est devenu un des outils de référence pour les chercheurs qui souhaitent construire des modèles basés sur des agents avec Python (MASAD et KAZIL 2015), (TASHAKOR et SUPPI 2019), (KAZIL, MASAD et CROOKS 2020).

Dans le but d'évaluer les approches proposées, nous l'avons appliqué pour résoudre un exemple de 10 patients (cf. tableau 5.1). Dans ce tableau, chaque tâche de soins nécessite une ou plusieurs compétences pour sa réalisation. Par exemple, le patient 1 nécessite deux fois la compétence

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

2. mesa.readthedocs.io/en/master/

Patients	Opération 1	Opération 2	Opération 3	Opération 4	Opération 5
1	C1*2	C1, C2	C1, C3	C1, C2*2	C4, C5*2, C6
2	C2, C3	C2, C3	C2	-	-
3	C3*2	C3	-	-	-
4	C4*3	C5, C6	C6*2	C4*2	C1, C2
5	C2*2	C5	C5, C6	C4, C5	C3
6	C1	C4	C6	-	-
7	C6*2	C1	C5, C6	C3	-
8	C3, C5	C2, C5	C3, C6	C6	-
9	C5	C4	C1	-	-
10	C4	C4, C5	C1, C2	C4	-

TABLEAU 5.1 – Exemple de 10 patients à ordonnancer




FIGURE 5.1 – Exemple de solution initiale d'ordonnancement

C1 pour réaliser sa première tâche de soins et nécessite en parallèle les compétences C1 et C2 pour l'exécution de sa deuxième tâche de soins, etc. La figure 5.1 montre le planning de chaque personnel soignant regroupé par compétence, c'est-à-dire les deux lignes 1 et 2 représentent la compétence C1 du personnel soignant 1, les deux lignes 3 et 4 représentent la compétence C2 du personnel soignant 2, les deux lignes 5 et 6 représentent la compétence C3 du personnel soignant 3, etc. Nous avons donc six personnels soignants de 1 à 6 qui sont représentés implicitement dans la figure 5.1. Chaque bloc représente une tâche qui est assignée à un personnel soignant, le numéro présenté dans ces blocs correspond au numéro de la tâche de soins.

Dans ce qui suit, nous menons un certain nombre d'expériences, avec un nombre variable de patients. Dans ces simulations, nous comparons les résultats donnés par chaque agent-métaheuristique individuellement à ceux obtenus avec le protocole de collaboration un-à-un et un-à-plusieurs (i.e. ART-AAG, ARS-AAG, ART-ARS, ART-ARS-AAG) dans les deux modes amis et ennemis. Le tableau 5.2 présente les résultats des expérimentations de cette comparaison. Concernant l'utilisation des agents-métaheuristiques, l'AAG surpasse à chaque fois l'ART et l'ARS, en réalisant de meilleures performances à chaque instance grâce au concept de paralléli-

Instance	patients	Nbr tâches	Sans collaboration			Collaboration Amis				Collaboration Ennemis			
			ARS	AAG	ART	ARS-AAG	ART-ARS	ART-AAG	ART-ARS-AAG	ARS-AAG	ART-ARS	ART-AAG	ART-ARS-AAG
1	15	45	16	14	16	14	16	14	14	14,65	16	14	14
2	15	49	23,65	22	23,65	22	23,65	22	22	22	23,65	22	22
3	20	65	46	41,5	46	41	46	41,25	41,5	41,75	46	41,25	42
4	20	62	46,75	41,5	46,75	46,75	46,75	37,75	41,5	46,75	46,75	41,5	41,5
5	25	70	30,6	29,8	30,6	30	29,6	28,6	28,6	28,8	30,6	28,6	30
6	25	63	29,6	28,8	29,6	28,8	29,6	28,8	28,8	28,8	29,6	28,8	28,8
7	30	94	76,65	73,15	76,65	72,3	76,65	73	71,3	73,5	76,65	73,15	72
8	30	76	41,8	40	41,8	39,8	41,8	39,8	36,3	40,65	41,8	39,8	41
9	40	109	54,37	52,88	54,25	51,5	54,37	52,75	48,75	51,88	54,37	52,63	50,37
10	50	170	128,1	127,7	128,3	125	127,1	125,5	124,8	126,3	126,8	125,9	125,7
11	60	184	127,5	127	127,6	125,3	126,2	125,2	125,3	125,3	126,4	125	125,2

TABLEAU 5.2 – Comparaison du temps d'attente moyen global (min) avec et sans le protocole de collaboration




FIGURE 5.2 – Comparaison des résultats du temps d'attente moyen global (min) dans les deux modes de collaboration

sation et aux opérateurs de croisement et de mutation contrôlés. La raison pour que l'ART et l'ARS trouvent des résultats moins bons que ceux de l'AAG est probablement due au fait qu'ils utilisent les mêmes structures de voisinage pour explorer d'une manière itérative l'espace des solutions.

Quant à l'utilisation de notre protocole de collaboration, les résultats montrent une amélioration de la performance du système d'ordonnancement ainsi qu'une diminution du temps d'attente moyen global, sauf lorsque le nombre de patients est moins important.

Nous remarquons également que les meilleures performances sont souvent atteintes avec une collaboration impliquant tous les agents, ce qui semble montrer que plus les agents travaillent ensemble, meilleures sont les solutions trouvées. Cependant, il arrive que certaines paires d'agents fassent mieux que les trois agents ensemble. Par exemple, dans l'instance 3, l'ARS-AAG trouve une solution meilleure que celle trouvée par l'ART-ARS-AAG (en mode amis). Ce phénomène peut s'expliquer par le caractère aléatoire qui entre en jeu dans le comportement des métaheuristiques. En outre, pour atteindre une meilleure qualité de solutions, il faut utiliser une collaboration maximale mais il n'est pas impossible qu'une moindre collaboration permette de trouver la meilleure solution. Dans le même tableau 5.2, nous pouvons noter que les résultats obtenus en utilisant le mode de collaboration amis sont, dans la majorité des cas, plus efficaces que ceux obtenus avec le mode de collaboration ennemis. Afin de mieux illustrer la différence en terme de performance entre les deux modes, nous traçons les résultats de l'instance 7 dans la figure 5.2. Cette dernière montre que le mode de collaboration amis permet de trouver plus rapidement les meilleures solutions. En effet, il est probablement plus facile pour la métaheuristique d'utiliser directement les solutions trouvées par les autres agents-métaheuristiques plutôt que d'avoir simplement accès à la valeur de la fonction objectif.

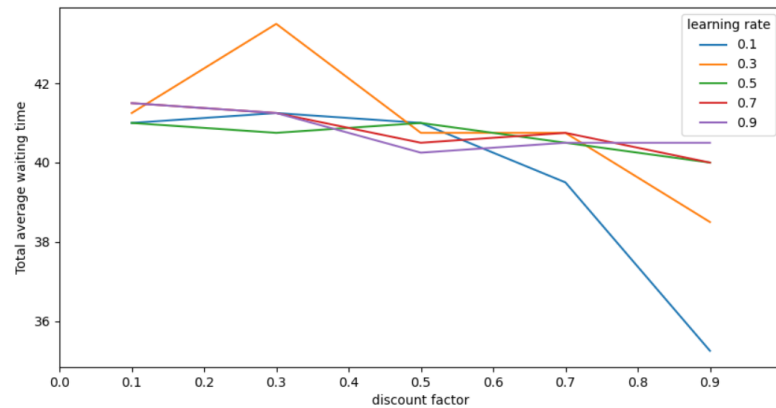


FIGURE 5.3 – Temps d'attente moyen global (min) de la meilleure solution trouvée avec l'apprentissage par renforcement en fonction du facteur d'actualisation et du taux d'apprentissage

Instance	Nombre de patients	Nombre de tâches	Sans apprentissage		Avec apprentissage		Pratique actuelle
			Amis	Ennemis	Amis	Ennemis	
			ART-ARS-AAG				
1	15	45	14	14	14	14	20,48
2	15	49	22	22	22	21	30,74
3	20	65	41,5	42	34,75	41,25	59,84
4	20	62	41,5	41,5	34	38,75	59,84
5	25	70	28,6	30	27,8	27,8	40,08
6	25	63	28,8	28,8	28,8	28,8	37,88
7	30	94	71,3	72	70,8	71	100,41
8	30	76	36,3	41	35	37,3	54,34
9	40	109	48,75	50,37	46,62	48,25	70,68
10	50	170	124,8	125,7	121,6	123,3	166,50
11	60	184	125,3	125,2	124,7	125	165,71

TABLEAU 5.3 – Comparaison du temps d'attente moyen global (min) en utilisant le protocole de collaboration avec et sans apprentissage par rapport au fonctionnement actuel

Sur la base de ces résultats, nous poursuivons nos expériences en comparant les performances de trois agents collaboratifs avec et sans technique d'apprentissage par renforcement (algorithme Q-Learning). Le tableau 5.3 présente les résultats obtenus en pratique (selon la base de données réelle du SUA) avec ceux générés par les 3 agents collaboratifs avec et sans apprentissage. L'écart entre les solutions montre que l'utilisation de l'apprentissage par renforcement aboutit à une amélioration du temps d'attente global moyen de 30,55% en mode amis et de 28,52% en mode ennemis par rapport au fonctionnement actuel dans le SUA. Les paramètres d'apprentissage sont fixés à l'aide des résultats empiriques, la figure 5.3 affiche le temps d'attente moyen global en fonction du facteur d'actualisation pour 20 patients (l'instance 3 du tableau 5.3). Cette figure montre que les meilleurs résultats sont obtenus avec un taux d'apprentissage $\alpha = 0,1$ et avec un facteur d'actualisation $\gamma = 0,9$. Un faible taux d'apprentissage peut être expliqué par le fait que le processus de décision de Markov est ici aléatoire, ainsi le processus d'apprentissage ne doit pas donner trop d'importance à la nouvelle information aléatoire par rapport à l'ensemble des connaissances déjà acquises.

La figure 5.4 montre le temps de calcul pour les deux modes de collaboration avec et sans apprentissage pour les différents nombres de patients. Nous pouvons remarquer que la collaboration en mode amis nécessite significativement plus de temps que la collaboration en

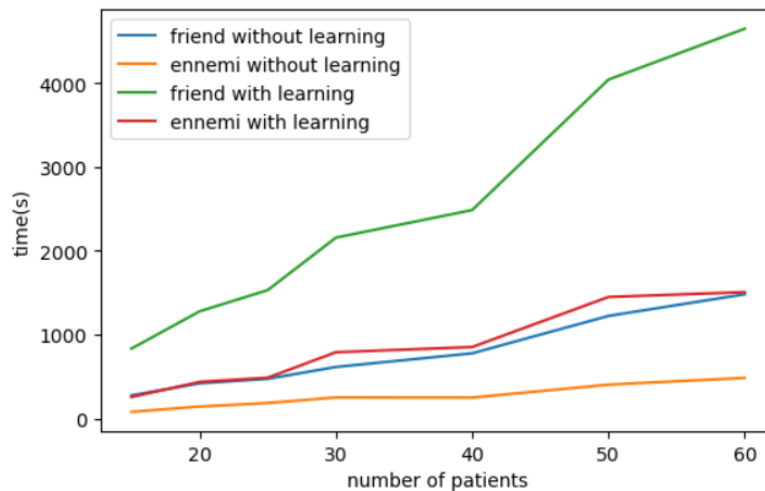


FIGURE 5.4 – Temps de calcul avec collaboration maximale (3 agents) pour les diverses instances

mode ennemis. Ceci est dû au fait que dans la collaboration ennemis, les agents ne fonctionnent que si un autre agent a trouvé une solution strictement meilleure que leurs meilleures solutions. Nous pouvons également noter que l'utilisation de l'apprentissage par renforcement augmente le temps de calcul. Cela peut s'expliquer par le fait que l'algorithme proposé pour générer une solution voisine en utilisant l'apprentissage par renforcement impose plus de calculs de solutions voisines.

Dans cette thèse, nous implémentons un système multi-agent collaboratif basé sur le déploiement des métaheuristiques utilisant l'apprentissage par renforcement pour résoudre un problème d'ordonnancement de tâches soins à compétences multiples. L'utilité de l'approche hybride auto-adaptative est démontrée puisque les résultats obtenus montrent que l'approche d'apprentissage collaborative conduit à de meilleurs résultats par rapport aux résultats où les agents travaillent individuellement ou sans apprentissage. La figure 5.5 montre un exemple d'ordonnancement de 20 patients avec notre approche hybride auto-adaptative et avec le mode de collaboration amis.

5.3 Expérimentations et résultats des algorithmes de gestion de lits d'aval

Afin de contribuer à la bonne gestion des lits dans les structures d'aval, nous présentons dans cette section les différentes expérimentations et résultats liés à l'approche proposée dans 4.6. Pour commencer, nous effectuons des tests pour évaluer la performance de l'algorithme CLS (algorithme 10), qui permet le contrôle du nombre de lits nécessaires dans un service i . Dans ce cadre, nous testons l'algorithme CLS avec trois types différents de sélection : sélection par tournoi, sélection à la roulette et sélection avec un mixte des deux. Les figures 5.6 et 5.7 présentent respectivement la valeur fitness et le temps d'exécution (en seconde) en fonction du nombre de générations. Sachant que le nombre de générations varie entre 10 et 300, le résultat montre que la sélection par tournoi est toujours meilleure tant pour la qualité des solutions que pour le temps d'exécution.




FIGURE 5.5 – Exemple d’ordonnement avec l’approche hybride auto-adaptative, mode amis




FIGURE 5.6 – Comparaison du temps d’exécution en utilisant différents types de sélection




FIGURE 5.7 – Comparaison de la qualité de solution en utilisant différents types de sélection




FIGURE 5.8 – Le nombre de transferts internes par an

Service	θ_i	σ_i	$\omega_{i,d}$ (jour)	ε_d (€)	τ (€)	Patient réorienté (%)
Traumatologie	60	10,68	25,11	30,97	1056,50	2
UHCD	20	15,03	30,03	21,13	1047,22	5
Rhumatologie Hosp complète	10	10,02	8,05	20,60	1054,50	5
Soins intensifs neuro-vasculaires	100	40,18	25,27	40,41	2001,15	1
Neurologie	80	30,03	13,04	66,33	2002,08	1,5

TABLEAU 5.4 – Valeurs optimales de l'algorithme CLS (10)

En moyenne le SUA de Lille oriente 86579,6 patients par an vers des services internes. La figure 5.8 montre le nombre de transferts internes effectués sur quatre ans (juin 2016 - juin 2020). Ce nombre augmente chaque année de manière continue (86500 en 2017, 86526 en 2018 et 86713 en 2019), il est considéré ainsi comme un élément clé qui met en évidence la problématique des lits d'aval. La même figure 5.8 peut donner l'impression que le nombre de transferts des patients est moins important en 2016 et en 2020 cependant, ce constat est tout à fait normal puisque la base de données ne contient que la moitié des données pour ces deux années³. Dans ce contexte, il est essentiel de contrôler le nombre de ressources par service afin de pouvoir vérifier leurs suffisances en termes de nombre de lits. Le tableau 5.4 présente un exemple de résultat de l'algorithme CLS. Ce tableau montre que le pourcentage du nombre de patients réorientés peut être contrôlé si nous surveillons le nombre de lits par service i . Par exemple, le pourcentage de 1% des patients réorientés peut être atteint avec 100 lits, un flux d'arrivée d'environ 40,18 patients par jour et une durée de séjour égale à 25 jours. Ensuite, il est important de noter que les expérimentations réalisées ont montré que notre approche est extrêmement flexible puisque le même pourcentage de patients réorientés de 5% peut être atteint avec 10 ou 20 lits, néanmoins ce pourcentage dépend fortement de flux d'arrivée et de durée de séjour (10,02/8,05 vs. 15,03/30,03).

Passons maintenant aux expérimentations et aux résultats du deuxième algorithme proposé. L'algorithme AIDL (11) a pour objectif de fluidifier le transfert de patients des urgences vers les services d'aval. Pour faciliter la communication entre les services d'aval et les urgences, nous utilisons la technologie des Beacons permettant ainsi de visualiser l'état des lits dans les services en temps réel. Afin de pouvoir acquérir les données, nous attribuons à chaque lit de test un Beacon (figure 5.9). Ce petit boîtier à pile a une autonomie longue qui utilise la norme Bluetooth, il émet en permanence un signal contenant son identifiant unique (UUID). Pour réceptionner le signal de cet appareil (Beacon), nous développons une application Android destinée à être

3. les données de l'année 2016 commencent en juin tandis que celles de l'année 2020 se terminent en juin.



FIGURE 5.9 – Beacon Bluetooth Low Energy

ID Patient	Service prévu	Service assigné	UUID-Lit	Chambre
02354	UHCD	UHCD	0x2A80	A001
02322	UHCD	UHCD	0x2A82	A002
03456	Réanimation	Réanimation	0xAA12	R005
03789	Réanimation	Réanimation	0xAA16	R004
06572	Gériatrique	Gériatrique	0xFFD1	E012
02894	Gériatrique	Gériatrique	0xFFD3	E014
07896	Chirurgie vasculaire	Chirurgie vasculaire	0x2A07	V034
04567	Chirurgie vasculaire	Chirurgie vasculaire	0xFFF8	V078

TABLEAU 5.5 – Exemple de résultats d'affectation des lits en situation normale

installée sur les smartphones des patients. Nous attribuons à chaque patient un identifiant unique. Une fois l'application ouverte (figure 5.10), elle scanne les appareils Beacons à proximité et détermine quel est le Beacon le plus proche (i.e. la distance est évaluée à partir de la puissance du signal reçu). Connaissant la correspondance Beacon-lit, l'application peut alors envoyer au serveur la position du patient via la connexion Internet du smartphone. Comme le montre la figure 5.11, grâce à l'algorithme AIDL (11) et à la technologie Beacons, le tableau de bord est rempli. Ce dernier permet de fournir aux urgentistes les informations nécessaires concernant l'état des lit d'aval. Un lit peut avoir quatre états : libre (i.e. le lit est propre et prêt à recevoir un patient), occupé (i.e. un patient utilise le lit), réservé (i.e. un médecin a réservé un lit disponible pour pouvoir l'affecter à un de ses patients) ou en attente (i.e. le lit doit être nettoyé avant d'être de nouveau disponible) (figure 5.12). La mise en place de ce tableau dans le SUA offre une vision complète de la disponibilité des lits dans chaque service d'aval. Il permet par conséquent l'affectation des patients aux services d'aval adéquats dans les délais les plus brefs, minimisant ainsi le temps d'attente des patients dans la zone E du SUA ce qui procure aussi un gain du temps aux personnels soignants (figure 5.13).

La particularité d'AIDL (algorithme 11) est sa capacité à prendre en compte les deux modes dans le SUA : situation normale et situation de tension. Afin de tester ces fonctionnalités, nous réalisons des scénarios de tests indiqués dans les tableaux 5.5 et 5.6. Ces tableaux présentent respectivement des échantillons des résultats d'affectation des patients dans les deux modes. Le tableau 5.6, montre qu'en mode tension l'algorithme AIDL ne respecte pas nécessairement l'affectation des patients dans les services d'aval prévu. Dans ce mode l'objectif principal est de gérer efficacement la situation de tension en diminuant le temps d'attente et ainsi soulager la situation dans le SUA sans mettre en danger la sécurité des patients.

Lits disponibles								
Nom du service	Lits installés	0	0	0 0	Libres	Occupés	Réservé	En attente
UHCD	12	2	2	2	6	4	0	2
Réanimation médicale	26	7	3	7	17	4	2	3
USC	16	6	6	4	16	0	0	0
Chirurgie Vasculaire	12	3	3	4	10	1	1	0
Neurologie	20	6	6	8	20	0	0	0
Médecine interne	38	12	12	13	37	0	1	0
MAG	12	2	2	8	12	0	0	0
UPUG	38	12	12	14	38	0	0	0
Néphrologie	14	4	4	6	14	0	0	0
Rhumatologie	37	11	8	13	32	3	2	0
Endocrinologie	0	0	0	0	0	0	0	0
Dermatologie	20	6	6	8	20	0	0	0
Chirurgie Orthopédique	38	12	12	14	38	0	0	0

FIGURE 5.12 – Le tableau de bord dynamique

1	Num dossier	Informations du	Patient	Anté	Exams	Orientation->destination	Orientation->famfert vers le service	Patient-nom de la ville	Orientation->Numero de lit
51	15907179	01/06/2016 00:36	77	oui		Admis(e) en NEUROLOGIE B 5 EST (3283/CAC)	NEUROLOGIE B 5 EST	LA BASSEE	9
20	15907316	01/06/2016 06:03	61	oui		Admis(e) en SOINS INTENSIFS NEUROVASCULAIRES (3303/CAC)	SOINS INTENSIFS NEUROVASCULAIRES	LILLE	10
21	15907317	01/06/2016 06:23	57	oui		Admis(e) en HOSPITALISATION COMPLETE (1831/CAC)	HOSPITALISATION COMPLETE	ANICHE	3
22	15907318	01/06/2016 06:28	44	oui		Admis(e) en MÉDECINE POLYVALENTE POST URGENCE (2250/CAC)	MÉDECINE POLYVALENTE POST URGENCE	LILLE	3
23	15907322	01/06/2016 07:09	76	oui		Admis(e) en HC CHR DIGEST RAZEMON (1401/CAC)	HC CHR DIGEST RAZEMON	LILLE	1
24	15907326	01/06/2016 07:16	56	Ostéop	oui	Admis(e) en HC NÉPHRO A ET IRA (5084/CAC)	HC NÉPHRO A ET IRA	LILLE	1
31	15907391	01/06/2016 08:57	34	insuffisar	oui	Admis(e) en RHUMATOLOGIE HOSP COMPLETE (3261/CAC)	RHUMATOLOGIE HOSP COMPLETE	HALLENNES LEZ HAUBOURD	4
52	15908658	01/06/2016 10:25	27	musovisc	oui	Admis(e) en NE PLUS UTILISER (2552/CAC)	NE PLUS UTILISER	RONCHIN	5
56	15908950	01/06/2016 10:46	63	Probabl	oui	Admis(e) en NEUROLOGIE A 4 NORD HC HPOD EXPLORATIONS EPILEPSIE	NEUROLOGIE A 4 NORD HC HPOD EXPLORATIONS EPILEPSIE	VILLENEUVE D ASCQ	9
58	15909056	01/06/2016 10:54	66	oui		Admis(e) en MÉDECINE POLYVALENTE POST URGENCE (2250/CAC)	MÉDECINE POLYVALENTE POST URGENCE	BAISEUX	2
61	15909183	01/06/2016 11:06	76	oui		Admis(e) en NEUROLOGIE B 5 EST (3283/CAC)	NEUROLOGIE B 5 EST	ARMENTIERES	1
63	15909338	01/06/2016 11:24	60	CHC sur chon		Admis(e) en HC EDIN A ET B (17043/CAC)	HC EDIN A ET B	LILLE	2
66	15928896	01/06/2016 11:45	84	ATCD	- non	Admis(e) en MÉDECINE GÉRIATRIQUE SUD (EX SALENGRO) (3711)/MÉDECINE GÉRIATRIQUE SUD (EX SALENGRO)	MÉDECINE GÉRIATRIQUE SUD (EX SALENGRO)	MARQUETTE LEZ LILLE	3
78	15909762	01/06/2016 12:24	31	sciatique	oui	Admis(e) en RHUMATOLOGIE HOSP COMPLETE (3261/CAC)	RHUMATOLOGIE HOSP COMPLETE	ROEUX	2
82	15909807	01/06/2016 12:38	64	oui		Admis(e) en HOSP COMPLETE (7082/CAC)	HOSP COMPLETE	HAUBOURDIN	4
88	15909887	01/06/2016 12:55	51	oui		Admis(e) en OPHTALMO HC GASS MACHEMER (1771/CAC) Requis: OPHTALMO HC GASS MACHEMER	OPHTALMO HC GASS MACHEMER	VILLENEUVE D ASCQ	5
91	15909898	01/06/2016 13:05	15	oui		Admis(e) en NEUROLOGIE A 4 NORD HC HPOD EXPLORATIONS EPILEPSIE	NEUROLOGIE A 4 NORD HC HPOD EXPLORATIONS EPILEPSIE	VILLENEUVE D ASCQ	10
92	15909925	01/06/2016 13:11	77	oui		Admis(e) en WÉMEAU (1355/CAC)	WÉMEAU	MASNIERES	1
95	15909970	01/06/2016 13:18	55	oui		Admis(e) en HOSPITALISATION COMPLETE (1831/CAC)	HOSPITALISATION COMPLETE	CARVIN	1
96	15880673	01/06/2016 13:22	76	- Diabète	oui	Admis(e) en MÉDECINE GÉRIATRIQUE OUEST (EX CARDIO) (3715/C)	MÉDECINE GÉRIATRIQUE OUEST (EX CARDIO)	WAMBRECHIES	5
98	15910045	01/06/2016 13:27	69	non		Admis(e) en SOINS INTENSIFS NEUROVASCULAIRES (3303/CAC)	SOINS INTENSIFS NEUROVASCULAIRES	LILLE	1
99	15910111	01/06/2016 13:32	77	oui		Admis(e) en RÉANIMATION (3820/CAC)	RÉANIMATION	COULOGNE	6
103	15910207	01/06/2016 13:42	72	oui		Admis(e) en TRAUMATOLOGIE (3966/CAC)	TRAUMATOLOGIE	LAMBERSART	2
112	15910726	01/06/2016 14:37	82	- Insuffis	oui	Admis(e) en NEUROLOGIE C 6 NORD HC (10291/CAC)	NEUROLOGIE C 6 NORD HC	LAMBERSART	8
115	15910848	01/06/2016 14:49	46	non		Admis(e) en SOINS INTENSIFS NEUROVASCULAIRES (3303/CAC)	SOINS INTENSIFS NEUROVASCULAIRES	VENDEVILLE	2
116	15910963	01/06/2016 15:00	92	Fibrillation	non	Admis(e) en MÉDECINE GÉRIATRIQUE OUEST (EX CARDIO) (3715/C)/MÉDECINE GÉRIATRIQUE OUEST (EX CARDIO)	MÉDECINE GÉRIATRIQUE OUEST (EX CARDIO)	J.A. MADRIEFINE	2

FIGURE 5.13 – Affectation des patients aux services d'aval

ID Patient	Service prévu	Service assigné	UID-Lit	Chambre
02355	Chirurgie vasculaire	UHCD	0x2A86	A008
02972	UHCD	UHCD	0x2A81	A002
03456	Chirurgie orthopédique	Réanimation	0xFFD2	R015
03989	Chirurgie orthopédique	Réanimation	0x2A83	R008
06572	Gériatrique	Chirurgie vasculaire	0x2A19	E202
02891	Neurologie	Gériatrique	0xFFE7	E017
03892	Neurologie	Chirurgie vasculaire	0xFFE8	V057
05567	Rhumatologie	Chirurgie vasculaire	0xFFF2	V079

TABLEAU 5.6 – Exemple de résultats d'affectation des lits en situation de tension

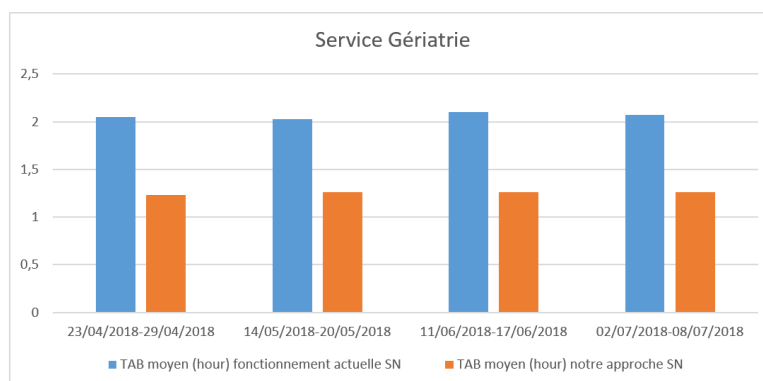


FIGURE 5.14 – Comparaison du TAB moyen avec et sans notre approche en situation normale (SN) Service Gériatrie

Dans l'objectif d'évaluer le niveau de performance de notre approche de gestion des lits d'aval nous choisissons de l'expérimenter dans deux services du CHU de Lille : le service gériatrie et le service pneumologie. Le choix de ce deux services est établi suite à une analyse de la base de données et aux différents discussions avec les urgentistes où nous concluons que le nombre de transferts vers ces services est récurrent. La détermination des périodes de situation normale ou situation de tension est déduite de la base de données réelles, selon des critères spécifiques tels que : l'afflux d'arrivée des patients par heure, le temps d'attente total moyen et la durée totale de séjour des patients aux urgences (cf. chapitre 3). Le tableau 5.7 compare les résultats trouvés par notre approche à ceux obtenus en pratique (fonctionnement actuel). Le même tableau montre que le temps d'attente moyen TAB (cf. équation 4.13) pour obtenir un lit d'aval trouvé par notre approche est plus court par rapport à la pratique réelle. Par exemple, les résultats des expérimentations montrent que l'application de notre approche a permis de diminuer le TAB d'environ 40% (figure 5.14) et 35% (figure 5.15) en situation normale et d'environ 30% (figure 5.16 et 5.17) en situation de tension respectivement pour le service gériatrie et celui de pneumologie. La différence de gain en pourcentage du temps d'attente entre les deux services dans les deux situations montre d'une part que notre approche s'adapte en fonction des services, et d'autre part l'importance d'appliquer un tel outil pour contribuer à la gestion automatique des lits d'aval. En effet, l'approche proposée a permis de diminuer le temps d'attente moyen TAB pour obtenir un lit d'hospitalisation. Pour conclure, la mise en place de notre approche nécessite d'une part, l'implémentation de la technologie Beacon dans tous les services en aval ce qui offre par conséquent un système d'information fiable en temps réel et d'autre part, une formation adéquate pour le gestionnaire des lits (bed manager).

5.4 Implémentation et simulation du SAD 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 (SAD) pour optimiser la chaîne logistique des urgences. Un SAD permet de réaliser la collecte et la transformation des données brutes issues de sources hétérogènes en vue de simplifier le processus de prise de décisions. L'idée de notre SAD est d'exploiter des données opérationnelles de la chaîne des urgences pour faciliter la prise de décision au profit d'un pilotage et d'une orchestration optimisés du parcours patients. Dans

Situation	Semaine	Service d'aval	Patients (Zone E)	TAB en pratique (hour)	TAB avec notre approche (hour)
Normale (SN)	23/04/2018-29/04/2018	Gériatrie	13	2,051	1,230
	14/05/2018-20/05/2018		20	2,029	1,257
	11/06/2018-17/06/2018		12	2,1	1,26
	02/07/2018-08/07/2018		25	2,07	1,26
	23/04/2018-29/04/2018	Pneumologie	20	2,52	1,63
	14/05/2018-20/05/2018		28	2,941	1,97
	11/06/2018-17/06/2018		25	2,1	1,36
	02/07/2018-08/07/2018		10	1,84	1,21
Tension (ST)	19/11/2018-25/11/2018	Gériatrie	26	2,58	1,806
	10/12/2018-16/12/2018		28	2,92	2,10
	07/01/2019-13/01/2019		30	2,62	1,83
	18/01/2019-24/01/2019		33	3,3	2,343
	19/11/2018-25/11/2018	Pneumologie	30	2,71	1,89
	10/12/2018-16/12/2018		35	3,8	2,736
	07/01/2019-13/01/2019		30	3,01	2,16
	18/01/2019-24/01/2019		31	2,84	2,016

TABLEAU 5.7 – Temps d'attente moyen pour l'obtention d'un lit d'aval avec et sans notre approche




FIGURE 5.15 – Comparaison du TAB moyen avec et sans notre approche en situation normale (SN) Service Pneumologie




FIGURE 5.16 – Comparaison du TAB moyen avec et sans notre approche en situation de tension (ST) Service Gériatrie




FIGURE 5.17 – Comparaison du TAB moyen avec et sans notre approche en situation de tension (ST) Service Pneumologie

cette partie d'expérimentation, nous déployons un outil informatique permettant de supporter un SAD de type Business Intelligence (BI).

Dans ce cadre, il est donc nécessaire d'afficher les données et les indicateurs retenus lors de nos réunions avec le personnel hospitalier au sein du SAD. Afin que ces informations soient compréhensibles rapidement et visuellement attractives pour éviter toute perte de temps inutile pour les soignants, nous avons choisi d'utiliser l'outil Power BI Desktop. Ce dernier est un outil décisionnel d'exploration et de visualisation interactive des données. Il permet aux personnels soignants de rassembler et d'interpréter des données afin de pouvoir prendre la meilleure décision. Cet outil est proposé par Microsoft⁴ présenté sous la forme d'un interface suffisamment simple permettant ainsi une prise en main facile aux utilisateurs (FERRARI et RUSSO 2016). En effet, les visuels attractifs sont affichés sous forme d'un tableau de bord contenant des informations statiques et dynamiques pertinentes issues successivement de la base de données et des approches développées dans le chapitre 4. Afin de tester la performance de cet outil nous réalisons des simulations sur trois mois de la base de données réelle. Dans notre cas, le Power BI Desktop permet d'afficher :

- l'étude statistique et l'étude prédictive réalisées dans le chapitre 3 : Principalement destinée aux personnels souhaitant connaître les statistiques en termes de charge de patients sur différentes périodes (mois, jour, heure) (cf. figure 5.18), de proportion de patients par pathologie (cf. figure 5.19), de durée d'attente (cf. figure 5.20) ou des examens complémentaires sur un intervalle de temps qu'ils définissent eux même à des fins d'analyse (cf. figure 5.21). Celles-ci pourraient permettre aux personnels soignants d'optimiser la répartition de ressources humaines et matérielles grâce à des statistiques fiables. Par exemple, dans la figure 5.19, grâce à un simple appui sur la troisième barre du histogramme, l'ensemble des barres restantes sont mises en surbrillance. Ce qui permet de mettre en évidence l'information sélectionnée (dans ce cas, il s'agit du nombre des patients avec la pathologie cardiologie).
- la figure 5.22 montre un exemple de planning des opérations de soins. Ces plannings sont destinés à l'ensemble du personnel soignant puisque les visuels présentent à la fois le planning par zone (i.e. zone A, B, C et D, circuit court (CC)) mais aussi leur taux de saturation. Nous pouvons également accéder au planning de chaque patient avec son temps d'attente primaire et secondaire (figure 5.23) grâce à notre approche hybride auto-adaptative (cf. chapitre 4). En effet, bien que nos approches ont pour but de minimiser ces données, il faut néanmoins pouvoir y avoir accès afin de pouvoir répondre à une saturation trop importante d'un service ou un temps d'attente trop long pouvant tous les deux conduire à une dégradation de l'état des patients. Nous choisissons de faire apparaître en vert, jaune ou rouge les cases correspondant aux temps d'attente et taux de saturation afin de signaler rapidement au personnel soignant la présence d'une zone de congestion ou d'une attente trop longue pouvant mener à la dégradation de l'état de santé des patients.
- la figure 5.24 affiche le nombre de lits disponibles pour chaque service d'aval. Ces informations sont destinées à l'ensemble du personnel soignant et en particulier aux bed manager. Les informations affichées dans la figure 5.24 sont visualisées grâce à l'algorithme d'automatisation de l'information sur la disponibilité des lits (cf. algorithme 11).

L'une des attentes de ces travaux de thèse, est bien évidemment d'avoir un SAD réunissant les informations recueillies par chacun de nos algorithmes (i.e. inter et intra urgences). Avant une possible intégration dans le logiciel ResUrgences, nous avons donc conçu notre solution

4. docs.microsoft.com/en-us/power-bi




FIGURE 5.18 – Tableau de Bord sur le nombre des patients en heure, jour et mois




FIGURE 5.19 – Tableau de Bord sur la proportion de patients par pathologie

avec une architecture relativement simple (figure 5.25). La base de données que nous avons utilisée 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 le temps d'attente primaire, il est possible d'avoir une vision globale sur la situation du SUA dans le futur. En appliquant par exemple une étude de prédiction des examens complémentaires, nous pouvons ajouter dans la base de données la probabilité que le patient réalise un examen complémentaire ou non. Cette base est ensuite utilisée par l'algorithme d'attribution des opérations qui ressort un nouveau fichier utilisé par le système multi-agent. Après l'ordonnancement des patients, il est possible d'affecter les lits aux différents patients. L'algorithme d'attribution des lits est alimenté par un fichier donnant en temps réel l'état de disponibilité des lits dans les services d'aval. Le Power BI utilise les informations contenues dans les différents fichiers Excel pour afficher en temps réel les informations sur l'évolution de l'état dans le SUA.

5.5 Conclusion

Dans ce chapitre, nous avons présenté les expérimentations et les résultats montrant l'intérêt de nos approches en utilisant une base de données réelles. D'abord, nous avons simulé notre approche hybride auto-adaptative qui est basée sur un algorithme Q-Learning. Les résultats des expérimentations montrent que notre approche a amélioré les performances du SUA de Lille en réduisant le temps d'attente global moyen. Ensuite, nous avons simulé notre approche



FIGURE 5.23 – Tableau de Bord : temps d’attente des patients




FIGURE 5.24 – Vue en temps réel sur le nombre des lits disponibles

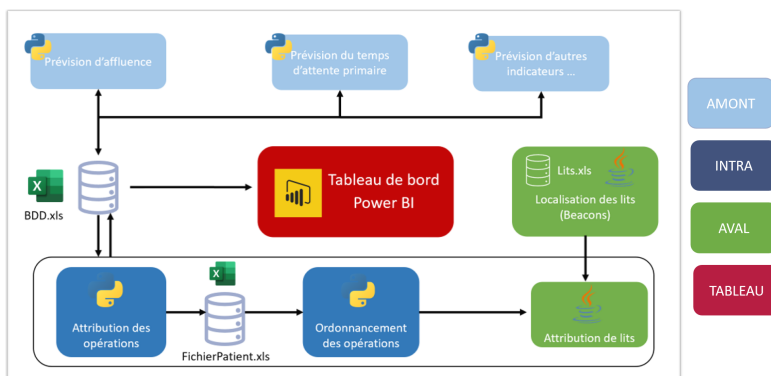


FIGURE 5.25 – Architecture d’exploitation du SAD

d'automatisation des lits d'aval en combinant une métaheuristique (AG) et la technologie des Beacons. Les résultats des expérimentations nous ont permis de conclure que la mise en place d'une approche d'automatisation permet à la fois de réduire le temps de boarding pour les patients dans la zone E et d'améliorer le quotidien du personnel soignant. Pour conclure, nous avons présenté notre SAD sous la forme d'un tableau de bord permettant l'affichage des différents données et indicateurs grâce au logiciel Power BI Desktop.

Conclusion générale

L'amélioration de l'efficacité du parcours patient nécessite l'optimisation de la logistique intra-service (urgences) et inter-services qu'ils soient ou non au sein de la même structure. Le patient qui arrive aux urgences est priorisé en fonction de son niveau de gravité, ce qui détermine son temps d'attente prévisionnel. Une fois le patient pris en charge, son parcours peut requérir un plateau technique ou des avis spécialisés dont le service dispose ou non. Le patient doit donc être géré en interne ou en interaction avec d'autres services le plus efficacement possible. À la fin de la prise en charge, le patient est orienté le plus rapidement possible vers son domicile ou vers une autre structure de soins. Par conséquent, un service d'urgences adultes (SUA) peut être vu dans une première approche comme **un système en interaction avec d'autres systèmes**, avec des flux entrants et des flux sortants. Le but de cette thèse est donc d'étudier et de développer une architecture informatique de supervision centrée sur le patient optimisant son parcours dans la chaîne des urgences (*amont, intra et aval*) notamment en mode tension. La gestion optimale de tension aux urgences hospitalières est nécessaire mais pas suffisante depuis que nous savons que l'une des principales causes de situation de tension est la mauvaise organisation de l'aval des urgences, notamment pour l'affectation des lits d'hospitalisation aux patients des SU, ce qui entraîne une prolongation de séjour de patients en attente d'hospitalisation. Cette longue attente peut causer ainsi une augmentation de la mortalité, une diminution de la qualité des soins et un séjour hospitalier prolongé dans toute la chaîne hospitalière vis-à-vis des patients mais aussi provoquer une détérioration de la qualité de travail du personnel soignant. Dans ce contexte, les travaux de cette thèse visent à réduire la situation de tensions dans les SU en étudiant toutes les étapes du parcours patient : de l'amont à l'aval. Chaque étape de cette chaîne participe à des degrés divers à la situation de tension dans le SU. De même, la gestion de l'amont à l'aval doit tenir compte de tous les aspects d'une interférence permanente entre les trois types de patients : les patients programmés, les patients non programmés et les patients non programmés urgents. Cette interférence est la cause principale qui qualifie la gestion des SU comme complexe puisqu'elle empêche toute planification préalable. Dans ce cadre, nous avons proposé une approche relativement nouvelle alliant les métaheuristiques, le système multi-agent et l'apprentissage comme approche appropriée pour assurer l'optimisation collaborative qui génère de bonnes actions à adopter. Ces actions sont utiles pour ordonnancer les tâches de soins à compétences multiples avec la prise en compte des contraintes de l'aval. Le critère d'optimisation choisi dans le cadre de cette étude, est le temps d'attente global moyen qui représente un critère crucial pour améliorer la qualité de prise en charge des patients en intra-urgences et dans les services d'aval.

En intra-urgences, nous proposons une architecture à base d'agents communicants dont le comportement de chaque agent est décrit à l'aide d'une métaheuristique. Nous choisissons d'expérimenter trois agents-métaheuristiques : agent algorithme génétique, agent recuit simulé

et agent recherche tabou. La conséquence des interactions entre ces agents est l'émergence d'un modèle comportemental global, complexe et non programmé explicitement. Les systèmes à base d'agents fournissent une théorie solide et un ensemble de modèles cohérents qui permettent de caractériser les modèles de comportement global produits par l'interaction collective pour guider la recherche des solutions optimales vers des zones plus prometteuses. Dans cette perspective, nous avons conçu plusieurs concepts et modèles basés sur les agents qui génèrent des comportements de recherche globale d'ordonnement des patients très efficaces. En effet, un nouveau protocole de collaboration générique (PCG) entre les agents est développé pour faire collaborer plusieurs métaheuristiques. Deux instances "amis" et "ennemis" de ce protocole impliquant un petit ensemble de règles pour produire deux modèles globaux émergents peuvent être considérées comme des étapes d'exploration et d'exploitation. Nous développons et testons également le modèle d'auto-adaptation des agents par apprentissage. Un type de méthode d'apprentissage par renforcement est développé pour traiter le problème d'optimisation de l'ordonnement des patients. Les principes de l'algorithme proposé, y compris l'agent d'apprentissage et ses actions, l'environnement et ses états, et les fonctions de récompense, sont présentés en détail. Les réglages des paramètres de l'algorithme proposé sont également discutés dans la section expérimentale. En outre, la qualité de la solution de l'algorithme Q-Learning proposé est prouvée en la comparant sur plusieurs instances à celle de la méthode utilisant des agents-métaheuristiques sans apprentissage. Les résultats expérimentaux montrent que l'efficacité de l'auto-adaptation des agents par apprentissage est meilleure que celle de la méthode sans apprentissage et que la précision de l'algorithme Q-Learning est supérieure à celle des algorithmes métaheuristiques seuls. De plus, l'algorithme Q-Learning fournit des solutions améliorées au problème conjoint d'ordonnement et d'allocation des ressources en ajustant la valeur de l'épisode de formation k dans des applications pratiques telles que le problème étudié. Pour évaluer ses performances, l'approche proposée a été testée dans les urgences du CHU de Lille en utilisant des données réelles concernant l'ordonnement des tâches de soins à compétences multiples. Les résultats de simulation démontrent l'association prometteuse entre les trois paradigmes "optimisation-agents-apprentissage".

Nous proposons également dans cette thèse, des algorithmes qui opèrent dans un autre schéma d'optimisation différent du précédent (i.e. intra-urgences) pour continuer à optimiser le temps d'attente global moyen des patients qui attendent des lits d'hospitalisation dans les services d'aval. Pour vérifier la suffisance du nombre des lits dans chaque service nous avons présenté un modèle de file d'attente qui façonne le flux des patients à travers le SUA, puis nous avons développé un algorithme génétique pour éviter les situations d'insuffisance et d'excès. L'objectif principal de cet algorithme est de contrôler le nombre de lits nécessaires dans chaque service en aval. Comme mentionné auparavant, le taux d'occupation des services en aval et la disponibilité de leurs lits pour les patients non programmés ont un impact important sur la situation de tension des urgences. Pour y faire face, une approche d'automatisation des informations sur la disponibilité des lits est nécessaire. Dans ce cadre, nous avons mis en place un algorithme qui permet de réduire le temps de boarding en mettant à disposition des urgentistes l'information en temps réel sur la disponibilité de lits d'aval grâce à la technologie Beacons. Ainsi, cette approche d'automatisation améliore et facilite l'échange d'informations sur la disponibilité des lits en aval au sein du CHU de Lille. En effet, nous utilisons le logiciel Power BI Desktop comme un tableau de bord pour afficher les données et les indicateurs retenus de notre SAD.

Cette thèse présente de nombreuses perspectives scientifiques et techniques :

- Intégrer et explorer les avantages de l'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 automatiser le processus de paramétrage des métaheuristiques.
- Prédire la durée de séjour des patients hospitalisés pour chaque unité de soins en utilisant un algorithme d'apprentissage tel que l'algorithme Q-Learning.
- Inclure un système multi-agent pour assurer une collaboration efficace entre un groupement hospitalier de territoire (GHT).
- Analyser et établir les procédures d'évitement des tensions dans le contexte des urgences adultes en mettant en place :
 - des procédures de veille et d'analyse en temps réel des principales informations ;
 - des procédures d'affichage ergonomique des indicateurs de tension ;
 - des procédures de cheminement claires et formalisées du signalement et de l'alerte en cas de tension ressentie.

Bibliographie

- AARTS, Emile, Emile HL AARTS et Jan Karel LENSTRA (2003). *Local search in combinatorial optimization*. Princeton University Press.
- ABRI, Méhadji, Noureddine BOUKLI-HACENE et Fethi Tarik BENDIMERAD (2005). "Application du recuit simulé à la synthèse d'antennes en réseau constituées d'éléments annulaires imprimés". In : *Annales des télécommunications*. T. 60. 11. Springer, p. 1422-1438.
- AERTS, Jeroen CJH et al. (2018). "Integrating human behaviour dynamics into flood disaster risk assessment". In : *Nature Climate Change* 8.3, p. 193-199.
- AFILAL, Mohamed et al. (2016). "Emergency department flow : A new practical patients classification and forecasting daily attendance". In : *IFAC-PapersOnLine* 49.12, p. 721-726.
- AGERBECK, Christian et Mikael O HANSEN (2008). "A multi-agent approach to solving NP-complete problems". Mém. de mast. Technical University of Denmark, DTU, DK-2800 Kgs. Lyngby, Denmark.
- AJMI, Faiza et al. (2020). "Generic agent-based optimization framework to solve combinatorial problems". In : *2020 IEEE International Conference on Systems, Man, and Cybernetics (SMC)*. IEEE, p. 950-956.
- AJMI, Faten (2019). "Méthodes d'ordonnancement et d'orchestration dynamique des tâches de soins pour optimiser la prise en charge des patients dans les urgences hospitalières". Thèse de doct. Ecole centrale de Lille.
- AJMI, Faten et al. (2018). "Patient Pathway Workflow Model Identifying Overcrowding Indicators in Emergency Department". In :
- AKACHI, Yoko et Margaret E KRUK (2017). "Quality of care : measuring a neglected driver of improved health". In : *Bulletin of the World Health Organization* 95.6, p. 465.
- ALELAIWI, Abdulhameed (2020). "Resource Allocation Management in Patient-to-Physician Communications Based on Deep Reinforcement Learning in Smart Healthcare Services". In : *2020 IEEE International Conference on Multimedia & Expo Workshops (ICMEW)*. IEEE, p. 1-5.
- ALPAYDIN, Ethem (2020). *Introduction to machine learning*. MIT press.
- APOLINARSKA, Aleksandra Anna et al. (2021). "Robotic assembly of timber joints using reinforcement learning". In : *Automation in Construction* 125, p. 103569.
- APTEL, O (2000). "le rôle de la logistique dans la connaissance des niveaux des stocks : le cas du secteur hospitalier". In : *Les troisièmes rencontres Internationales de la recherche en logistique. Trois rivières, 9, 10, 11 mai 2000. pn 12*.
- AUCHINCLOSS, Amy H et Ana V DIEZ ROUX (2008). "A new tool for epidemiology : the usefulness of dynamic-agent models in understanding place effects on health". In : *American journal of epidemiology* 168.1, p. 1-8.
- AYDIN, Mehmet Emin (2013). "Agentification of individuals : A multi-agent approach to metaheuristics". In : *J Comput Sci Syst Biol* 6, e105.

- BACK, Thomas (1996). *Evolutionary algorithms in theory and practice : evolution strategies, evolutionary programming, genetic algorithms*. Oxford university press.
- BACON, Pierre-Luc, Jean HARB et Doina PRECUP (2017). "The option-critic architecture". In : *Proceedings of the AAAI Conference on Artificial Intelligence*. T. 31. 1.
- BADEIG, Fabien et Flavien BALBO (2012). "Définition d'un cadre de conception et d'exécution pour la simulation multi-agent." In : *Revue d'intelligence artificielle* 26.3, p. 255-280.
- BAI, Aijun et Stuart RUSSELL (2017). "Efficient reinforcement learning with hierarchies of machines by leveraging internal transitions". In : *Twenty-Sixth International Joint Conference on Artificial Intelligence*.
- BALLARD, Madeleine et Ryan SCHWARZ (2019). "Employing practitioner expertise in optimizing community healthcare systems". In : *Healthcare*. T. 7. 3. Elsevier, p. 100334.
- BARNHART, Cynthia, Christopher A HANE et Pamela H VANCE (2000). "Using branch-and-price-and-cut to solve origin-destination integer multicommodity flow problems". In : *Operations Research* 48.2, p. 318-326.
- BARNHART, Cynthia et al. (1998). "Branch-and-price : Column generation for solving huge integer programs". In : *Operations research* 46.3, p. 316-329.
- BARNIER, Nicolas et Pascal BRISSET (1999). "Optimisation par algorithme génétique sous contraintes". In : *Technique et science informatiques* 18.1, pp-1.
- 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.
- BEAUDRY, Alexandre et al. (2010). "Dynamic transportation of patients in hospitals". In : *OR spectrum* 32.1, p. 77-107.
- BEĆIRSPAHIĆ, Lejla, Adisa ĐULOVIĆ et Novica NOSOVIĆ (2013). "Parallelization and performance analysis of the Simulated Annealing algorithm for graph coloring problem". In : *2013 36th International Convention on Information and Communication Technology, Electronics and Microelectronics (MIPRO)*. IEEE, p. 1306-1309.
- BELCIUG, Smaranda et Florin GORUNESCU (2015). "Improving hospital bed occupancy and resource utilization through queuing modeling and evolutionary computation". In : *Journal of biomedical informatics* 53, p. 261-269.
- BELIËN, Jeroen et Erik DEMEULEMEESTER (2007). "Building cyclic master surgery schedules with leveled resulting bed occupancy". In : *European journal of operational research* 176.2, p. 1185-1204.
- BELLMAN, Richard (1957). "A Markovian decision process". In : *Journal of mathematics and mechanics* 6.5, p. 679-684.
- BELLOIR, Nicolas, Jean-Michel BRUEL et Raphaël FAUDOU (2014). "Modélisation des exigences en UML/SysML". In : *Revue Génie Logiciel* 111, p. 6-12.
- BENHAJJI, Noura, Daniel ROY et Didier ANCIAUX (2015). "Patient-centered multi agent system for health care". In : *IFAC-PapersOnLine* 48.3, p. 710-714.
- BERGONZONI, Alice et al. (2020). "Les établissements de santé : édition 2020". In :
- BERNSTEIN, Steven L et al. (2003). "Development and validation of a new index to measure emergency department crowding". In : *Academic Emergency Medicine* 10.9, p. 938-942.
- 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.
- BERTUCCI, François et al. (2020). "Santé numérique et «cancer hors les murs», Big Data et intelligence artificielle". In : *Bulletin du Cancer* 107.1, p. 102-112.
- BLAKE, John T et Michael W CARTER (2002). "A goal programming approach to strategic resource allocation in acute care hospitals". In : *European Journal of Operational Research* 140.3, p. 541-561.

- BLUM, Christian et al. (2011). "Hybrid metaheuristics in combinatorial optimization : A survey". In : *Applied soft computing* 11.6, p. 4135-4151.
- BOGERT, Kenneth et al. (2016). "Expectation-maximization for inverse reinforcement learning with hidden data". In : *Proceedings of the 2016 International Conference on Autonomous Agents & Multiagent Systems*, p. 1034-1042.
- BOK, Michiel de, Lóránt TAVASSZY et Sebastiaan THOEN (2020). "Application of an empirical multi-agent model for urban goods transport to analyze impacts of zero emission zones in The Netherlands". In : *Transport Policy*.
- BONED, Olivier, Romain GUERRY et Luc PIERRON (2018). "Les mutuelles de santé face à la réglementation européenne : une banalisation de l'identité mutualiste?" In : *RECMA* 3, p. 42-55.
- BOOCH, Grady (1996). *Best of booch : Designing strategies for object technology*. T. 7. Cambridge University Press.
- BOUAÏTI, E et al. (2016). "Facteurs déterminants de la satisfaction des patients consultant aux urgences de l'hôpital militaire d'instruction Mohamed V de Rabat, Maroc". In : *Revue d'Épidémiologie et de Santé Publique* 64, S140-S141.
- BOURRET, Christian (2016). "Relever le défi des Inégalités Sociales et Territoriales en Santé (ISTS) par la rencontre des organisations d'interface et de la télésanté dans une approche d'«humanisme numérique» en santé?" In : *Revue française des sciences de l'information et de la communication* 9.
- BOYLE, Adrian et al. (2016). "Comparison of the International Crowding Measure in Emergency Departments (ICMED) and the National Emergency Department Overcrowding Score (NE-DOCS) to measure emergency department crowding : pilot study". In : *Emergency Medicine Journal* 33.5, p. 307-312.
- BOYLE, Justin et al. (2012). "Predicting emergency department admissions". In : *Emergency Medicine Journal* 29.5, p. 358-365.
- BUFFET, Olivier (2003). "Une double approche modulaire de l'apprentissage par renforcement pour des agents intelligents adaptatifs". Thèse de doct. Université Henri Poincaré-Nancy I.
- BUNEL, Rudy et al. (2020). "Branch and bound for piecewise linear neural network verification". In : *Journal of Machine Learning Research* 21.2020.
- CABRERA, Eduardo et al. (2012). "Simulation optimization for healthcare emergency departments". In : *Procedia Computer Science* 9, p. 1464-1473.
- CAMERON, Allan et al. (2015). "A simple tool to predict admission at the time of triage". In : *Emergency Medicine Journal* 32.3, p. 174-179.
- 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.
- CARTWRIGHT, Hugh M (2004). *Applications of evolutionary computation in chemistry*. T. 110. Springer Science & Business Media.
- 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 :
- CHARTIER, Yves, J ADAMS et J BARTRAM (2008). "Essential environmental health standards in health care". In : *Geneva : WHO*.
- CHATTERJEE, Parag et al. (2021). "Machine learning in healthcare toward early risk prediction : A case study of liver transplantation". In : *Data Analytics in Biomedical Engineering and Healthcare*. Elsevier, p. 57-72.
- CHAVIS, John et al. (2016). "A simulation model of patient flow through the emergency department to determine the impact of a short stay unit on hospital congestion". In : *2016 Winter Simulation Conference (WSC)*. IEEE, p. 1982-1993.

- CHEN, Yu, Huizhuo YUAN et Yujun LI (2019). "Object-Oriented State Abstraction in Reinforcement Learning for Video Games". In : *2019 IEEE Conference on Games (CoG)*. IEEE, p. 1-4.
- CHIUSANO, Silvia et al. (1997). "Hybrid symbolic-explicit techniques for the graph coloring problem". In : *Proceedings European Design and Test Conference. ED & TC 97*. IEEE, p. 422-426.
- CLAVEL, Daniel, Cristian MAHULEA et Manuel SILVA (2019). "From Healthcare System Specifications to Formal Models". In : *2019 IEEE International Conference on Systems, Man and Cybernetics (SMC)*. IEEE, p. 2344-2351.
- COLLETTE, Yann et Patrick SIARRY (2011). *Optimisation multiobjectif : Algorithmes*. Editions Eyrolles.
- CORNS, Steven, Ajay THUKRAL et Vijay THUKRAL (2014). "5.1. 1 Parametric Analysis Through a Model-based Reference Architecture for Medical Device Development". In : *INCOSE International Symposium*. T. 24. 1. Wiley Online Library, p. 406-417.
- CORONATO, Antonio et al. (2020). "Reinforcement learning for intelligent healthcare applications : A survey". In : *Artificial Intelligence in Medicine* 109, p. 101964.
- COSTIN, Maria (2010). "Logistique hospitalière, un outil du management". In : *Humanisme et Entreprise* 4, p. 29-48.
- COWAN, Robert M et Stephen TRZECIAK (2004). "Clinical review : emergency department overcrowding and the potential impact on the critically ill". In : *Critical care* 9.3, p. 1-5.
- DAGHISTANI, Tahani A et al. (2019). "Predictors of in-hospital length of stay among cardiac patients : A machine learning approach". In : *International journal of cardiology* 288, p. 140-147.
- DAOUDI, Mourad (2012). "Approches de résolution par les métaheuristiques de problèmes d'optimisation combinatoire NP-Difficiles". Thèse de doct. usthb.
- DE JONG, Kenneth A et William M SPEARS (1993). "On the State of Evolutionary Computation." In : *ICGA*. Citeseer, p. 618-625.
- DENG, Yue et al. (2016). "Deep direct reinforcement learning for financial signal representation and trading". In : *IEEE transactions on neural networks and learning systems* 28.3, p. 653-664.
- DOLLEY, Shawn (2018). "Big data's role in precision public health". In : *Frontiers in public health* 6, p. 68.
- DUNIE, Rob et al. (2015). "Magic Quadrant for intelligent business process management suites". In : *Gartner Inc*.
- DURAND, Anne-Claire et al. (2011). "ED patients : how nonurgent are they? Systematic review of the emergency medicine literature". In : *The American journal of emergency medicine* 29.3, p. 333-345.
- DURFEE, Edmund H et Thomas A MONTGOMERY (1991). "Coordination as distributed search in a hierarchical behavior space". In : *IEEE Transactions on Systems, Man, and Cybernetics* 21.6, p. 1363-1378.
- DZIUGAITE, Gintare Karolina et Daniel M ROY (2017). "Computing nonvacuous generalization bounds for deep (stochastic) neural networks with many more parameters than training data". In : *arXiv preprint arXiv :1703.11008*.
- ELDER, Elizabeth, Amy NB JOHNSTON et Julia CRILLY (2015). "Systematic review of three key strategies designed to improve patient flow through the emergency department". In : *Emergency Medicine Australasia* 27.5, p. 394-404.
- ELFAKI, Awad Elkareem Eltjani (2000). "SUDAN UNIVERSITY OF SCIENCE AND TECHNOLOGY COLLEGE OF GRADUATE STUDIES". Thèse de doct. Sudan University of Science et Technology.
- ERNST, Damién, Mevludin GLAVIC et Louis WEHENKEL (2004). "Power systems stability control : reinforcement learning framework". In : *IEEE transactions on power systems* 19.1, p. 427-435.

- ESDAR, Moritz et al. (2017). "Understanding latent structures of clinical information logistics : A bottom-up approach for model building and validating the workflow composite score". In : *International journal of medical informatics* 97, p. 210-220.
- ESFAHANI, Naeem, Ehsan KOUROSHFAR et Sam MALEK (2011). "Taming uncertainty in self-adaptive software". In : *Proceedings of the 19th ACM SIGSOFT symposium and the 13th European conference on Foundations of software engineering*, p. 234-244.
- FARMER, J Doyne et Duncan FOLEY (2009). "The economy needs agent-based modelling". In : *Nature* 460.7256, p. 685-686.
- FAYOUMI, Amjad et Richard WILLIAMS (2021). "An Integrated Socio-Technical Enterprise Modelling : A Scenario of Healthcare System Analysis and Design". In : *Journal of Industrial Information Integration*, p. 100221.
- FERNANDES, Filipe Costa et al. (2009). "A multiagent architecture for solving combinatorial optimization problems through metaheuristics". In : *2009 IEEE International Conference on Systems, Man and Cybernetics*. IEEE, p. 3071-3076.
- FERRARI, Alberto et Marco RUSSO (2016). *Introducing Microsoft Power BI*. Microsoft Press.
- FOGEL, David B (1994). "Evolutionary programming : An introduction and some current directions". In : *Statistics and Computing* 4.2, p. 113-129.
- FOGEL, Lawrence J, Alvin J OWENS et Michael J WALSH (1966). "Artificial intelligence through simulated evolution". In :
- FORCIER, Mélanie Bourassa et al. (2019). "Integrating artificial intelligence into health care through data access : can the GDPR act as a beacon for policymakers?" In : *Journal of Law and the Biosciences* 6.1, p. 317.
- FORMARIER, Monique, Ljiljana JOVIC et al. (2012). *Les concepts en sciences infirmières*. Mallet conseil.
- FORTUN, Michael et Silvan S SCHWEBER (1993). "Scientists and the legacy of World War II : The case of operations research (OR)". In : *Social studies of science* 23.4, p. 595-642.
- FRANÇOIS, P et al. (2013). "Le comité de retour d'expérience (CREX) : une méthode pour l'amélioration de la sécurité des soins". In : *Revue d'épidémiologie et de santé publique* 61.2, p. 155-161.
- FREISLEBEN, Bernd et Peter MERZ (1996). "New genetic local search operators for the traveling salesman problem". In : *International Conference on Parallel Problem Solving from Nature*. Springer, p. 890-899.
- FRICHI, Youness et al. (2018). "Hospital logistics : An effective tool in improving the quality of care". In : *Proceedings of the International Conference on Industrial Engineering and Operations Management*, p. 1229-1238.
- GARIDI, Sarah (2020). "L'adoption d'un système d'information à l'hôpital dans le contexte de la crise sanitaire du coronavirus". In : *Logistique & Management* 28.3-4, p. 169-183.
- GAUJAL, Laetitia et al. (2016). "Première enquête de satisfaction dans une unité de chirurgie ambulatoire dédiée à la cancérologie". In : *Bulletin du Cancer* 103.4, p. 330-335.
- GEANTA, Ioana (2014). "Contribution à un cadre de modélisation de gestion intégrée de l'état de santé de véhicules : Proposition d'un module générique de gestion de la santé support à l'intégration du diagnostic et du pronostic". Thèse de doct. Université de Lorraine.
- GHANES, Karim et al. (2014). "A comprehensive simulation modeling of an emergency department : A case study for simulation optimization of staffing levels". In : *Proceedings of the Winter Simulation Conference 2014*. IEEE, p. 1421-1432.
- GJONI, Oskeol (2015). "Comparison of two model driven architecture approaches for automating business processes, Moskitt Framework and Bizagi Process Management Suite". In : *Mediterranean Journal of Social Sciences* 6.2, p. 615-615.
- GLOVER, Fred (1986). "Future paths for integer programming and links to artificial intelligence". In : *Computers & operations research* 13.5, p. 533-549.

- GLOVER, Fred et Manuel LAGUNA (1997). "Tabu Search Kluwer Academic Publishers". In : Boston, MA.
- GOLDBERG, David E (1989). "Genetic algorithms in search". In : *Optimization, and Machine Learning*.
- GOLDBERG, David E, Robert LINGLE et al. (1985). "Alleles, loci, and the traveling salesman problem". In : *Proceedings of an international conference on genetic algorithms and their applications*. T. 154. Lawrence Erlbaum Hillsdale, NJ, p. 154-159.
- GÓRRIZ, JM et al. (2006). "Optimizing blind source separation with guided genetic algorithms". In : *Neurocomputing* 69.13-15, p. 1442-1457.
- GORUNESCU, Florin, Sally I McCLEAN et Peter H MILLARD (2002). "Using a queueing model to help plan bed allocation in a department of geriatric medicine". In : *Health care management science* 5.4, p. 307-312.
- GRAVES, Henson et Yvonne BIJAN (2011). "Using formal methods with SysML in aerospace design and engineering". In : *Annals of Mathematics and Artificial Intelligence* 63.1, p. 53-102.
- GUL, Muhammet et A Fuat GUNERI (2012). "A computer simulation model to reduce patient length of stay and to improve resource utilization rate in an emergency department service system". In : *International Journal of Industrial Engineering* 19.5, p. 221-231.
- GUTKNECHT, Olivier (2001). "Proposition d'un modèle organisationnel générique de systèmes multi-agents et examen de ses conséquences formelles, implémentatoires et méthodologiques". Thèse de doct. Université Montpellier II-Sciences et Techniques du Languedoc.
- HACHIMI, Hanaa (2013). "Hybridations d'algorithmes métaheuristiques en optimisation globale et leurs applications". Thèse de doct. INSA de Rouen.
- HALINKA, Adrian, Piotr RZEPKA et Mateusz SZABLICKI (2015). "Agent model of multi-agent system for area power system protection". In : *2015 Modern Electric Power Systems (MEPS)*. IEEE, p. 1-4.
- HAN, Mengjie et al. (2021). "The reinforcement learning method for occupant behavior in building control : a review". In : *Energy and Built Environment* 2.2, p. 137-148.
- HAO, Jin-Kao, Philippe GALINIER et Michel HABIB (1999). "Métaheuristiques pour l'optimisation combinatoire et l'affectation sous contraintes". In : *Revue d'intelligence artificielle* 13.2, p. 283-324.
- HE, Lu et al. (2019). "A systematic review of research design and modeling techniques in inpatient bed management". In : *Computers & Industrial Engineering* 127, p. 451-466.
- HEJAZI, Taha-Hossein, Hossein BADRI et Kai YANG (2019). "A reliability-based approach for performance optimization of service industries : An application to healthcare systems". In : *European Journal of Operational Research* 273.3, p. 1016-1025.
- HEREDIA, Paulo C et Shaoshuai MOU (2019). "Distributed multi-agent reinforcement learning by actor-critic method". In : *IFAC-PapersOnLine* 52.20, p. 363-368.
- HESTER, Todd et Peter STONE (2013). "Texplora : real-time sample-efficient reinforcement learning for robots". In : *Machine learning* 90.3, p. 385-429.
- HO, Ting-Yu, Shan LIU et Zelda B ZABINSKY (2019). "A branch and bound algorithm for dynamic resource allocation in population disease management". In : *Operations Research Letters* 47.6, p. 579-586.
- HOLLAND, John H (1962). "Outline for a logical theory of adaptive systems". In : *Journal of the ACM (JACM)* 9.3, p. 297-314.
- (1975). "Adaptation in natural and artificial systems". In : *Ann Arbor : University of Michigan Press*.
- HOLLING, Crawford S (1966). "The strategy of building models of complex ecological systems". In : *Systems analysis in ecology*, p. 195-214.

- HORWITZ, Leora I, Jeremy GREEN et Elizabeth H BRADLEY (2010). "US emergency department performance on wait time and length of visit". In : *Annals of emergency medicine* 55.2, p. 133-141.
- HOYLE, Lisa (2013). "Condition yellow : a hospital-wide approach to ED overcrowding". In : *Journal of Emergency Nursing* 39.1, p. 40-45.
- HUANG, Ying et al. (2020). "A fitness landscape ruggedness multiobjective differential evolution algorithm with a reinforcement learning strategy". In : *Applied Soft Computing* 96, p. 106693.
- 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.
- JACOBSON, Ivar, Magnus CHRISTERSON et Larry L CONSTANTINE (1994). "The OOSE method : a use—case-driven approach". In : *Object development methods*, p. 247-270.
- JACQUES, FERBER (1995). "Les systèmes multi-agents : vers une intelligence collective". In : *InterEditions, Paris* 322.
- JEBALI, Aida, Atidel B Hadj ALOUANE et Pierre LADET (2006). "Operating rooms scheduling". In : *International Journal of Production Economics* 99.1-2, p. 52-62.
- JIA, Shengde, Lincheng SHEN et Hongtao XUE (2015). "Continuous-time Markov decision process with average reward : Using reinforcement learning method". In : *2015 34th Chinese Control Conference (CCC)*. IEEE, p. 3097-3100.
- JIANG, Yan et al. (2014). "Comparing a hybrid branch and bound algorithm with evolutionary computation methods, local search and their hybrids on the tsp". In : *2014 IEEE Symposium on Computational Intelligence in Production and Logistics Systems (CIPLS)*. IEEE, p. 148-155.
- JIAO, Wenpin et Yanchun SUN (2016). "Self-adaptation of multi-agent systems in dynamic environments based on experience exchanges". In : *Journal of Systems and Software* 122, p. 165-179.
- JIN, Xiaolong et Jiming LIU (2002). "Multiagent SAT (MASSAT) : Autonomous pattern search in constrained domains". In : *International Conference on Intelligent Data Engineering and Automated Learning*. Springer, p. 318-328.
- KAMALDINOV, Ildar et Ilya MAKAROV (2019). "Deep reinforcement learning in match-3 game". In : *2019 IEEE conference on games (CoG)*. IEEE, p. 1-4.
- KAMOUN, Mohamed Amine (2007). "Conception d'un système d'information pour l'aide au déplacement multimodal : Une approche multi-agents pour la recherche et la composition des itinéraires en ligne." Thèse de doct. Ecole Centrale de Lille.
- KAWANO, Takahisa et al. (2014). "Direct relationship between aging and overcrowding in the ED, and a calculation formula for demand projection : a cross-sectional study". In : *Emergency medicine journal* 31.1, p. 19-23.
- KAZIL, Jackie, David MASAD et Andrew CROOKS (2020). "Utilizing Python for Agent-Based Modeling : The Mesa Framework". In : *International Conference on Social Computing, Behavioral-Cultural Modeling and Prediction and Behavior Representation in Modeling and Simulation*. Springer, p. 308-317.
- KELLERMANN, Arthur L et al. (2013). "Emergency care : then, now, and next". In : *Health affairs* 32.12, p. 2069-2074.
- KHALDI, Rohaifa, Abdellatif EL AFIA et Raddouane CHIHEB (2019). "Forecasting of weekly patient visits to emergency department : real case study". In : *Procedia computer science* 148, p. 532-541.
- KHAMPARIA, Aditya et Karan Mehtab SINGH (2019). "A systematic review on deep learning architectures and applications". In : *Expert Systems* 36.3, e12400.
- KHARE, Rahul K et al. (2009). "Adding more beds to the emergency department or reducing admitted patient boarding times : which has a more significant influence on emergency department congestion?" In : *Annals of emergency medicine* 53.5, p. 575-585.

- KIM, Susan W et al. (2014). "Predicting admission of patients by their presentation to the emergency department". In : *Emergency Medicine Australasia* 26.4, p. 361-367.
- KIM, Woojae et al. (2012). "Development of novel breast cancer recurrence prediction model using support vector machine". In : *Journal of breast cancer* 15.2, p. 230.
- KIRKLAND, Scott William et al. (2019). "A systematic review examining the impact of redirecting low-acuity patients seeking emergency department care : is the juice worth the squeeze?" In : *Emergency Medicine Journal* 36.2, p. 97-106.
- KIRKPATRICK, Scott, C Daniel GELATT et Mario P VECCHI (1983). "Optimization by simulated annealing". In : *science* 220.4598, p. 671-680.
- KOBER, Jens, J Andrew BAGNELL et Jan PETERS (2013). "Reinforcement learning in robotics : A survey". In : *The International Journal of Robotics Research* 32.11, p. 1238-1274.
- KOTRONIS, Ch et al. (2018). "A model-based approach for managing criticality requirements in e-health IoT systems". In : *2018 13th annual conference on system of systems engineering (SoSE)*. IEEE, p. 60-67.
- KRASNOGOR, Natalio et James SMITH (2005). "A tutorial for competent memetic algorithms : model, taxonomy, and design issues". In : *IEEE Transactions on Evolutionary Computation* 9.5, p. 474-488.
- KRIEGEL, Johannes et al. (2013). "Advanced services in hospital logistics in the German health service sector". In : *Logistics Research* 6.2-3, p. 47-56.
- 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.
- LABED, Said, KOUT AKRAM et Salim CHIKHI (2018). "Solving the graph b-coloring problem with hybrid genetic algorithm". In : *2018 3rd International Conference on Pattern Analysis and Intelligent Systems (PAIS)*. IEEE, p. 1-7.
- LÄNGKVIST, Martin, Lars KARLSSON et Amy LOUTFI (2014). "A review of unsupervised feature learning and deep learning for time-series modeling". In : *Pattern Recognition Letters* 42, p. 11-24.
- LEE, Seunghoon et Young Hoon LEE (2020). "Improving emergency department efficiency by patient scheduling using deep reinforcement learning". In : *Healthcare*. T. 8. 2. Multidisciplinary Digital Publishing Institute, p. 77.
- LEE, Sungtae et al. (2017). "Micro-objective learning : Accelerating deep reinforcement learning through the discovery of continuous subgoals". In : *arXiv preprint arXiv :1703.03933*.
- LEO, Carlo Giacomo et al. (2019). "Obstructive sleep apnoea : Improving healthcare services by combining process modelling and population analysis". In : *International journal of medical informatics* 127, p. 43-51.
- LEO, Gianmaria et al. (2016). "Emergency department management in Lazio, Italy". In : *Omega* 58, p. 128-138.
- LI, Munan et Fen HUANG (2016). "Formal describing the organizations in the pervasive healthcare information system : Multi-agent system perspective". In : *2016 International Conference on Advanced Robotics and Mechatronics (ICARM)*. IEEE, p. 524-529.
- 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.
- LIMNIOS, Nikolaos et Gheorghe OPRISAN (2012). *Semi-Markov processes and reliability*. Springer Science & Business Media.
- LIN, Fu-Ren et al. (2013). "Modeling an Agent-Based Healthcare Service System : An Exploration of the Capitation Payment Scheme of Zhishan-CHG in Taiwan". In : *2013 Fifth International Conference on Service Science and Innovation*. IEEE, p. 67-74.

- LIN, Kai et al. (2016). "Enhanced fingerprinting and trajectory prediction for IoT localization in smart buildings". In : *IEEE Transactions on Automation Science and Engineering* 13.3, p. 1294-1307.
- LIU, Zhuo et al. (2019). "Deep reinforcement learning with its application for lung cancer detection in medical Internet of Things". In : *Future Generation Computer Systems* 97, p. 1-9.
- LONG, Brit, Alex KOYFMAN et Michael GOTTLIEB (2019). "An evidence-based narrative review of the emergency department evaluation and management of rhabdomyolysis". In : *The American journal of emergency medicine* 37.3, p. 518-523.
- MAMEI, Marco et Franco ZAMBONELLI (2006). *Field-based coordination for pervasive multiagent systems*. Springer Science & Business Media.
- MANDAVIA, Sujai et Loretta SAMANIEGO (2016). "Improving ED efficiency to capture additional revenue". In : *Healthcare Financial Management* 70.6, p. 66-70.
- MARKS, Robert E (2013). "Validation and model selection : Three similarity measures compared". In : *Complexity Economics* 2.1, p. 41-61.
- MASAD, David et Jacqueline KAZIL (2015). "MESA : an agent-based modeling framework". In : *14th PYTHON in Science Conference*. Citeseer, p. 53-60.
- MATUCHANSKY, Claude (2019). "Intelligence clinique et intelligence artificielle-Une question de nuance". In : *médecine/sciences* 35.10, p. 797-803.
- MCCARTHY, John et Patrick J HAYES (1981). "Some philosophical problems from the standpoint of artificial intelligence". In : *Readings in artificial intelligence*. Elsevier, p. 431-450.
- MELO, Teresa (2012). *A note on challenges and opportunities for Operations Research in hospital logistics*. Rapp. tech. Schriftenreihe Logistik der Fakultät für Wirtschaftswissenschaften der HTW ...
- METROPOLIS, Nicholas et al. (1953). "Equation of state calculations by fast computing machines". In : *The journal of chemical physics* 21.6, p. 1087-1092.
- MGUI, Fethi et al. (2012). "Modélisation d'un Système Multi-Agent pour la résolution d'un Problème de Tournées de Véhicule dans une situation d'urgence". In : *9th International Conference on Modeling, Optimization & SIMulation*, 7-pages.
- MILANO, Michela et Andrea ROLI (2004). "Magma : A multiagent architecture for metaheuristics". In : *IEEE Transactions on Systems, Man, and Cybernetics, Part B (Cybernetics)* 34.2, p. 925-941.
- MINCARONE, Pierpaolo et al. (2018). "Standardized languages and notations for graphical modeling of patient care processes : a systematic review". In : *International Journal for Quality in Health Care* 30.3, p. 169-177.
- MIRZAZADEH, Farzaneh, Babak BEHSAZ et Hamid BEIGY (2007). "A new learning algorithm for the maxq hierarchical reinforcement learning method". In : *2007 International Conference on Information and Communication Technology*. IEEE, p. 105-108.
- MOREL, Marie-Agnès (2012). "Qualité des soins". In : *Les concepts en sciences infirmières*. ARSI, Toulouse, p. 256-260.
- MOSCATO, Pablo (1999). "Memetic algorithms : A short introduction". In : *New ideas in optimization*, p. 219-234.
- 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.
- MU, Chaoxu et al. (2019). "Q-learning solution for optimal consensus control of discrete-time multiagent systems using reinforcement learning". In : *Journal of the Franklin Institute* 356.13, p. 6946-6967.
- NAFIE, Faisal M (2016). "The comparison of the workflow management systems Bizagi, Arabdox, Bonita and Joget". In : *International Journal of Engineering Science Invention* 5.5, p. 26-31.

- NAOURI, Diane et al. (2020). "Factors associated with inappropriate use of emergency departments : findings from a cross-sectional national study in France". In : *BMJ quality & safety* 29.6, p. 449-464.
- NEALON, John L (2003). *Applications of software agent technology in the health care domain*. Springer Science & Business Media.
- NOEL, Guilhem (2019). "TENSION DANS LES SERVICES D'URGENCE : QUANTIFICATION, IMPACT ET OUTILS DE FLUIDIFICATION DE L'AVANT DES URGENCES." In :
- 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.
- NOEL, 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.
- NOIZET, M et al. (2020). "Retour d'expérience de deux structures d'urgences de centres hospitaliers généraux pendant la crise de la Covid-19". In : *Annales françaises de médecine d'urgence* 10.4-5, p. 243-250.
- OLIVER, IM, DJd SMITH et John RC HOLLAND (1987). "Study of permutation crossover operators on the traveling salesman problem". In : *Genetic algorithms and their applications : proceedings of the second International Conference on Genetic Algorithms : July 28-31, 1987 at the Massachusetts Institute of Technology, Cambridge, MA*. Hillsdale, NJ : L. Erlbaum Associates, 1987.
- OREDSSON, Sven et al. (2011). "A systematic review of triage-related interventions to improve patient flow in emergency departments". In : *Scandinavian journal of trauma, resuscitation and emergency medicine* 19.1, p. 1-9.
- ORGANIZATION, World Health et al. (2012). *WHO QualityRights tool kit : assessing and improving quality and human rights in mental health and social care facilities*. World Health Organization.
- (2015). "Global standards for quality health-care services for adolescents : a guide to implement a standards-driven approach to improve the quality of health care services for adolescents". In :
- (2017). "What is quality of care and why is it important". In : *World Health Organization*.
- (2020). "Standards for improving the quality of care for small and sick newborns in health facilities". In :
- PADBERG, Manfred et Giovanni RINALDI (1991). "A branch-and-cut algorithm for the resolution of large-scale symmetric traveling salesman problems". In : *SIAM review* 33.1, p. 60-100.
- PAN, Wei, Xiaotong SHEN et Binghui LIU (2013). "Cluster Analysis : Unsupervised Learning via Supervised Learning with a Non-convex Penalty." In : *Journal of Machine Learning Research* 14.7.
- PARK, Hyun Sang, Hune CHO et Hwa Sun KIM (2016). "Development of a multi-agent m-health application based on various protocols for chronic disease self-management". In : *Journal of medical systems* 40.1, p. 1-14.
- PARK, Jangsoo, Jongseok LEE et Donggyu SIM (2020). "Low-complexity CNN with 1D and 2D filters for super-resolution". In : *Journal of Real-Time Image Processing* 17.6, p. 2065-2076.
- 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.
- PATEL, Pankaj B, Mary A COMBS et David R VINSON (2014). "Reduction of admit wait times : the effect of a leadership-based program". In : *Academic Emergency Medicine* 21.3, p. 266-273.
- 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.

- PESAPANE, Filippo et al. (2018). "Artificial intelligence as a medical device in radiology : ethical and regulatory issues in Europe and the United States". In : *Insights into imaging* 9.5, p. 745-753.
- 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.
- POŁAP, Dawid, Gautam SRIVASTAVA et Keping YU (2021). "Agent architecture of an intelligent medical system based on federated learning and blockchain technology". In : *Journal of Information Security and Applications* 58, p. 102748.
- POWERS, Jordan G et al. (2017). "The weather research and forecasting model : Overview, system efforts, and future directions". In : *Bulletin of the American Meteorological Society* 98.8, p. 1717-1737.
- PROUDLOVE, Nathan C (2020). "The 85% bed occupancy fallacy : The use, misuse and insights of queuing theory". In : *Health services management research* 33.3, p. 110-121.
- PROUDLOVE, NC, K GORDON et R BOADEN (2003). "Can good bed management solve the overcrowding in accident and emergency departments?" In : *Emergency Medicine Journal* 20.2, p. 149-155.
- PUTERMAN, Martin L (2014). *Markov decision processes : discrete stochastic dynamic programming*. John Wiley & Sons.
- REEVES, Colin R (1995). "Genetic algorithms and combinatorial optimization". In : *Applications of modern heuristic methods* 111, p. 126.
- REEVES, CR (1993). "Modern heuristic techniques for combinatorial problems Blackwell Scientific Press". In : *Oxford, UK* 1.99, p. 2.
- REID, Malcolm et Elhadi M SHAKSHUKI (2017). "Implementing a multi-agent system for recording and transmitting biometric information of elderly citizens". In : *Procedia computer science* 113, p. 334-343.
- REN, Ziwu et Ye SAN (2006). "A hybrid optimized algorithm based on simplex method and genetic algorithm". In : *2006 6th World Congress on Intelligent Control and Automation*. T. 1. IEEE, p. 3547-3551.
- RICHTER, Aaron N et Taghi M KHOSHGOFTAAR (2018). "A review of statistical and machine learning methods for modeling cancer risk using structured clinical data". In : *Artificial intelligence in medicine* 90, p. 1-14.
- ROQUES, Pascal (2011). *SysML par l'exemple-Un langage de modélisation pour systèmes complexes*. Editions Eyrolles.
- ROQUES, Pascal et Franck VALLÉE (2004). "UML 2 en action". In : *De l'analyse des besoins à la conception J2EE*, p. 15.
- ROSTAMI-TABAR, Bahman et Florian ZIEL (2020). "Anticipating special events in Emergency Department forecasting". In : *International Journal of Forecasting*.
- ROTUNĂ, Carmen et al. (2019). "New tendencies in linear prediction of events". In : *Rom. J. Inf. Technol. Autom. Control* 29.3, p. 19-30.
- RUMBAUGH, James (1996). *OMT Insights : Perspective on Modeling from the Journal of Object-Oriented Programming*. T. 6. Cambridge University Press.
- 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.
- SAMPIERI-TEISSIER, Nathalie (2016). "Valoriser la logistique hospitalière au service des patients". In : *Supply Chain Magazine* 102, p. 144-145.

- SAYAH, Assaad et al. (2016). "Emergency department expansion versus patient flow improvement : impact on patient experience of care". In : *The Journal of emergency medicine* 50.2, p. 339-348.
- SCHRIJVER, Alexander (1986). "Theory of linear and integer programming. John Wiley & Sons". In : *Inc., Chichester*.
- SCHULMAN, John et al. (2015). "Trust region policy optimization". In : *International conference on machine learning*. PMLR, p. 1889-1897.
- SCHWALBE, Nina et Brian WAHL (2020). "Artificial intelligence and the future of global health". In : *The Lancet* 395.10236, p. 1579-1586.
- SHAKSHUKI, Elhadi et Malcolm REID (2015). "Multi-agent system applications in healthcare : Current technology and future roadmap". In : *Procedia Computer Science* 52, p. 252-261.
- SHANI, Guy, Joelle PINEAU et Robert KAPLOW (2013). "A survey of point-based POMDP solvers". In : *Autonomous Agents and Multi-Agent Systems* 27.1, p. 1-51.
- SHEN, Ying et al. (2015). "Emerging medical informatics with case-based reasoning for aiding clinical decision in multi-agent system". In : *Journal of biomedical informatics* 56, p. 307-317.
- SILVA, Maria Amélia Lopes et al. (2014). "An agent-based metaheuristic approach applied to the vehicle routing problem with time-windows". In : *Proc. of the 2014 Brazilian Conference on Intelligent Systems-Enc. Nac. de Inteligência Artificial e Computacional (BRACIS-ENIAC 2014)*.
- SILVA, Maria Amélia Lopes et al. (2015). "A multi-agent metaheuristic optimization framework with cooperation". In : *2015 Brazilian Conference on Intelligent Systems (BRACIS)*. IEEE, p. 104-109.
- SILVA, Maria Amélia Lopes et al. (2018). "Hybrid metaheuristics and multi-agent systems for solving optimization problems : A review of frameworks and a comparative analysis". In : *Applied Soft Computing* 71, p. 433-459.
- SILVER, David et al. (2014). "Deterministic policy gradient algorithms". In : *International conference on machine learning*. PMLR, p. 387-395.
- SILVER, David et al. (2016). "Mastering the game of Go with deep neural networks and tree search". In : *nature* 529.7587, p. 484-489.
- SINGAL, Amit G et al. (2013). "Machine learning algorithms outperform conventional regression models in predicting development of hepatocellular carcinoma". In : *The American journal of gastroenterology* 108.11, p. 1723.
- 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.
- SINREICH, David et Ola JABALI (2007). "Staggered work shifts : a way to downsize and restructure an emergency department workforce yet maintain current operational performance". In : *Health care management science* 10.3, p. 293-308.
- 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.
- SVIRSKO, Anna Camille et al. (2019). "Using mathematical modeling to improve the emergency department nurse-scheduling process". In : *Journal of Emergency Nursing* 45.4, p. 425-432.
- SWEENEY, Linda Booth et Dennis MEADOWS (2010). *The systems thinking playbook : Exercises to stretch and build learning and systems thinking capabilities*. Chelsea Green Publishing.
- SYED, Samina T, Ben S GERBER et Lisa K SHARP (2013). "Traveling towards disease : transportation barriers to health care access". In : *Journal of community health* 38.5, p. 976-993.
- TABIA, Nourredine et al. (2014). "Recherche Tabou Robuste pour l'allocation de fréquences". In : *ROADEF 2014, 15ème congrès annuel de la Société française de recherche opérationnelle et d'aide à la décision*.
- TABOADA, Manel et al. (2011). "An agent-based decision support system for hospitals emergency departments". In : *Procedia Computer Science* 4, p. 1870-1879.

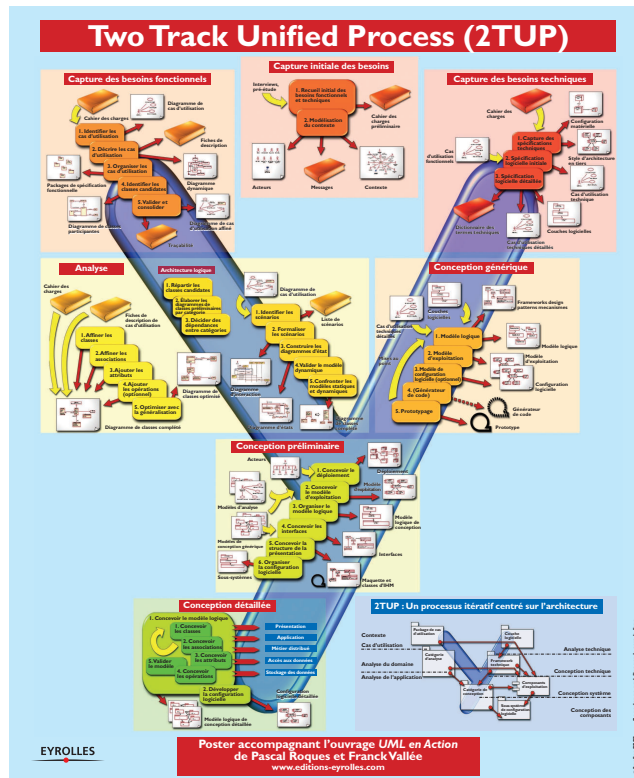
- TABOULET, P et al. (2019). "Validité de la FRENCH, l'échelle de tri des urgences hospitalières élaborée par la Société française de médecine d'urgence". In : *Annales françaises de médecine d'urgence* 9.1, p. 10-16.
- TAKAKUWA, Kevin M, Frances S SHOFRER et Stephanie B ABBUHL (2007). "Strategies for dealing with emergency department overcrowding : a one-year study on how bedside registration affects patient throughput times". In : *The Journal of emergency medicine* 32.4, p. 337-342.
- TALBI, EG, Z HAFIDI et JM GEIB (1997). "Parallel adaptive tabu search for large optimization problems". In :
- TASHAKOR, Ghazal et Remo SUPPI (2019). "Agent-based model for tumour-analysis using Python+ Mesa". In : *arXiv preprint arXiv :1909.01885*.
- TAYLOR, Matthew E et Peter STONE (2005). "Behavior transfer for value-function-based reinforcement learning". In : *Proceedings of the fourth international joint conference on Autonomous agents and multiagent systems*, p. 53-59.
- TAYLOR, Sean J et Benjamin LETHAM (2018). "Forecasting at scale". In : *The American Statistician* 72.1, p. 37-45.
- THIBON, E et al. (2019). "Association entre mortalité et attente aux urgences chez les adultes à hospitaliser pour étiologies médicales". In : *Annales françaises de médecine d'urgence* 9.4, p. 229-234.
- THORNE, Bryan C, Alexander M BAILEY et Shayn M PEIRCE (2007). "Combining experiments with multi-cell agent-based modeling to study biological tissue patterning". In : *Briefings in bioinformatics* 8.4, p. 245-257.
- TODDE, Marco et al. (2020). "Methodology and workflow to perform the data protection impact assessment in healthcare information systems". In : *Informatics in Medicine Unlocked* 19, p. 100361.
- TODOSIJEVIĆ, Raca (2015). "Contributions théoriques et pratiques pour la recherche dispersée, recherche à voisinage variable et matheuristique pour les programmes en nombres entiers mixtes". Thèse de doct. Valenciennes.
- TREUIL, Jean-Pierre, Alexis DROGOUL et Jean-Daniel ZUCKER (2008). *Modélisation et simulation à base d'agents : exemples commentés, outils informatiques et questions théoriques*. Dunod.
- TSANTEKIDIS, Avraam, Nikolaos PASSALIS et Anastasios TEFAS (2021). "Diversity-driven knowledge distillation for financial trading using Deep Reinforcement Learning". In : *Neural Networks*.
- URIARTE, Ainhoa Goienetxea et al. (2017). "How can decision makers be supported in the improvement of an emergency department? A simulation, optimization and data mining approach". In : *Operations Research for Health Care* 15, p. 102-122.
- VAART, Elske van der, Alice SA JOHNSTON et Richard M SIBLY (2016). "Predicting how many animals will be where : how to build, calibrate and evaluate individual-based models". In : *Ecological modelling* 326, p. 113-123.
- VAN DER AALST, Wil MP (2003). "Business process management demystified : A tutorial on models, systems and standards for workflow management". In : *Advanced Course on Petri Nets*. Springer, p. 1-65.
- VAN HASSELT, Hado, Arthur GUEZ et David SILVER (2016). "Deep reinforcement learning with double q-learning". In : *Proceedings of the AAAI Conference on Artificial Intelligence*. T. 30. 1.
- VANBRABANT, Lien et al. (2019). "Simulation of emergency department operations : A comprehensive review of KPIs and operational improvements". In : *Computers & Industrial Engineering* 131, p. 356-381.
- VASILAKIS, C, D LECZNAROWICZ et C LEE (2009). "Developing model requirements for patient flow simulation studies using the Unified Modelling Language (UML)". In : *Journal of Simulation* 3.3, p. 141-149.

- VERMEULEN, Ivan et al. (2007). "Multi-agent Pareto appointment exchanging in hospital patient scheduling". In : *Service Oriented Computing and Applications* 1.3, p. 185-196.
- VISSERS, Jan MH, JWM BERTRAND et Guus DE VRIES (2001). "A framework for production control in health care organizations". In : *Production Planning & Control* 12.6, p. 591-604.
- VOLLAND, Jonas et al. (2017). "Material logistics in hospitals : a literature review". In : *Omega* 69, p. 82-101.
- WAGNER, Gerd (2003). "The Agent-Object-Relationship metamodel : towards a unified view of state and behavior". In : *Information Systems* 28.5, p. 475-504.
- WAHBA, Maram A, Amira S ASHOUR et Rami GHANNAM (2020). "Prediction of harvestable energy for self-powered wearable healthcare devices : Filling a gap". In : *IEEE Access* 8, p. 170336-170354.
- WAHL, Brian et al. (2018). "Artificial intelligence (AI) and global health : how can AI contribute to health in resource-poor settings?" In : *BMJ global health* 3.4, e000798.
- WANG, Dong et al. (2018a). "A modified distributed optimization method for both continuous-time and discrete-time multi-agent systems". In : *Neurocomputing* 275, p. 725-732.
- WANG, Ge et al. (2018b). "Image reconstruction is a new frontier of machine learning". In : *IEEE transactions on medical imaging* 37.6, p. 1289-1296.
- WANG, Xiaoliang et Adrian RUTLE (2014). "Model checking healthcare workflows using alloy". In : *Procedia Computer Science* 37, p. 481-488.
- WANG, Zhen et al. (2018c). "Causes of emergency department overcrowding and blockage of access to critical services in Beijing : a 2-year study". In : *The Journal of emergency medicine* 54.5, p. 665-673.
- WATERS, Stuart et al. (2016). "Identification of factors influencing patient satisfaction with orthopaedic outpatient clinic consultation : a qualitative study". In : *Manual therapy* 25, p. 48-55.
- WEISS, Steven J et al. (2004). "Estimating the degree of emergency department overcrowding in academic medical centers : results of the National ED Overcrowding Study (NEDOCS)". In : *Academic Emergency Medicine* 11.1, p. 38-50.
- WENG, Shao-Jen et al. (2011). "Simulation optimization for emergency department resources allocation". In : *Proceedings of the 2011 winter simulation conference (WSC)*. IEEE, p. 1231-1238.
- WHITLEY, L Darrell, Timothy STARKWEATHER et D'Ann FUQUAY (1989). "Scheduling problems and traveling salesmen : The genetic edge recombination operator". In : *ICGA*. T. 89, p. 133-40.
- WILENSKY, Uri et William RAND (2015). *An introduction to agent-based modeling : modeling natural, social, and engineered complex systems with NetLogo*. Mit Press.
- WONG, Tse-Chiu, Mai XU et Kwai-Sang CHIN (2014). "A two-stage heuristic approach for nurse scheduling problem : A case study in an emergency department". In : *Computers & Operations Research* 51, p. 99-110.
- WOODWARD, Thomas et al. (2019). "Impact of an emergency department-run clinical decision unit on access block, ambulance ramping and National Emergency Access Target". In : *Emergency Medicine Australasia* 31.2, p. 200-204.
- WOOLDRIDGE, Michael, Nicholas R JENNINGS et David KINNY (2000). "The Gaia methodology for agent-oriented analysis and design". In : *Autonomous Agents and multi-agent systems* 3.3, p. 285-312.
- WRETBORN, Jens et al. (2015). "Skåne Emergency Department Assessment of Patient Load (SEAL)—A Model to Estimate Crowding Based on Workload in Swedish Emergency Departments". In : *PloS one* 10.6, e0130020.
- XIAO, Tianjun et al. (2015). "The application of two-level attention models in deep convolutional neural network for fine-grained image classification". In : *Proceedings of the IEEE conference on computer vision and pattern recognition*, p. 842-850.

- YANG, Shengxiang, Hui CHENG et Fang WANG (2009). "Genetic algorithms with immigrants and memory schemes for dynamic shortest path routing problems in mobile ad hoc networks". In : *IEEE Transactions on Systems, Man, and Cybernetics, Part C (Applications and Reviews)* 40.1, p. 52-63.
- YOUSEFI, Milad et al. (2018). "Chaotic genetic algorithm and Adaboost ensemble metamodeling approach for optimum resource planning in emergency departments". In : *Artificial intelligence in medicine* 84, p. 23-33.
- YU, Bin, Zhong-Zhen YANG et Baozhen YAO (2009). "An improved ant colony optimization for vehicle routing problem". In : *European journal of operational research* 196.1, p. 171-176.
- ZEMOUR, L, A BELGHITRI et N MIDOUN (2018). "Satisfaction des utilisateurs du dossier électronique médical dans le système d'information hospitalier, Oran". In : *Revue des Maladies Respiratoires* 35, A235-A236.
- ZGAYA, Hayfa et Slim HAMMADI (2016). *Logistics Engineering and Health*. Elsevier.
- ZHAO, Dongbin et al. (2016). "Deep reinforcement learning with experience replay based on SARSA". In : *2016 IEEE Symposium Series on Computational Intelligence (SSCI)*. IEEE, p. 1-6.
- ZHAO, Minhua, Junqi YU et Guanghua ZHAO (2009). "Modeling a complex socioeconomic systems using multi-agent platform". In : *2009 International Conference on Artificial Intelligence and Computational Intelligence*. T. 4. IEEE, p. 501-505.
- ZHENG, Yujun et al. (2012). "Distributed agent based cooperative differential evolution : A master-slave model". In : *2012 IEEE 2nd International Conference on Cloud Computing and Intelligence Systems*. T. 1. IEEE, p. 376-380.
- ZIMMER, Matthieu, Yann BONIFACE et Alain DUTECH (2018). "Developmental reinforcement learning through sensorimotor space enlargement". In : *2018 Joint IEEE 8th International Conference on Development and Learning and Epigenetic Robotics (ICDL-EpiRob)*. IEEE, p. 33-38.
- ZITZLER, Eckart (1999). *Evolutionary algorithms for multiobjective optimization : Methods and applications*. T. 63. Citeseer.
- ZOLFPUR-AROKHLO, Mortaza et M Reza MASHINCHI (2016). "A multi-agent system approach to control road transportation network". In : *2016 1st Conference on Swarm Intelligence and Evolutionary Computation (CSIEC)*. IEEE, p. 42-46.
- ZULKEPLI, Jafri et Tillal ELDABI (2015). "Towards a framework for conceptual model hybridization in healthcare". In : *2015 Winter Simulation Conference (WSC)*. IEEE, p. 1597-1608.

Annexes

Annexe B



Résumé

Cette thèse s'attaque à des problèmes d'ordonnement des patients aux urgences, avec prise en compte des contraintes d'aval, en utilisant des approches d'optimisation collaboratives optimisant le temps d'attente global moyen des patients. Ces approches sont utilisées en intégrant, dans le comportement de chaque agent, une métaheuristique qui évolue efficacement, grâce à deux protocoles d'interaction "amis" et "ennemis". En outre, chaque agent s'auto-adapte à l'aide d'un algorithme d'apprentissage par renforcement adapté au problème étudié. Cette auto-adaptation tient compte d'expériences des agents et de leurs connaissances de l'environnement des urgences. Afin d'assurer la continuité d'une prise en charge de qualité des patients, nous proposons également dans cette thèse, une approche conjointe d'ordonnement et d'affectation des lits d'aval aux patients. Nous illustrons les approches collaboratives proposées et démontrons leurs efficacités sur des données réelles provenant des services des urgences du CHU de Lille obtenues dans le cadre du projet ANR OILH. Les résultats de simulations donnent des meilleurs ordonnements par rapport aux scénarios dans lesquels les agents travaillent individuellement ou sans apprentissage. L'application des algorithmes qui gèrent la prise en charge des patients dans les services d'aval, fournit des résultats sous la forme d'un tableau de bord, contenant des informations statiques et dynamiques. Ces informations sont mises à jour en temps réel et permettent aux urgentistes d'orienter plus rapidement les patients vers les structures qui peuvent les accueillir. Ainsi, les résultats des expérimentations montrent que les algorithmes d'IA proposés peuvent améliorer de manière significative l'efficacité de la chaîne des urgences en réduisant le temps d'attente global moyen des patients en inter-intra-urgences.

Mots clés : ordonnancement en santé, métaheuristiques, système multi-agents, apprentissage, optimisation collaborative, logistique hospitalière.

Abstract

This thesis addresses the scheduling patients in emergency department (ED) considering downstream constraints, by using collaborative optimization approaches to optimize the total waiting time of patients. These approaches are used by integrating, in the behavior of each agent, a metaheuristic that evolves efficiently, thanks to two interaction protocols "friends" and "enemies". In addition, each agent self-adapts using a reinforcement learning algorithm adapted to the studied problem. This self-adaptation considers the agents' experiences and their knowledge of the ED environment. The learning of the agents allows to accelerate the convergence by guiding the search for good solutions towards more promising areas in the search space. In order to ensure the continuity of quality patient care, we also propose in this thesis, a joint approach for scheduling and assigning downstream beds to patients. We illustrate the proposed collaborative approaches and demonstrate their effectiveness on real data provided from the ED of the Lille University Hospital Center obtained in the framework of the ANR OILH project. The results obtained show that the collaborative Learning approach leads to better results compared to the scenario in which agents work individually or without learning. The application of the algorithms that manage the patients care in downstream services, provides results in the form of a dashboard, containing static and dynamic information. This information is updated in real time and allows emergency staff to assign patients more quickly to the adequate structures. The results of the simulation show that the proposed AI algorithms can significantly improve the efficiency of the emergency chain by reducing the total waiting time of patients in inter-intra-emergency.

Keywords: healthcare scheduling, metaheuristics, multi-agent systems, learning, collaborative optimization, hospital logistics.
