

Département d'Informatique

THÈSE

Pour obtenir le diplôme de
Doctorat En Sciences

Contribution à la planification réactive : prise en charge des urgences pédiatriques

Présentée par :

Benbelkacem Sofia

Soutenue publiquement
Le 20 janvier 2022

Devant le Jury :

Président	Bouamrane Karim	Professeur	Université Oran1
Examineur	El Berrichi Zakaria	Professeur	Université de Sidi Bel Abès
Examineur	Chikh Mohamed Amine	Professeur	Université de Tlemcen
Examineur	Benslimane Sidi Mohamed	Professeur	ESI Sidi Bel Abès
Examinatrice	Barigou Fatiha	MCA	Université Oran1
Directeur de thèse	Atmani Baghdad	Professeur	Université Oran1
Invité	Khemliche Belarbi	Professeur	Faculté de médecine d'Oran

2021-2022

Résumé

Quotidiennement, au niveau du service des urgences pédiatriques, les enfants sont souvent confrontés à des détresses vitales. L'insuffisance des structures d'accueil par rapport à la fréquence des arrivées des cas d'urgence et le manque en moyens thérapeutiques et de diagnostique causent d'importants problèmes qui justifient l'intérêt d'étudier la prise en charge des urgences médicales qui peut être considérée comme un processus d'aide à la décision destiné à améliorer les services de santé.

Le personnel hospitalier et les urgentistes manquent d'outils pour faire face à de telles situations. Ces outils sont primordiaux pour gérer les ressources humaines et matérielles du service des urgences ainsi que pour la planification de la prise en charge de celles-ci.

En réponse à ces besoins, et dans le cadre de cette thèse, nous proposons une démarche d'aide à la prise en charge des urgences guidée par apprentissage automatique.

Mots-clés: Aide à la décision médicale, Apprentissage automatique, Fouille de données, Planification, Urgences pédiatriques.

Abstract

In the daily life of pediatric emergency departments, children often face life-threatening distress. The insufficiency of reception facilities in relation to the frequency of emergencies and the lack of therapeutic and diagnostic means cause important problems that justify the interest of studying emergency management. Hospital staff and emergency physicians lack tools to deal with this situation. These tools are essential for managing human and material resources of the emergency department as well as for emergency management planning.

In response to these needs, and as part of this thesis, we propose an approach based on machine learning to assist emergency management.

Keywords: Medical decision support, Machine learning, Data mining, Planning, Pediatric emergency.

ملخص

غالبًا ما يواجه الأطفال ضغوطًا تهدد حياتهم في خدمات الطوارئ اليومية. الافتقار إلى الوسائل العلاجية والتشخيصية وعدم كفاية مرافق الاستقبال فيما يتعلق بتواتر حالات الطوارئ يسببان مشاكل مهمة تبرر الاهتمام بدراسة إدارة حالات الطوارئ. يفتقر موظفو المستشفى وأطباء الطوارئ إلى الأدوات اللازمة للتعامل مع هذه الحالة. هذه الأدوات ضرورية لإدارة الموارد البشرية والمادية لقسم الطوارئ ، وكذلك للتخطيط لإدارة الطوارئ. استجابة لهذه الاحتياجات و كجزء من هذه الأطروحة ، نقترح نهجًا للمساعدة في إدارة حالات الطوارئ التي تسترشد بالتعلم التلقائي.

الكلمات المفتاحية : دعم القرار الطبي ، التعلم التلقائي ، استخراج البيانات ، التخطيط ، طوارئ الأطفال.

Table des matières

1. Contexte et problématique	1
1.1. Introduction.....	2
1.2. Planification réactive	3
1.3. Prise en charge des urgences médicales.....	4
1.4. Prédiction de la durée de séjour	8
1.5. Contributions de la thèse.....	9
1.6. Organisation du manuscrit	10
2. Aide à la décision médicale dans les urgences	12
2.1. Objectifs	13
2.2. Notions de base	13
2.2.1. Aide à la décision médicale	13
2.2.2. Système d'aide à la décision médicale.....	14
2.3. Types des systèmes d'aide à la décision médicale.....	14
2.3.1. Systèmes d'assistance documentaire	14
2.3.2. Systèmes de rappels automatiques.....	14
2.3.3. Systèmes consultants	15
2.4. Caractéristiques des systèmes d'aide à la décision médicale.....	15
2.5. Aide à la décision médicale dans les urgences	16
2.6. Planification pour la prise en charge des urgences	18
2.6.1. Planification	18
2.6.2. Limites de la planification	19
2.6.3. Planification des ressources	19
2.7. Conclusion	21
3. L'intelligence artificielle dans le secteur de la santé.....	22
3.1. Objectifs.....	23
3.2. Intelligence artificielle : Apprentissage automatique	23
3.2.1. Apprentissage supervisé.....	24
3.2.2. Apprentissage non supervisé.....	24

3.2.3. Apprentissage semi-supervisé.....	25
3.2.4. Apprentissage par renforcement	25
3.3. Intelligence artificielle pour la santé.....	25
3.4. Fouille de données par apprentissage automatique.....	27
3.4.1. Qu'est-ce que la fouille de données ?	27
3.4.2. Sélection des attributs	28
3.4.2.1. Sélection des attributs : définition.....	28
3.4.2.2. Sélection des attributs : état de l'art.....	29
3.4.3. Techniques de fouille de données	30
3.5. Apprentissage automatique dans le médical	33
3.6. Conclusion	38
4. Prédiction de la durée de séjour des patients dans les urgences guidée par fouille de données.....	40
4.1. Objectifs.....	41
4.2. État de l'art.....	41
4.3. Processus basé sur la fouille de données : Cas d'étude	45
4.3.1. Collection des données	46
4.3.2. Description de la base de données	47
4.3.3. Prétraitement des données.....	47
4.3.4. Modèles de classification.....	48
4.3.5. Évaluation des modèles de classification.....	48
4.4. Résultats et discussions.....	49
4.5. Conclusion	52
5. Prise en charge des urgences pédiatriques : Modèle de prévision par sélection de variables pertinentes.....	53
5.1. Objectifs.....	54
5.2. Description de l'approche proposée.....	54
5.2.1. Collection des données	55
5.2.2. Prétraitement des données.....	56
5.2.3. Analyse descriptive des données	56
5.2.4. Sélection des données	56

5.2.4.1. Qu'est ce que la sélection des attributs ?	56
5.2.4.2. Catégories des méthodes de sélection des attributs	57
5.2.5. Modélisation des données	57
5.3. Expérimentations et discussion des résultats : Application sur un cas réel	58
5.3.1. Description des données	58
5.3.2. Préparation des données.....	59
5.3.3. Analyse statistique des données.....	59
5.3.4. Sélection des attributs basée sur la corrélation	62
5.3.5. Modèles de prédiction.....	63
5.3.6. Évaluation des performances	66
5.4. Conclusion	68
6. Conclusion générale	71
Bibliographie	73

Liste des tableaux

Tableau I.	Planification des ressources dans les urgences	21
Tableau II.	Application de la fouille de données dans les SADM	38
Tableau III.	Algorithmes de fouille de données appliqués aux systèmes de soins de santé ...	45
Tableau IV.	Signification et description des variables exogènes	47
Tableau V.	Évaluation des performances des modèles de prédiction du LOS	50
Tableau VI.	Description des attributs	59
Tableau VII.	Périodes de l'année	60
Tableau VIII.	Périodes journalières	62
Tableau IX.	Description des nouveaux attributs	62
Tableau X.	Descripteurs avant et après la sélection d'attributs	63
Tableau XI.	Précision des modèles de prédiction avec et sans sélection d'attributs	65
Tableau XII.	Évaluation des erreurs de prédiction	67
Tableau XIII.	Évaluation des performances des modèles de prévision sélectionnés	68

Liste des figures

Figure 1.	Types d'apprentissage automatique.....	24
Figure 2.	Le processus ECD.....	27
Figure 3.	Le processus de sélection des attributs	29
Figure 4.	Architecture générale de l'approche proposée	46
Figure 5.	Format de la matrice de confusion.....	49
Figure 6.	Taux maximum	51
Figure 7.	Schéma général de l'approche proposée.....	55
Figure 8.	Nombre d'arrivées des patients par mois.....	60
Figure 9.	Nombre d'arrivées quotidiennes des patients	61
Figure 10.	Nombre d'arrivées des patients par 24h le dimanche	61
Figure 11.	Nombre d'arrivées des patients par heure	62
Figure 12.	Performances des modèles de prédiction basés sur la sélection d'attributs	66

Liste des sigles

AA : Apprentissage automatique

ANN : Artificial neural networks

CART : Classification and regression trees

CCMU : Classification clinique des malades aux urgences

CFS : Correlation-based feature selection

CHU : Centre hospitalier régional

CHRU : Centre hospitalier régional universitaire

DT : Decision tree

ECD : Extraction de connaissances à partir de données

FN : False negative

FP : False positive

GEMSA : Groupes d'étude multicentrique des services d'accueil

GTI : Groupe tactique d'intervention

IA : Intelligence artificielle

KDD: Knowledge discovery in databases

k-NN : k nearest neighbors

K-ppv : K plus proches voisins

LOS : Length of stay

MAE : Mean absolute error

MLP : Multilayer perceptron

NB : Naïve Bayes

PDDL : Planning domain definition language

RAE : Relative absolute error

RF : Random forest

RMSE : Root mean squared error

SADM : Systèmes d'aide à la décision médicale

SAU : Service d'accueil d'urgence

STRIPS : Stanford research institute problem solver

SUP : Service d'urgence pédiatrique

SVM : Support vector machine

TN : True negative

TP : True positive

A la mémoire de ma grand-mère,

A mon époux,

A mes parents,

A ma belle mère,

A mes sœurs et mes frères,

A toute ma famille,

A mes amis.

Remerciements

Tout d'abord, j'adresse ma gratitude et ma profonde reconnaissance à mon directeur de thèse Mr Atmani Baghdad, Professeur à l'Université d'Oran 1, pour m'avoir guidé durant toutes ces années, et plus particulièrement pour sa disponibilité, sa patience et ses encouragements. Je lui présente également mes sincères remerciements pour la confiance qu'il m'a témoignée tout au long de cette thèse et pour la pertinence de ses remarques qui ont grandement contribué à la mise en œuvre de ce travail.

Je tiens à remercier Mr Bouamrane Karim, Professeur à l'Université d'Oran 1, pour m'avoir fait l'honneur de présider le jury. Mes remerciements s'adressent également aux membres du jury Mr El Berrichi Zakaria, Professeur à l'Université de Sidi Bel Abbès, Mr Chikh Mohamed Amine, Professeur à l'Université de Tlemcen, Mr Benslimane Sidi Mohamed, Professeur à l'École Supérieure en Informatique de Sidi Bel Abbès, et Mme Barigou Fatiha, Maître de conférences à l'Université d'Oran 1 qui m'honorent de leur présence et pour avoir accepté d'évaluer ce travail.

J'exprime mes sincères remerciements à l'égard de Mr Khemliche Belarbi, Professeur à la Faculté de médecine d'Oran. Mes remerciements vont aussi aux membres du laboratoire « Recherche en accidentologie pédiatrique » du CHU d'Oran.

Mes sincères remerciements vont également à Mme Chaabane Sondès, Maître de conférences à l'Université Polytechnique Hauts-de-France et membre du laboratoire d'Automatique de Mécanique et d'Informatique Industrielles et Humaines « LAMIH » de l'université de Valenciennes. Je porte aussi ma reconnaissance à Mr Kadri Farid, également membre du laboratoire « LAMIH ».

Je remercie les membres de l'équipe de recherche « Apprentissage Automatique, Intelligence Artificielle et Raisonnement » du laboratoire d'Informatique d'Oran « LIO » de l'université d'Oran 1 ainsi que les membres du laboratoire « LAMIH » pour leur collaboration dans la réalisation de ce travail.

Enfin, je dis un grand merci à tous ceux qui ont contribué de près ou de loin à la réalisation de ce travail de recherche.

Chapitre 1

Contexte et problématique

1.1. Introduction

Dans le service des urgences pédiatriques, les enfants sont souvent confrontés à des détresses vitales. La mission principale d'un service d'urgence est la prise en charge immédiate de ces patients. La prise en charge de ces patients nécessite des ressources humaines et matérielles. Ces ressources doivent être bien planifiées afin d'assurer une prise en charge adéquate des patients. Les professionnels des soins d'urgence doivent trouver des moyens pour planifier efficacement l'utilisation des ressources (Walczak et al., 1998).

Les services des urgences sont confrontés à une panoplie de problèmes. Le flux de patients augment constamment ce qui inclut une demande accrue des soins d'urgence (Sinclair, 2007 ; Trunkey, 2007; Forero & Hillman, 2008). Un surpeuplement peut arriver dans le service des urgences lorsque le besoin identifié pour les soins des patients dépasse les ressources disponibles (Mangai & Harris, 2016). La saturation du service d'urgence entraîne de longues périodes d'attente aux différents niveaux de la prise en charge du patient et une durée de séjour des patients supérieure à celle souhaitée. Ces situations peuvent provoquer la non satisfaction des patients et une dégradation de la qualité des soins dispensés (Bruballa et al., 2016).

Dans les situations d'urgence, il y a une contrainte de temps critique sur l'évacuation des personnes affectées et la distribution des ressources disponibles (Ajmi et al., 2015). D'autres problèmes peuvent survenir tels que l'insuffisance des ressources humaines et matérielles, l'encombrement des structures d'accueil, des périodes d'attente et des durées de séjour prolongées. Ceux-ci justifient l'intérêt de l'étude sur la prise en charge des patients en détresse vitale.

Le travail présenté dans cette thèse de doctorat porte sur la mise en œuvre d'une méthodologie d'aide à la prise en charge des urgences pédiatriques. Nous proposons d'exploiter les techniques d'apprentissage automatique pour prédire la durée de séjour des patients dans les services d'urgence. Notre objectif est de prévenir l'avènement des situations de tension et améliorer la planification des ressources dans les services d'urgence pédiatrique.

Ce travail s'inscrit dans le cadre du projet de recherche (CNEPRU) : « Surveillance Pédiatrique : Système Interactif d'Aide à la Décision basé sur le Datamining et le Web

Sémantique (SIAD/DMWS) » de l'équipe « Apprentissage Automatique, Intelligence Artificielle et Raisonnement » du laboratoire d'Informatique d'Oran de l'Université Oran 1, Ahmed Ben Bella. Ce projet a permis la collaboration du laboratoire de recherche en accidentologie pédiatrique, notamment le Pr Khemliche, de l'équipe « les accidents graves de la circulation : préventions, premiers soins et séquelles ». Ce travail de thèse a également permis de faire collaborer le laboratoire d'Automatique de Mécanique et d'Informatique Industrielles et Humaines (LAMIH) de l'université de Valenciennes et du Hainaut Cambrésis.

Dans ce premier chapitre, nous décrivons le contexte et la problématique, les contributions de la thèse, et nous terminons par la structure du manuscrit.

1.2. Planification réactive

La planification est une approche basée sur un modèle de comportement autonome où un modèle prédictif d'actions est utilisé pour générer un comportement permettant d'atteindre des objectifs donnés. La planification classique fait référence à la forme la plus simple de la planification dans laquelle des objectifs doivent être atteints en appliquant des actions déterministes à une situation initiale parfaitement connue (Geffner, 2014). De ce fait, le paradigme de planification classique ne convient pas aux environnements complexes et dynamiques. Pour remédier aux limites de la planification classique, d'autres techniques de planification ont été développées en intelligence artificielle, telle que la planification réactive. La planification réactive opère dans un environnement non déterministe où des informations nécessaires peuvent être incomplètes ou imprécises (Marinagi et al., 2005).

La planification réactive devient de plus en plus une zone active dans la recherche en intelligence artificielle. Elle se préoccupe des difficultés d'interaction directe avec un monde en mutation. Un système de planification réactive peut être contraint à réagir à des événements imprévus tels que ceux qui peuvent survenir dans des situations d'urgence. Les situations d'urgence se réfèrent à des événements qui parviennent soudainement et pouvant causer d'importants dommages allant de graves blessures jusqu'à la perte humaine. Ces situations peuvent se présenter sous différentes formes, à savoir, les incendies, les tremblements de terre, les accidents de la route, etc.

1.3. Prise en charge des urgences médicales

Morgans & Burgess (2011) ont exploré la définition d'une urgence de santé à travers une étude de la littérature. Ils ont élaboré une nouvelle définition de «l'urgence médicale» qui englobe à la fois les perspectives des professionnels de la santé et celles des patients. Une définition combinée de ces deux perspectives est donnée comme suit:

« Une urgence médicale est une menace soudaine ou inattendue pour la santé physique ou le bien-être qui nécessite une évaluation urgente et un soulagement des symptômes » (Morgans & Burgess, 2011).

La gestion des urgences médicales englobe à la fois les urgences liées directement à la santé, ainsi que d'autres urgences ayant des conséquences sur la santé telles que les catastrophes naturelles (Core Public Health, 2006). L'intérêt pour la prise en charge des urgences a considérablement augmenté au cours de ces dernières années (Bennett & Hardiker, 2017; Pereira et al., 2016; Dey et al., 2007 ; Grunwald & Bearman, 2017).

De nombreux problèmes peuvent survenir dans les services des urgences, ce qui est néfaste pour la prise en charge des patients d'où la détérioration de leur état de santé. Dans ce qui suit, nous citons quelques travaux qui ont abordé des problèmes courants auxquels sont confrontés les services des urgences. Le GTI (Groupe tactique d'intervention) en collaboration avec l'association des médecins d'urgence du Québec, ont présenté un diagnostic des principaux problèmes à l'origine du débordement des urgences ainsi qu'un ensemble de recommandations et de normes pour redresser la situation. Les principaux problèmes à l'origine du débordement des urgences sont la présence accrue de patients ayant des besoins particuliers (les enfants, les personnes âgées, les personnes ayant besoin d'une réadaptation,...), la gestion déficiente des lits hospitaliers et les délais de la prise de décision médicale concernant le patient (GTI, 1998). Les situations médicales des patients affluant aux urgences et leur nombre à certains moments de la journée posent inévitablement le problème de l'orientation, la différenciation dans les prises en charge et l'estimation de l'état de santé réel. Une organisation adéquate permet au patient de bénéficier des soins appropriés à son cas. A cette fin, les services des urgences doivent organiser une prise en charge adaptée à certaines catégories de patients. Des recommandations en ce sens ont fait l'objet de deux circulaires. La première, relative aux personnes âgées, prévoit

l'admission directe des personnes âgées dans un service gériatrique. La seconde, relative à l'accueil des enfants et des adolescents aux urgences prévoit une prise en charge impliquant le service de pédiatrie. Un autre problème pouvant se présenter dans les services des urgences est le manque de lits pour l'admission. Dans un grand nombre d'établissements, les patients en attente de lits pour leur admission (hospitalisation) sont parfois placés plusieurs heures sur des brancards dans les couloirs du service des urgences. Pour remédier à cette situation, l'ensemble des acteurs de l'établissement de santé doit se mobiliser et participer à l'amélioration de l'organisation interne afin de permettre une gestion des flux des urgences (DHOS, 2003). Les services d'accueil des urgences sont confrontés à des flux de patients entrants qui ne cessent de croître. Afin d'éviter la surcharge des urgences, il faut agir sur le temps de passage en essayant de l'améliorer. De ce fait, il est nécessaire de développer et renforcer les partenariats entre les services composant le pôle d'urgence. Les médecins et soignants qui y travaillent doivent pouvoir favoriser les échanges de personnel entre les services en cas de besoin. Ainsi, en cas d'afflux importants de patients, la possibilité de disposer de ressources disponibles permet de gérer rapidement des pics d'affluence afin d'éviter une surcharge source de dysfonctionnement. En outre, le travail au sein des services d'urgence est épuisant en cas de flux incessant de patients. Il apparaît donc nécessaire de mettre en place un système où seuls des médecins urgentistes spécialisés et des soignants correctement formés travaillent au sein du service d'urgence. Par ailleurs, il est nécessaire de développer des dossiers médicaux informatisés afin de permettre un gain de temps appréciable et améliorer la qualité des informations médicales (Etchart & Levraut, 2006). Le taux de la population qui se présente aux services d'urgence hospitalière augmente de plus en plus. Mais le plus souvent, l'état des patients ne correspond pas à une situation critique (urgence vitale ou grave) étant donné que les patients retournent au domicile après une simple consultation ou des examens complémentaires sont demandés. Cela peut créer des insatisfactions non seulement pour le personnel mais aussi pour les patients, à cause de la difficulté qui se présente pour gérer les flux des patients et du temps d'attente jugé parfois excessif. Les pouvoirs publics ont tenté de limiter l'afflux des patients aux services d'urgence hospitalière en organisant une meilleure coordination entre tous ceux qui interviennent en amont de l'hôpital et en renforçant l'efficacité du système d'orientation des patients (Kadri et al., 2014). L'engorgement des services d'urgence due à l'allongement des temps de passage des patients, engendre l'insatisfaction des patients, l'altération des conditions

de travail des professionnels et la dégradation de la qualité des soins. Face à ces constats, l'allocation de ressources supplémentaires (personnels, lits, équipements techniques dédiés) peut être perçue comme une solution. Les professionnels des services des urgences ont démontré qu'il était possible, à l'aide de solutions organisationnelles, d'apporter quelques améliorations à la situation constatée. Certains ont ainsi obtenu des réductions sensibles sur les délais de prise en charge, d'autres ont pu limiter l'impact sur les temps de passage des patients. La majorité a obtenu une réduction sensible du nombre de patients concernés par des temps de passage très longs (MEAH, 2007). Jarrar et al. (2008) ont proposé de faire une étude prospective pour analyser l'activité du service d'accueil d'urgence (SAU) du CHU Farhat Hached et les délais d'attente qui composent le parcours du patient. Le SAU accepte un flux important de malades de gravités différentes mais la gestion du flux des patients se fait sans suivre une méthode de triage. Ce qui peut laisser un patient nécessitant une prise en charge rapide attendre plus qu'un autre en état stable. Ces résultats montrent l'importance du rôle de l'infirmier d'accueil qui pourrait intervenir dans l'orientation du patient et dans sa prise en charge rapide si son état le nécessite. Ainsi, l'étude des délais de prise en charge permet de repérer les causes des durées de séjours prolongées et par conséquent avancer des solutions pour améliorer la prise en charge du patient. Simon et al. (2009) proposent d'utiliser un système de dossiers médicaux électroniques pour identifier les cas moins graves les plus fréquemment présentés aux urgences pédiatriques. L'objectif de cette étude est d'évaluer l'impact de ces patients sur le surpeuplement des urgences pédiatriques. L'identification de ces patients en utilisant le dossier médical électronique permettra à des interventions ciblées de ce sous-groupe d'améliorer l'allocation future des ressources. Veyre (2009) a suggéré des propositions destinées à répondre à l'afflux des urgences pédiatriques en impliquant différents acteurs du système de soins. Les mesures proposées consistent entre autres à restaurer le dialogue afin de permettre un meilleur déroulement des soins. La collaboration des parents à ce stade peut aider les experts à mieux discerner la pathologie donc il faut prendre le temps de les écouter. Par ailleurs, la communication entre les médecins libéraux et les services d'urgence est insuffisante. Un simple échange téléphonique entre le médecin traitant et le service d'urgence pourrait permettre d'établir un bon échange d'informations et de trouver une entente sur la conduite à tenir. De même, la rédaction d'un compte-rendu de consultation facilitée par l'utilisation de l'informatique et remis au médecin dès la sortie des urgences lui permettrait d'assurer la poursuite de la prise en charge.

Les services d'urgences hospitalières sont parfois confrontés à des surcharges. La gestion de la charge fait appel à une gestion des délais de prise en charge dépendante de la disponibilité des moyens et des ressources de prise en charge, mais aussi de la façon de combiner tous ces éléments dans une organisation. Les patients sont de plus en plus nombreux dans les services d'urgences et leur prise en charge a un coût auquel peut succéder un surcoût. La prise en charge des patients se base sur un processus impliquant des moyens (ou ressources) de production destinés à produire des soins. Ce processus résulte du choix de combinaisons et d'organisations des moyens de production. Ces combinaisons sont améliorables grâce à des démarches d'optimisation qui ont des répercussions en termes de coût (Apete, 2011). La surcharge de travail dans les services d'urgences due au nombre important de consultations pour des situations d'urgences implique une impossibilité de répondre immédiatement aux demandes des patients. Pour faire face à ce problème récurrent, un concept de tri a été instauré il y a déjà trente ans dans les pays Anglo-Saxons. Ce concept cherche à répondre à l'identification immédiate et la catégorisation des plaintes du patient, selon les priorités vitales et les pathologies, l'évaluation tolérable du délai de temps d'attente avant une prise en charge médicale et la détermination de l'endroit le mieux adapté à la prise en charge (Elsa, 2011).

La prise en charge des urgences peut être considérée comme un processus d'aide à la décision destiné à améliorer les services de santé. Dans ce contexte, nous nous sommes fixés l'implication des techniques d'apprentissage automatique pour le développement d'une approche d'aide à la prise en charge des urgences et plus particulièrement les urgences du service pédiatrique.

Les patients dans un état critique doivent être pris en charge immédiatement, ce qui nécessite des ressources suffisantes. La planification des ressources est un scénario très important qui doit être pris en compte lors de la prise en charge des patients dans les services d'urgence (Mangai & Harris, 2016). Il est donc essentiel de bien planifier l'allocation des ressources pour améliorer la qualité des soins. La prédiction de la durée de séjour permet d'aider les professionnels des urgences à planifier plus efficacement les ressources.

1.4. Prédiction de la durée de séjour

La littérature sur le sujet de la prédiction de la durée de séjour est très abondante. Celle-ci démontre l'utilité de la prédiction de la durée de séjour des patients pour résoudre l'un des problèmes des urgences à savoir l'allocation des ressources et leur planification ce qui permettrait d'améliorer la prise en charge des patients.

Walczak et al. (2003) ont utilisé une méthode d'apprentissage supervisé pour créer un outil d'aide à la décision qui prédit avec précision la durée de séjour des patients souffrant de différents problèmes d'urgence, à savoir les patients pédiatriques atteints de traumatisme ou de pancréatite aiguë. Des modèles de réseaux de neurones distincts ont été développés et mis en œuvre pour chacun des deux problèmes du domaine médical. La recherche rapportée dans cette étude a montré que les réseaux de neurones sont capables de fournir des informations de planification et de soins aux patients. Une identification plus précoce de la durée de séjour permettrait une meilleure planification des ressources et améliorerait les soins des patients à l'hôpital. Carter & Potts (2014) ont analysé des variables extraites des dossiers électroniques des patients atteints d'une arthroplastie totale du genou pour déterminer les facteurs qui peuvent influencer de manière significative sur la durée de séjour des patients à l'hôpital. Cette étude a fourni un modèle innovant pour la prédiction de la durée de séjour contribuant à améliorer la planification des ressources. Ce modèle a aussi été utilisé comme un outil d'aide à la décision pour prédire l'espérance de vie des patients. Panchami & Radhika (2014) proposent une approche pour prédire si la durée de séjour des patients est supérieure à une semaine. L'estimation de la durée de séjour des patients dans un hôpital est un aspect important pour une planification efficace à différents niveaux. C'est utile pour planifier l'utilisation future des lits, déterminer des spécialistes pour les patients présentant des diagnostics multiples, planifier les dates de sortie des patients, etc. De plus, la prévision de la durée de séjour contribue à une utilisation efficace des ressources et des installations. Morton et al. (2014) ont appliqué des algorithmes d'apprentissage supervisé à des patients diabétiques hospitalisés pour prédire leur durée de séjour à court terme et à long terme. Dans l'ensemble, les résultats indiquent que la méthode SVM est la plus prometteuse pour prédire la durée de séjour chez des patients diabétiques hospitalisés. Il devient de plus en plus important de prévoir la durée de séjour des patients hospitalisés pour la planification des ressources. Awad et al. (2016) passent en revue

les applications de la durée de séjour en médecine aiguë et en soins intensifs. Cette étude se concentre sur les publications de 1984 à 2015 relatives au domaine de la prévision de la durée de séjour. Il est possible qu'une prédiction précise de la durée de séjour aide à améliorer la planification de l'allocation des ressources, en particulier les ressources humaines. Aghajani & Kargari (2016) ont utilisé des algorithmes de fouille de données pour prédire la durée de séjour dans le service de chirurgie générale et identifier les facteurs qui influencent la durée de séjour. Cette étude a déterminé que l'utilisation d'algorithmes de fouille de données peut aider à prédire la durée de séjour des patients à l'hôpital. La prévision de la durée de séjour va permettre aux administrateurs des hôpitaux de gérer et planifier plus efficacement les ressources hospitalières. Stecker et al. (2017) ont essayé d'identifier les facteurs permettant de prédire la sortie et la durée de séjour des patients admis dans un service en neurosciences. C'est une étude descriptive corrélationnelle qui a été réalisée par l'analyse des données et la validation des facteurs statistiquement significatifs pour déterminer la durée de séjour. Cette étude a montré que la prévision de la durée de séjour peut aider à améliorer de façon significative la planification des ressources et la sortie des patients de l'hôpital.

1.5. Contributions de la thèse

Ce travail de recherche comporte la réalisation de deux objectifs principaux.

Le premier objectif consiste à étudier la contribution de l'apprentissage automatique dans le cadre des urgences médicales. Pour ce faire, nous avons effectué une revue de la littérature faisant ressortir les techniques d'apprentissage automatique les plus couramment utilisées dans les services d'urgence hospitalière.

Le deuxième objectif contribue à anticiper l'occurrence des situations de tension dans les urgences pédiatriques. Une situation de tension peut arriver dans le cas d'un surpeuplement où le besoin identifié pour les soins des patients dépasse les ressources disponibles dans le service d'urgence. Une planification adéquate des ressources est donc essentielle pour fournir des soins de santé de haute qualité. Dans ce contexte, notre contribution porte sur la mise en œuvre d'une méthodologie guidée par fouille de données (Benbelkacem et al., 2019). Cette méthodologie porte sur la prédiction de la durée de séjour des patients afin de détecter les situations de tension. Nous étudions, sur un cas réel, la prédiction de la durée de séjour des

patients au niveau du service des urgences pédiatriques du CHU de Lille. La prédiction de la durée de séjour vise à aboutir à une meilleure planification des ressources et par conséquent améliorer la prise en charge des patients dans les urgences pédiatriques.

1.6. Organisation du manuscrit

La thèse est structurée en cinq chapitres décrits comme suit.

Le premier chapitre présente le cadre de cette thèse. Il décrit le contexte et la problématique ainsi que les contributions de la thèse. Ce chapitre présente une étude de la littérature qui aborde les problèmes auxquels sont confrontés les services d'urgence. Une étude de la littérature a également été effectuée sur l'utilisation de la prédiction de la durée de séjour des patients pour résoudre le problème d'allocation des ressources dans les urgences.

Le deuxième chapitre introduit les systèmes d'aide à la décision médicale et la planification. Ce chapitre présente une étude de la littérature sur l'utilisation des systèmes d'aide à la décision dans les situations d'urgence et résume un état de l'art sur la planification des ressources. Cette étude de la littérature souligne l'importance de la prise de décision dans les urgences et l'utilité de la planification réactive pour la prise en charge des patients.

Le troisième chapitre répond à notre premier objectif par la présentation des applications récentes de l'intelligence artificielle dans le secteur de la santé. Ce chapitre souligne l'importance de la fouille de données dans les systèmes d'aide à la décision médicale. Nous montrons à travers un état de l'art l'apport des techniques de fouille de données dans le domaine médical.

Le quatrième chapitre concerne notre contribution. Ce chapitre résume d'abord les applications actuelles des techniques de fouille de données dans les systèmes de santé. Ensuite, une approche basée sur la fouille de données est appliquée à un cas d'étude. L'objectif est d'illustrer comment la fouille de données peut être utile pour prévoir la durée de séjour. Enfin, nous discutons les résultats obtenus et nous soulignons les limites de l'approche proposée pour l'améliorer dans le chapitre suivant.

Le cinquième chapitre concerne également la contribution de la thèse. Nous donnons en premier lieu une description détaillée de la démarche méthodologique suivie pour aboutir aux

objectifs de cette recherche. Nous proposons d'exploiter les techniques d'apprentissage automatique pour mettre en place une méthodologie d'aide à la prise en charge des urgences pédiatriques. Il s'agit de prédire la durée de séjour des patients afin de prévenir l'avènement des situations de tension. Nous appliquons des techniques de sélection d'attributs afin de trouver les descripteurs les plus pertinents pour la prédiction de la durée de séjour. Enfin, nous présentons les résultats des expérimentations effectuées sur une base de données réelle extraite du service des urgences pédiatriques du CHU de Lille.

En conclusion, nous montrons le niveau de satisfaction de notre approche et soulignons les perspectives ouvertes par notre travail de recherche qui permettent d'ouvrir de nouveaux axes de recherche à explorer.

Chapitre 2

Aide à la décision médicale dans les urgences

2.1. Objectifs

Le chapitre 2 présente en premier lieu, les systèmes d'aide à la décision médicale (SADM). Nous commençons par aborder les notions de base des SADM. Puis, nous citons brièvement les différents types et caractéristiques des systèmes d'aide à la décision médicale. Par la suite, nous présentons un état de l'art qui résume des travaux de la littérature qui ont utilisé l'aide à la décision dans les situations d'urgence. En second lieu, nous présentons la notion de planification et nous énumérons quelques limites de la planification classique. Et nous terminons par un état de l'art sur la planification des ressources.

L'objectif de ce chapitre est de souligner l'importance de la prise de décision dans les urgences et de montrer que la planification réactive peut être utilisée pour améliorer la prise en charge des patients.

2.2. Notions de base

2.2.1. Aide à la décision médicale

Nous utilisons la définition proposée par Roy & Bouyssou (1993) pour introduire la notion d'aide à la décision: « l'activité de celui qui, prenant appui sur des modèles clairement explicités mais non nécessairement complètement formalisés, aide à obtenir des éléments de réponses aux questions que se pose un intervenant dans un processus de décision, éléments concourant à éclairer la décision et normalement à prescrire, ou simplement à favoriser, un comportement de nature à accroître la cohérence entre l'évolution du processus d'une part, les objectifs et le système de valeurs au service desquels cet intervenant se trouve placé d'autre part ».

L'aide à la décision ne vise pas à remplacer le décideur en proposant des solutions toutes faites. Au contraire, l'aide à la décision cherche à guider le décideur vers les décisions qu'il devra prendre sous sa responsabilité (Benbelkacem, 2012).

La décision médicale est la composante élémentaire de l'activité de santé. Le médecin a la responsabilité de traiter des informations pour établir un diagnostic, un pronostic, une thérapeutique ou réaliser une intervention (Chabot, 2009). Autrement dit, décider en médecine

consiste à établir un jugement, il s'agit d'appliquer une ou des règles générales à un cas particulier (Delassus, 2011). L'aide à la décision médicale est définie comme l'ensemble des techniques de gestion de l'information qui peuvent fournir une assistance, partielle ou globale, au médecin dans son processus décisionnel (Benbelkacem, 2012).

2.2.2. Système d'aide à la décision médicale

Les systèmes d'aide à la décision médicale sont « des outils informatiques qui visent à fournir aux cliniciens en temps et lieux utiles les informations décrivant la situation clinique d'un patient et les connaissances appropriées à cette situation, correctement filtrées et présentées afin d'améliorer la qualité des soins et la santé des patients » (Lobach et al., 2007).

Les systèmes d'aide à la décision médicale (SADM) sont des outils informatiques qui se basent sur le traitement de l'ensemble des caractéristiques des patients pour fournir aux cliniciens une aide au diagnostic ou à la thérapie. Il existe des systèmes d'aide à la décision médicale pour l'ensemble des activités médicales : la prévention, le dépistage, le diagnostic et le traitement (Seroussi & Bouaud, 2014).

2.3. Types des systèmes d'aide à la décision médicale

Trois grandes catégories de systèmes d'aide à la décision médicale peuvent être distinguées (Degoulet & Fieschi, 1991).

2.3.1. Systèmes d'assistance documentaire

Les systèmes d'assistance documentaire ont pour but de faciliter l'accès aux informations pertinentes en un temps record mais ces systèmes ne disposent pas d'une méthode de raisonnement à proprement parler (Cleret et al., 2001).

2.3.2. Systèmes de rappels automatiques

Les systèmes de rappels automatiques visent à rappeler au médecin des consignes à adopter pour éviter des erreurs qui ne devraient pas être commises ou des éléments importants à prendre en compte pour la décision. Ces systèmes sont plus actifs et participent plus directement à la décision médicale. L'assistance fournie ne constitue pas une aide au

raisonnement proprement dit ou à l'appréhension globale du cas du patient, mais plutôt un aide-mémoire qui permet de fournir des informations utiles et pertinentes dans une situation facile à définir a priori (Degoulet & Fieschi, 1991).

2.3.3. Systèmes consultants

Les systèmes consultants ont pour objectif d'émettre un avis de spécialiste face à une situation médicale bien définie telle qu'un pronostic, un diagnostic ou une thérapie (Degoulet & Fieschi, 1991). Ces systèmes proposent des conclusions argumentées selon les méthodes de raisonnement utilisées.

2.4. Caractéristiques des systèmes d'aide à la décision médicale

Les systèmes d'aide à la décision médicale sont souvent basés sur les caractéristiques suivantes (Musen et al., 2014) :

- **Fonction système**

Cette caractéristique distingue deux types de fonctions. Déterminer qu'est-ce qui est vrai? Il s'agit notamment des systèmes d'aide à la décision médicale purement diagnostiques. Et déterminer que faire? Il s'agit de conseiller quel test prescrire en vue d'un diagnostic différentiel approfondi ou quel médicament prescrire pour l'état actuel du patient. Cependant, cette distinction a une valeur limitée car la plupart des SADM actuels exécutent les deux types de fonctions: déterminer d'abord ce qui est vrai pour un patient, puis suggérer ce qu'il faut faire.

- **Modèle de conseils**

Une autre caractéristique des systèmes d'aide à la décision médicale, c'est qu'ils offrent des conseils. Ces conseils sont de deux catégories : passive ou active. Les SADM passifs obligent l'utilisateur à demander le conseil, alors que l'actif donne des conseils en continu. Cependant, l'une des problématiques de ces systèmes dit actifs est d'éviter la génération d'un nombre excessif d'alertes afin de ne pas embarrasser les utilisateurs.

- **Style de communication**

Le style de communication est une caractéristique couramment utilisée pour classer les systèmes d'aide à la décision médicale. Cette caractéristique permet de distinguer entre un modèle consultant et un modèle critique dit de « feedback ».

- **Interaction homme-machine**

L'interaction homme-machine est une autre caractéristique du système d'aide à la décision médicale. Historiquement, les systèmes d'aide à la décision médicale étaient lents, difficiles d'accès et difficiles à utiliser. Cependant, la puissance informatique moderne, l'intégration des dossiers de santé électroniques et la mobilité des ordinateurs ont contribué à résoudre ces problèmes.

- **Modèle décisionnel sous-jacent**

La dernière caractérisation couramment utilisée des systèmes d'aide à la décision médicale est le modèle décisionnel sous-jacent. Avec l'évolution des modèles statistiques et une puissance de calcul accrue, des modèles beaucoup plus complexes ont été étudiés, tels que, les réseaux de neurones artificiels, les modèles Bayésiens, les SVM, etc. Bon nombre de ces modèles sont utilisés pour donner la priorité au traitement, améliorer la prévision des résultats, ou aider à choisir le meilleur plan d'action.

2.5. Aide à la décision médicale dans les urgences

Dans tous les domaines de la société humaine, des urgences occasionnelles sont presque inévitables. Lorsqu'une urgence se produit, une prise de décision rapide et appropriée est nécessaire (Dai et al., 1994). Les situations d'urgence surviennent de manière imprévisible et amènent les individus et les organisations à changer d'attention immédiatement pour faire face à la situation.

Par définition, « les situations d'urgence sont des situations que nous ne connaissons pas et qui, par leur simple événement, créent des sentiments aigus de stress, d'anxiété et d'incertitude » (Van de Walle & Turoff, 2008).

Lorsqu'on est confronté à des situations d'urgence, il faut non seulement faire face à ces sentiments, mais aussi donner un sens à la situation en traitant avec des informations contradictoires ou manquantes pendant des périodes très intenses avec des délais très courts. En

cas d'urgence, les personnes qui répondent doivent avoir le sentiment de disposer de toutes les observations et informations pertinentes disponibles afin de prendre une décision qui reflète la réalité de la situation donnée (Van de Walle & Turoff, 2008). Les décideurs en situation d'urgence doivent relever le défi de prendre des décisions rapides et à haut risque lors d'une situation d'urgence. Cependant, les décideurs en situation d'urgence utilisent parfois des systèmes d'aide à la décision pour faire face à une crise (Steen et al., 2017).

La prise de décision est particulièrement importante pour les responsables des urgences car ils doivent souvent prendre des décisions rapidement avec des informations inadéquates (Cosgrave, 1996). Les défis auxquels sont confrontés les systèmes d'aide à la décision dans les situations d'urgence sont nombreux. Van de Walle & Turoff (2008) ont présenté les avancées récentes des systèmes d'aide à la décision dans les situations d'urgence. Dai et al. (1994) ont exploré la conception et le développement des systèmes d'assistance informatisés pour la prise de décision d'urgence. Ils ont d'abord examiné les caractéristiques des problèmes de prise de décision d'urgence. Ensuite, ils ont identifié les exigences d'un système de support informatisé pour la prise de décision d'urgence. Enfin, ils ont proposé une structure conceptuelle pour les systèmes d'aide à la décision d'urgence basés sur la connaissance. Taboada et al. (2011) ont mis en place un simulateur utilisé comme un système d'aide à la décision. L'objectif de ce simulateur consiste à aider les responsables des services d'urgence à prendre les meilleures décisions possibles. Steen et al. (2017) ont décrit des travaux visant à concevoir et à mettre en place des systèmes destinés à aider les décideurs en cas d'urgence. La valeur de ce type de système a été démontrée du point de vue technique et utilisateur. D'autres tests sont envisagés pour définir si la gestion des décisions peut être améliorée dans des scénarios d'urgence fondés sur la réalité. Shan & Yan (2017) ont décrit un système d'aide à la décision destiné aux interventions d'urgence. L'objectif de ce système d'aide à la décision est d'assister les décideurs dans l'évaluation des plans d'urgence. Ce système doit également aider les décideurs à choisir un plan d'action en leur fournissant un accès aux connaissances appropriées en matière de secours d'urgence. De plus, des services différenciés sont fournis pour répondre à des besoins particuliers.

Face à une situation d'urgence, une décision doit être prise rapidement. Certains systèmes d'aide à la décision utilisent la planification pour déterminer les mesures à prendre en cas d'urgence.

2.6. Planification pour la prise en charge des urgences

2.6.1. Planification

Le problème de la planification est l'un des problèmes les plus complexes dans le domaine de l'intelligence artificielle. Les situations les plus connues sont la gestion de crise, la gestion de la production, la gestion de projet, la médecine, etc. (Atmani et al., 2013). Dans l'intelligence artificielle, la planification fait référence à un domaine de recherche qui propose de développer des systèmes capables de générer automatiquement, au travers d'une procédure formalisée, un résultat énoncé, sous la forme d'un système intégré de prise de décision appelé plan (Benbelkacem et al., 2013). Un plan sert principalement à guider les actions d'un ou plusieurs agents d'exécution chargés de prendre des décisions adaptées aux situations successives rencontrées afin d'atteindre un objectif prédéfini. Par extension, un plan est le processus qui élabore cet ensemble d'actions. Le planificateur ou générateur de plans désigne le système qui produit le plan (Régner, 2005).

L'émergence de la planification en intelligence artificielle a conduit à ce que l'on appelle les planificateurs classiques (Baki, 2006). La planification classique fait référence à la forme la plus simple de la planification dans laquelle des objectifs doivent être atteints en appliquant des actions déterministes à une situation initiale parfaitement connue (Geffner, 2014). Les problèmes de la planification classique sont généralement modélisés à l'aide de langages de représentation tels que STRIPS (Stanford Research Institute Problem Solver) ou PDDL (Planning Domain Definition Language). STRIPS (Fikes & Nilsson, 1971) utilise des notations dérivées de la logique du premier ordre. La planification classique est souvent associée à STRIPS qui a été l'un des premiers planificateurs en intelligence artificielle.

2.6.2. Limites de la planification

La planification classique est conçue comme un processus formel qui opère à partir de bases toujours identiques définies par la description de l'état initial, la description du but à atteindre et la description des actions qui peuvent être réalisées (Régnier, 2005). Les actions ne peuvent pas s'exécuter en même temps. De plus, des plans préétablis sont exécutés sans être remis en cause car les planificateurs classiques retournent un plan en cas de succès et un échec s'il n'existe pas de solution (Beaudry, 2011).

Dans certains modèles de planification classique, un plan d'action doit être synthétisé dans son intégralité avant de passer à la phase d'exécution. La phase d'exécution nécessite la surveillance du plan, il s'agit de vérifier que les actions donnent les résultats escomptés et que l'environnement n'a pas changé de manière à rendre l'exécution du plan impossible. La re-planification devient nécessaire si l'exécution du plan échoue. Cela implique le rejet de la totalité ou de la majeure partie du plan initial et cause la perte de beaucoup d'efforts de planification antérieure (Downs & Reichgelt, 1991).

Ces problèmes ont pour conséquence que le paradigme de planification classique ne convient pas aux environnements complexes et dynamiques (Benbelkacem, 2012). Plusieurs techniques de planification ont été développées en intelligence artificielle pour tenter de surmonter les limitations de la planification classique. Parmi ces techniques, on trouve la planification adaptative, la planification conditionnelle, la planification temporelle, la planification réactive, etc. La planification réactive opère dans un environnement non déterministe où des informations nécessaires peuvent être incomplètes ou imprécises (Marinagi et al., 2005).

2.6.3. Planification des ressources

Une ressource est une source ou un approvisionnement à partir duquel un bénéfice est produit. En règle générale, les ressources peuvent être du matériel, du personnel, des services, des connaissances, ou tout autre élément nécessaire à la réalisation des activités prévues. Des ressources doivent être affectées à chaque activité. L'allocation des ressources est le processus

d'attribution et de gestion des actifs de manière à soutenir les objectifs stratégiques d'une organisation (Mangai & Harris, 2016).

Dans les services d'urgence, les ressources sont principalement humaines (médecins urgentistes, infirmières de triage, etc.) et matérielles (lits d'urgence, matériel médical, etc.). La prise en charge des patients dans le service d'urgence nécessite des ressources qui doivent être bien planifiées afin d'assurer un traitement adéquat aux patients. Une gestion des urgences rapide et efficace s'appuie sur l'intégration des ressources disponibles (Chen et al., 2019). La planification des ressources est un scénario très important qui doit être pris en compte lors du traitement des patients dans les services d'urgence. Les patients en état critique doivent être traités immédiatement, ce qui nécessite des ressources suffisantes (Mangai & Harris, 2016). Pour ce faire, les professionnels des soins d'urgence doivent trouver des moyens afin de planifier efficacement l'utilisation des ressources (Walczak et al., 1998). Grebennik et al. (2019) ont discuté des problèmes d'allocation des ressources pour la prévention des situations d'urgence. Zeinali et al. (2015) ont proposé un modèle de planification des ressources du service d'urgence. Il s'agit d'un système d'aide à la décision destiné à améliorer le flux des patients et soulager la congestion. Le modèle proposé est utilisé pour minimiser les temps d'attente moyens des patients. Les résultats expérimentaux ont montré que l'allocation des ressources à l'aide du modèle proposé a permis de réduire le temps d'attente des patients dans le service d'urgence. Xiang & Zhuang (2016) ont formulé un modèle d'allocation de ressources médicales pour un réseau de patients en file d'attente dont les conditions de santé se dégradent. L'objectif est de minimiser le taux de mortalité total et le temps d'attente. Cela fournirait de nouveaux outils d'analyse et de modélisation aux organismes de soins de santé pour faire face aux flux de patients. Zhang et al. (2016) ont proposé une approche d'allocation de ressources décentralisée pour gérer les cas d'urgence. L'approche proposée est conçue pour sélectionner efficacement les ressources appropriées et générer simultanément les plans de déploiement de ressources en tenant compte du niveau de gravité d'un événement d'urgence.

Références	Domaine d'application
Zeinali et al. (2015)	Améliorer le flux des patients
Xiang & Zhuang (2016)	Minimiser le taux de mortalité et le temps d'attente

Zhang et al. (2016)	Générer les plans de déploiement de ressources
Grebennik et al. (2019)	Prévenir les situations d'urgence

Tableau I. Planification des ressources dans les urgences

2.7. Conclusion

Dans ce chapitre, nous avons abordé les notions de base d'un système d'aide à la décision médicale. Nous avons cité les différents types des systèmes d'aide à la décision médicale. Ensuite, nous avons défini les caractéristiques sur lesquelles se base un système d'aide à la décision médicale. Une caractéristique particulièrement intéressante des systèmes d'aide à la décision médicale est le modèle décisionnel sous-jacent. Ce modèle peut être utilisé pour améliorer la prévision des résultats ou aider à choisir le meilleur plan d'action. Nous avons introduit la notion de situation d'urgence et nous avons résumé des travaux de la littérature qui ont développé des systèmes d'aide à la décision destinés aux urgences. Un peu plus loin dans ce chapitre, nous avons abordé la planification pour la prise en charge des urgences. Nous avons d'abord présenté la planification classique et ses limites. La planification dite réactive est capable de recourir à certains problèmes de la planification classique. Contrairement à la planification classique qui est insensible aux évolutions de l'environnement, la planification réactive peut réagir en temps voulu aux changements soudains de l'environnement.

La revue de la littérature nous a permis de connaître diverses approches pour traiter la problématique de la prise en charge des urgences. L'intelligence artificielle participe à de grandes avancées technologiques qui se font ressentir dans le secteur de la santé. Nous avons jugé nécessaire d'approfondir nos recherches concernant l'implication de l'intelligence artificielle dans le secteur médical et cela fera l'objet du prochain chapitre.

Chapitre 3

L'intelligence artificielle dans le secteur de la santé

3.1. Objectifs

Le chapitre 3 est consacré aux méthodes d'intelligence artificielle appliquées dans le domaine des soins de santé. Nous commençons par définir l'Intelligence Artificielle (IA). Ensuite, nous présentons une revue de la littérature concernant l'implication des méthodes issues de l'intelligence artificielle et en particulier l'apprentissage automatique dans le secteur médical. Par la suite, nous présentons la fouille de données (datamining) et nous décrivons les techniques de fouille de données les plus utilisées dans le secteur de la santé.

Ce chapitre présente des applications récentes de l'intelligence artificielle visant à améliorer les soins de santé.

3.2. Intelligence artificielle : Apprentissage automatique

L'intelligence artificielle (IA) peut être définie comme étant le développement de systèmes informatiques permettant de résoudre les problèmes liés à l'intelligence humaine (Fogel & Kvedar, 2018). L'intelligence artificielle utilise différentes approches mathématiques et algorithmiques allant de la recherche opérationnelle à la programmation contrainte, et se trouve donc au carrefour de l'inférence statistique, la reconnaissance de formes, l'exploration de données, la découverte de connaissances et l'apprentissage automatique (Miller & Brown, 2018).

En tant que sous-domaine de l'intelligence artificielle, l'apprentissage automatique (AA) repose sur des concepts de statistiques et d'optimisation. La particularité des programmes d'apprentissage automatique se situe en leur capacité à s'ajuster eux-mêmes lorsqu'ils sont exposés à de nouveaux jeux de données, c'est-à-dire à apprendre sans être explicitement programmés. Les programmes d'apprentissage automatique sont généralement conçus pour rechercher des modèles et des associations, découvrir des inefficacités, apprendre et devenir meilleur, exécuter des plans, et prédire les résultats futurs en fonction des tendances historiques (Miller & Brown, 2018).

Il existe plusieurs types d'apprentissage automatique. Quatre formes principales peuvent être distinguées, l'apprentissage supervisé, l'apprentissage non supervisé, l'apprentissage semi-supervisé et l'apprentissage par renforcement (figure 1).




Figure 1. Types d'apprentissage automatique

3.2.1. Apprentissage supervisé

Généralement le but pour un modèle en apprentissage supervisé est de générer une fonction de prédiction $f(x)$ à partir d'un ensemble de données D fourni, qu'on appelle ensemble d'entraînement. D est composé de paires d'exemples (x, y) , où x est un vecteur servant d'entrée au modèle et y un vecteur cible qui représente ce que l'on veut prédire. Notons que les entrées et les cibles sont présentées sous forme de vecteurs, mais pourraient être remplacées par des scalaires. Le fait d'avoir une cible pour chaque exemple, et de s'en servir, est la caractéristique principale de l'apprentissage supervisé. L'apprentissage supervisé permet de prédire la cible pour une entrée donnée par l'utilisateur.

Supposons que la fonction $f(x)$, prenant en entrée le vecteur x de taille J , ait la forme suivante:

$$f(x) = \theta_0 + \theta_1 x_1 + \theta_2 x_2 + \dots + \theta_J x_J \quad (1)$$

Où θ_0 à θ_J sont les paramètres du modèle d'apprentissage.

Le but de ce modèle est donc de trouver les valeurs des paramètres afin d'obtenir les meilleures prédictions possibles, c'est-à-dire le plus proche possible des cibles (Laully, 2016).

3.2.2. Apprentissage non supervisé

Dans l'approche non-supervisée, c'est l'utilisateur qui doit spécifier le problème à résoudre. Contrairement à l'approche supervisée, l'ensemble de données D utilisé en apprentissage non-supervisé n'est pas composé de paires d'exemples (x, y) , mais seulement de x , c'est-à-dire qu'il n'y a plus de cible associée à chaque exemple. Dans un tel cadre, un modèle en apprentissage automatique modélisera l'information fournie en entrée seulement. La fonction

$f(x)$ retournée par un algorithme d'apprentissage n'est pas dictée par la nature des données. En effet, contrairement à l'approche supervisée, il n'y a pas de but explicitement exprimé par le biais de cibles (Laully, 2016).

3.2.3. Apprentissage semi-supervisé

L'apprentissage semi-supervisé utilise un ensemble de deux types de données, étiquetées et non-étiquetées. Il se situe entre l'apprentissage supervisé qui utilise des données étiquetées et l'apprentissage non-supervisé qui utilise des données non-étiquetées. L'étiquetage de données nécessite l'intervention d'un utilisateur humain. La combinaison entre les données étiquetées et les données non-étiquetées permet d'améliorer considérablement la qualité de l'apprentissage (Zhu & Goldberg, 2009).

3.2.4. Apprentissage par renforcement

L'apprentissage par renforcement est un paradigme d'apprentissage qui vise à apprendre à contrôler un système de manière à maximiser une mesure de performance numérique qui exprime un objectif à long terme. L'apprentissage est défini par l'utilisateur à l'aide d'un signal de renforcement. L'apprentissage par renforcement vise à développer des algorithmes d'apprentissage efficaces (Szepesvári, 2010).

3.3. Intelligence artificielle pour la santé

L'intelligence artificielle est utilisée de manière continue dans le cadre médical dans le but d'améliorer la santé des patients. Dans cette section, nous concentrons nos efforts sur les applications récentes de l'intelligence artificielle dans différents secteurs de la santé.

Marshall et al. (2017) ont donné un aperçu de l'impact de l'intelligence artificielle sur la santé et la recherche en sciences de la vie. Feng et al. (2016) ont tenté d'améliorer la méthode de prise de décision d'urgence en se basant sur l'intelligence artificielle. La normalisation de la connaissance du domaine a été introduite dans le système de décision d'urgence. Les informations clés ont été extraites des cas historiques et de la connaissance du domaine. Les éléments de connaissance du modèle d'ontologie peuvent être exploités pour obtenir de nouvelles règles d'association ou des connaissances du domaine afin d'atteindre l'objectif de

maintenance et de mise à jour de l'ontologie. L'article de Zhang (2018) est basé sur la théorie hiérarchique des ensembles approximatifs. Une base de connaissances sur les règles d'urgence est construite en définissant des ensembles de règles de décision extraites de différents niveaux abstraits. Tout d'abord, une analyse est effectuée sur les attributs d'incidents d'urgence. Ensuite, les données d'événements sont transformées sous la forme d'un cube de données multidimensionnel adapté à l'exploration de données. Enfin, des règles de connaissance sont générées à l'aide de la théorie des ensembles approximatifs. Lebedev et al. (2018) ont mené des études sur la détection de pathologies à partir d'images en ayant recours à l'intelligence artificielle. La reconnaissance des cellules pathologiques se divise en deux étapes, la détection des cellules et la classification des cellules. Des résultats préliminaires ont été obtenus sur la détection de certaines formes de leucocytes. Cette analyse préliminaire basée sur l'intelligence artificielle permet de réduire le temps de traitement et de diminuer la charge de travail des médecins. Chen et al. (2018) ont travaillé sur la conception d'un diagnostic d'intelligence artificielle personnalisé et sur le traitement des systèmes de gestion de la santé en simulant le rôle des médecins généralistes. Le but de cette étude est de proposer des interventions adaptées afin d'améliorer les changements de comportement liés à la santé. Les résultats ont conduit à faciliter les relations entre les médecins et leurs patients, et par conséquent améliorer la satisfaction des patients. Grigoryan et al. (2018) ont décrit plusieurs approches qui utilisent l'intelligence artificielle pour simplifier la saisie de texte avec des cartes à base de pictogrammes par entrée prédictive. Un outil pour analyser la sémantique des textes a été utilisé afin de permettre aux utilisateurs de composer des messages plus rapidement et simplifier le processus de communication. Des mesures de qualité ont été effectuées pour détecter automatiquement les messages suspects envoyés par des utilisateurs présentant un handicap. Cette approche permet d'aider les médecins à améliorer leurs capacités de surveillance et le contrôle comportemental et aussi à prendre les mesures appropriées dans le cas où un comportement suspect du patient est détecté par le système. Khaldi et al. (2019) ont combiné les réseaux de neurones artificiels avec une technique de décomposition de signaux afin d'aboutir à une prévision non anticipée du nombre de patients qui arrivent au département des urgences. La série chronologique de la demande a été décomposée en plusieurs sous-signaux modélisés à l'aide d'un modèle de réseaux de neurones artificiels. Les résultats de prévision ont été combinés pour produire la prévision

totale. Le modèle proposé peut être utilisé pour prévoir efficacement les arrivées dans les services des urgences et optimiser les ressources humaines et matérielles des hôpitaux.

3.4. Fouille de données par apprentissage automatique

3.4.1. Qu'est-ce que la fouille de données ?

La fouille de données, dite aussi *Datamining*, consiste à extraire des connaissances à partir de grandes quantités de données (Han et al., 2012). Les techniques de fouille de données permettent de développer des modèles prévisionnels, des règles de classification et d'autres types de connaissances qui seront utilisées pour l'aide à la décision (Hanifi, 2009).

La fouille de données est une étape du processus d'extraction de connaissances à partir de données (ECD) ou *Knowledge Discovery in Databases* (KDD). Fayyad et al. (1996) définissent l'ECD comme un processus non trivial qui identifie de nouveaux modèles valides, compréhensibles et potentiellement utiles, à partir de données. Les étapes du processus d'extraction des connaissances sont résumées dans la figure 2. L'extraction de connaissances à partir de données (ECD ou KDD en anglais) est un processus itératif qui comporte plusieurs étapes (Fayyad et al., 1996).




Figure 2. Le processus ECD (Fayyad et al., 1996)

1) Sélection

La sélection consiste à créer un ensemble de données cible. Il s'agit de sélectionner un ensemble ou un sous-ensemble de variables ou d'échantillons de données.

2) Prétraitement

Le prétraitement et le nettoyage des données incluent la suppression du bruit et le traitement des données manquantes.

3) Transformation

Les méthodes de transformation de données servent à définir des structures optimales de représentation des données.

4) Fouille de données

La fouille de données fait appel à de multiples méthodes issues de la statistique, l'apprentissage automatique, l'intelligence artificielle et la visualisation pour construire des modèles à partir des données préparées.

5) Interprétation et évaluation

Cette étape consiste à évaluer le taux d'erreur des modèles. Il est possible de retourner à l'une des étapes précédentes pour une itération ultérieure.

3.4.2. Sélection des attributs

3.4.2.1. Sélection des attributs : définition

La sélection des attributs est une étape cruciale du processus de fouille de données. Une méthode de sélection d'attributs comporte quatre étapes principales illustrées dans la figure 3 (Dash & Liu, 1997).

- **Génération**

La procédure de génération permet de générer le prochain sous-ensemble candidat. Cette étape peut commencer avec l'ensemble de tous les attributs ou avec un ensemble d'attributs vide ou bien avec un sous-ensemble aléatoire d'attributs. Dans les deux premiers cas, les attributs sont ajoutés ou supprimés de manière itérative. Dans le dernier cas, les attributs sont soit ajoutés, soit supprimés, soit produits aléatoirement par la suite.

- **Évaluation**

Une fonction d'évaluation permet de mesurer la qualité des sous-ensembles produits par la procédure de génération.

- **Critère d'arrêt**

Sans critère d'arrêt approprié, le processus de sélection d'attributs peut s'exécuter de manière exhaustive ou permanente dans l'espace des sous-ensembles. La procédure de génération et la fonction d'évaluation peuvent influencer le choix d'un critère d'arrêt. Le processus de sélection des attributs s'interrompt en générant un sous-ensemble sélectionné d'attributs dans une procédure de validation.

- **Validation**

La procédure de validation ne fait pas partie du processus de sélection des attributs, mais une méthode de sélection d'attributs doit être validée. Cette procédure vérifie la validité du sous-ensemble sélectionné en effectuant plusieurs tests : comparer les résultats avec des résultats préalables ou avec des méthodes de sélection d'attributs concurrentes, utiliser des données réelles, etc.




Figure 3. Le processus de sélection des attributs (Dash & Liu, 1997)

3.4.2.2. Sélection des attributs : état de l'art

L'utilisation des méthodes de sélection d'attributs pour identifier les attributs pertinents a fait l'objet de divers travaux dans la littérature à travers différents domaines, et en particulier dans le domaine médical. De Toledo et al. (2009) ont procédé à la sélection des attributs

pertinents pour créer un modèle de prédiction de l'hémorragie méningée. Des méthodes d'apprentissage automatique ont été utilisées en se basant uniquement sur les données recueillies lors de l'admission à l'hôpital. Delen et al. (2009) ont identifié les facteurs qui peuvent être utilisés pour classer avec précision les personnes avec et sans couverture de soins de santé. Une approche de sélection de variables a été utilisée afin de tirer profit des techniques de fouille de données et permettre aux modèles de classification de capturer davantage d'informations. Dans l'analyse comparative de Sethi & Jain (2010) trois méthodes statistiques de sélection d'attributs ont été utilisées pour extraire un ensemble de caractéristiques pertinentes. L'ensemble de descripteurs sélectionnés a ensuite été soumis aux modèles de classification pour analyser la couverture des soins de santé. Korfiatis et al. (2013) ont proposé une approche hybride pour analyser les traces des patients atteints de la polycythémie. D'abord, une approche de sélection d'attributs de type wrapper a été utilisée pour trouver le meilleur sous ensemble d'attributs. Ensuite, une approche de type filter a été utilisée pour sélectionner de nouveaux attributs permettant d'améliorer la performance du classifieur. Alnuaimi et al. (2015) ont étudié l'effet de la valeur moyenne des tests de laboratoire sur la prévision de la détérioration de l'état de santé des patients dans l'unité de soins intensifs. Les tests de laboratoire sont considérés comme des descripteurs. L'approche proposée utilise une sélection d'attributs pour identifier les tests les plus importants. La réduction du nombre de tests permet d'éviter les tests redondants, et par conséquent, le temps d'observation pourrait être réduit et un traitement précoce pourrait être fourni au patient. Jane & Ganesh (2019) ont proposé une approche qui vise à garantir le traitement des maladies des patients à l'aide d'une technique de classification par sélection d'attributs. Une méthode de sélection d'attributs a été utilisée pour sélectionner des sous-ensembles à partir de grands ensembles de données. Ensuite, l'algorithme naïve Bayes a été utilisé pour classifier les ensembles de données sélectionnés.

3.4.3. Techniques de fouille de données

Dans ce qui suit, nous présentons un bref aperçu de diverses techniques de fouille de données parmi les plus utilisées dans le secteur de la santé.

- **k-plus proches voisins (K-ppv)**

Comme tout classificateur, la méthode des plus proches voisins nécessite des données d'apprentissage avec des étiquettes données, ce qui constitue un exemple d'apprentissage supervisé. K-ppv est une méthode d'apprentissage automatique qui vise à étiqueter des objets en distinguant deux ou plusieurs classes. Dans la variante la plus simple, l'objet hérite de l'étiquette de l'exemple le plus proche parmi les données d'apprentissage. Les variantes courantes étendent la décision du plus proche voisin à l'ensemble des k voisins les plus proches pour tout $k > 1$. La règle de décision combine les libellés de ces k objets de décision soit par vote de majorité simple ou par système de pondération afin de prédire l'étiquette d'un objet donné (Seidl, 2009).

- **Réseaux Bayésiens**

Les classificateurs Bayésiens font partie de la famille probabiliste des classificateurs (Michalski et al., 1986). Ils prédisent la classe d'un échantillon en fonction de la probabilité. Autrement dit, les classificateurs Bayésiens prédisent d'abord la probabilité de l'échantillon lui-même, puis la classe qui a la probabilité la plus élevée compte tenu de l'observation. Un réseau Bayésien est un graphe acyclique dirigé dans lequel chaque nœud représente une variable principale et chaque arc entre les nœuds représente une dépendance probabiliste quantifiée à l'aide d'une distribution de probabilité conditionnelle pour chaque nœud. La structure du réseau Bayésien représente les relations entre les attributs et les données. Les experts humains peuvent facilement comprendre les structures du réseau et les modifier si nécessaire pour obtenir de meilleurs modèles prédictifs (Cheng & Greiner, 2001). Le classifieur Naïve Bayes (NB) est basé sur le théorème de Bayes. Naïve Bayes est un modèle génératif qui calcule ses prédictions en modélisant chaque classe (Basavaraju & Varde, 2016). L'utilisation du classifieur Bayésien a pour inconvénient majeur que les données du monde réel ne satisfont pas toujours l'hypothèse d'indépendance entre les attributs. Cette hypothèse pourrait rendre la précision de la prévision très sensible aux attributs corrélés (Fan & Poh, 2009).

- **Réseaux de neurones artificiels**

Les réseaux de neurones artificiels servent de modèle au réseau de neurones réel existant dans le cerveau humain. Le modèle est influencé par l'observation d'un système cérébral humain constitué de réseaux de neurones interconnectés. Les modèles de réseaux de neurones artificiels comprennent des composants de calcul non linéaires ou des unités de traitement fonctionnant

en parallèle et disposés de manière à ressembler à des réseaux de neurones biologiques. Les nœuds qui forment les composants de calcul sont connectés par des liens dotés de pondérations (Bishop, 1995).

- **SVM**

SVM (Support Vector Machine) est une méthode d'apprentissage supervisé pour la classification (Cortes & Vapnik, 1995). Le but des SVM est de construire des plans de décision ou des hyper-plans qui classent les vecteurs d'apprentissage en deux classes distinctes. Les données d'apprentissage sont constituées d'un ensemble de points qui forment les vecteurs. Les SVM dessinent des hyperplans pouvant séparer deux classes différentes. La meilleure classification est faite en choisissant les hyperplans qui produisent des marges maximales. Les SVM peuvent aider à évaluer les informations et fournissent une bonne généralisation hors échantillon (out-of-sample). Un inconvénient commun des techniques non paramétriques telles que les SVM est le manque de transparence des résultats (Auria & Moro, 2008).

- **Arbres de décision**

L'arbre de décision est l'une des méthodes les plus largement utilisées pour l'inférence inductive (Quinlan, 1986). Cette méthode non paramétrique peut être utilisée à la fois pour la classification et la régression. Les arbres de classification et de régression sont des arbres de décision qui apprennent à fractionner séquentiellement l'espace d'entrée via des limites de décision pour chaque variable (Basavaraju & Varde, 2016). Des algorithmes d'apprentissage supervisé peuvent être utilisés pour construire des arbres de décision ou des ensembles de règles. En d'autres termes, ces techniques créent une série de règles de décision qui peuvent être utilisées pour séparer des données en groupes spécifiques prédéterminés (McCue, 2015). L'arbre de décision classe les instances en les triant dans l'arborescence de la racine à un nœud feuille. Ce dernier fournit la classification de l'instance. Id3 et C4.5 sont les plus connus parmi ces algorithmes de construction d'arbres de décision. L'un des principaux avantages des arbres de décision est la facilité d'interprétation des modèles de classification et ils sont facilement convertis en un ensemble de règles de production. Malgré leurs nombreux avantages, les arbres de décision ont pour limite de devenir moins efficace lorsque le nombre d'échantillons est trop faible et que les attributs de sortie multiples ne sont pas autorisés (Zhao & Zhang, 2008).

3.5. Apprentissage automatique dans le médical

L'apprentissage automatique (AA) est une forme d'intelligence artificielle pouvant être utilisée pour automatiser la prise de décision et établir des prédictions à partir des données des patients. Ces dernières années, l'application des méthodes d'apprentissage automatique et d'exploration des connaissances s'est répandue dans la vie quotidienne (Koppad & Kumar, 2018). Magoulas & Prentza (2001) ont résumé quelques applications de l'apprentissage automatique en médecine. L'apprentissage automatique fournit des techniques et des outils permettant de résoudre des problèmes de diagnostic et de pronostic dans différents secteurs médicaux. L'apprentissage automatique est utilisé pour analyser l'importance des paramètres cliniques et leurs combinaisons pour le pronostic, par exemple, la prévision de la progression de la maladie, l'extraction des connaissances médicales pour la recherche sur les résultats, la gestion globale du patient et la planification du traitement. L'apprentissage automatique est également utilisé pour l'analyse des données, telle que l'interprétation des données continues utilisées dans l'unité de soins intensifs. Les techniques d'apprentissage automatique offrent des possibilités de faciliter le travail des experts médicaux et permettent d'améliorer l'efficacité et la qualité des soins médicaux. Karmani et al. (2019) ont présenté un l'état de l'art sur l'utilisation des techniques d'apprentissage automatique spécifiquement pour le diagnostic de la tuberculose. Les techniques d'apprentissage automatique appliquées à la santé ont été classées en quatre catégories : les types d'apprentissage automatique, les approches, les paradigmes d'apprentissage et les algorithmes pour l'informatique de santé. Les défis de la recherche ainsi que les forces et faiblesses des techniques d'apprentissage automatique ont été soulignés afin d'aider la communauté de la recherche en santé à choisir la technique appropriée à appliquer dans le domaine de la santé.

Avec les progrès rapides des méthodologies de l'apprentissage automatique au cours de la dernière décennie (Goh & Singh, 2015), la fouille de données est devenue une étude populaire dans plusieurs secteurs et spécifiquement dans le domaine des soins de santé. De nos jours, l'industrie des soins de santé recueille une énorme quantité de données. Ces grandes quantités de données constituent une ressource clé pour la fouille de données. Les tâches de la fouille de données sont liées au processus d'apprentissage automatique, telles que le prétraitement, la classification, la régression, le clustering, les règles d'association et la visualisation des données

(Witten et al., 2011). Les techniques de fouille de données peuvent être appliquées sur les données médicales pour extraire des connaissances utiles pour la prise de décision des professionnels de la santé. Les techniques de fouille de données ont été largement utilisées dans la conception des systèmes d'aide à la décision clinique pour la prédiction et le diagnostic de diverses maladies. Nous citons des travaux de la littérature qui ont utilisé les techniques de fouille de données dans le cadre médical.

Robnik-Sikonja et al. (2001) ont étudié la possibilité de prédire le taux de cicatrisation des plaies chroniques en début de traitement. Les arbres de régression et de classification ont été utilisés pour créer des modèles de prévision du taux de guérison des plaies. Les résultats obtenus sont encourageants et un classement des facteurs pronostiques compréhensible a été obtenu pour les experts du domaine. Les informations fournies peuvent aider à formuler des décisions de traitement appropriées. Siernala (2001) a présenté une nouvelle méthode d'apprentissage automatique en lien avec la méthode du plus proche voisin et appartenant à la famille des méthodes basées sur des instances. L'objectif est de prédire avec précision tous les types de structures secondaires des protéines. La méthode proposée a permis de trouver des séquences qui présentent une homologie suffisamment élevée. Mayer et al. (2005) ont implémenté un système d'aide à la décision destiné à aider les médecins à prévoir le stade de la fibrose du foie. Des modèles de classification ont été construits en utilisant les réseaux de neurones et les k plus proches voisins (K-ppv). Ce système d'aide à la décision pourrait aider les médecins à améliorer les processus de diagnostic. Rupnik & Kukar (2007) ont présenté un système d'aide à la décision basé sur la fouille de données, conçu pour des utilisateurs professionnels. Des règles d'association ont été intégrées dans le processus de décision afin de créer des modèles de fouille de données. Les modèles de fouille de données ont été créés par des experts en fouille de données et exploités par des utilisateurs professionnels. Les modèles de règles d'association ont permis de faciliter l'aide à la décision pour des utilisateurs ayant un niveau de connaissance de base. Reiz & Csató (2009) ont utilisé les réseaux Bayésiens pour prédire les chances de survie des patients ayant subi une chirurgie. Kiezun et al. (2009) ont utilisé la régression logistique pour aider les médecins dans le diagnostic de l'infarctus du myocarde (crise cardiaque) chez des patients présentant une douleur thoracique aux urgences. Sung & Seong (2010) ont mis en place un système de classification permettant de poser un

diagnostic complexe en utilisant les techniques de fouille de données. Des règles d'association ont été appliquées sur des données d'urgence recueillies à partir d'un hôpital. Cette méthodologie devrait aider les médecins du service des urgences à effectuer une classification plus rapide et plus précise des maladies avec douleurs thoraciques. Adnan et al. (2012) ont utilisé des techniques de fouille de données parmi les plus utilisées pour prédire l'obésité chez les enfants. La prédiction vise à identifier les enfants obèses et en surpoids en utilisant les données enregistrées à la naissance. Les techniques de fouille de données qui ont été utilisées dans cette étude comprennent les réseaux de neurones, les arbres de décision, les classificateurs Bayésiens et les SVM. L'objectif de cette étude est de montrer l'importance de la fouille de données dans les systèmes médicaux. Aleksovska-Stojkovska & Loskovska (2013) ont construit un système d'aide à la décision médicale pour gérer l'asthme chez les enfants d'âge scolaire. Des méthodes de fouille de données ont été utilisées pour extraire des règles spécifiques aux patients asthmatiques qui serviront à soutenir le processus de décision clinique. Diwani & Sam (2013) ont utilisé la fouille de données pour prédire les conditions médicales futures des maladies mortelles survenant en Tanzanie. Le cadre proposé vise à fournir des traitements d'auto-soins où plusieurs équipements de surveillance permettent d'aider les patients à gérer leurs conditions médicales. L'approche proposée peut grandement bénéficier au secteur des soins de santé en réduisant les coûts médicaux et le temps d'attente pour un traitement médical, et en améliorant la qualité des soins. Çela & Frasheri (2013) ont présenté une vue d'ensemble des recherches récentes qui ont utilisé les techniques de fouille de données pour le diagnostic, le pronostic et le traitement de diverses maladies. L'objectif principal de cette étude est d'identifier les domaines d'application les plus importants et les plus tendances de la recherche dans le domaine de la santé, en soulignant les problèmes critiques. La plupart des recherches ont été effectuées en étudiant des algorithmes de fouille de données tels que les arbres de décision, les réseaux Bayésiens, les SVM, les règles d'association, les réseaux de neurones, la régression logistique et les algorithmes génétiques. Chhikara & Sharma (2014) ont analysé les techniques de fouille de données nécessaires pour l'exploration de données médicales, en particulier pour détecter les maladies fréquentes. Ces techniques ont été résumées en fonction du problème qu'elles résolvent ou de leur utilité dans l'exploration de données médicales. La fouille de données a montré une amélioration significative dans l'industrie médicale en termes de prédiction et de prise de décision concernant diverses maladies telles que les anomalies cardiovasculaires, le cancer, le

diabète, etc. Dhorajiwala & Shaikh (2015) ont tenté d'alléger la charge de travail des médecins en identifiant un diagnostic médical à partir de la collecte de données concernant différents types de maladies telles que les maladies cardiaques et le diabète. Des systèmes d'aide à la décision médicale ont été développés en utilisant différents algorithmes de fouille de données. Les arbres de décision (ID3, CART), les algorithmes génétiques et les SVM ont été utilisés pour classifier les maladies afin de comparer leur utilité et leur efficacité. Les résultats rendent l'application clinique plus praticable, ce qui permettra une bonne prise en charge de la guérison des maladies. Arora & Jaglan (2015) ont décrit les algorithmes de fouille de données les plus couramment mis en œuvre dans les systèmes d'aide à la décision médicale. L'objectif consiste à identifier des algorithmes de fouille de données performants et utilisés dans les bases de données médicales. Les arbres de décision, les réseaux de neurones et les réseaux Bayésiens ont été utilisés pour le diagnostic et le pronostic de diverses maladies. Les résultats ont montré qu'un algorithme unique de fouille de données ne peut pas être défini comme étant le plus approprié pour le diagnostic ou le pronostic des maladies. Parfois, certains algorithmes s'exécutent mieux que d'autres, mais il existe des cas où un regroupement des meilleures propriétés de certains algorithmes s'avère plus utile. Ozaydine et al. (2016) ont cité les techniques de fouille de données qui sont généralement utilisées pour développer des systèmes d'aide à la décision médicale. Ces techniques incluent les arbres de décision, les réseaux de neurones, la régression logistique, les plus proches voisins, les algorithmes génétiques et l'analyse de données massives «Big Data». Baitharu & Pani (2016) ont développé des systèmes d'aide à la décision médicale en utilisant les méthodes de fouille de données sur des données recueillies sur les troubles hépatiques. Une analyse comparative a été menée pour déterminer l'impact des troubles hépatiques sur la performance prédictive des différents classificateurs (arbres de décision, k plus proches voisins, Naïve Bayes, ...). Shitole & Wakchaure (2016) ont décrit les algorithmes de fouille de données les plus couramment utilisés dans les systèmes d'aide à la décision médicale. Les techniques de fouille de données s'avèrent très efficaces dans le développement des systèmes d'aide à la décision médicale car elles permettent de découvrir des modèles et des informations utiles à partir des données médicales. Le choix de la méthode de fouille de données pour l'aide à la décision médicale dépend du domaine d'application. Koppad & Kumar (2018) ont mené des expérimentations pour prédire la présence et la gravité des maladies pulmonaires obstructives chroniques à l'aide des techniques d'extraction des connaissances et

d'apprentissage automatique. Une régression logistique et multinomiale a été mise en œuvre pour prédire la prévalence de la maladie.

Le tableau II présente un résumé des techniques de fouille de données parmi les plus utilisées dans le domaine de la santé et leur utilité pour l'aide à la décision médicale.

Références	Techniques de fouille de données	Utilisation
Robnik-Sikonja et al. (2001)	Arbres de régression et de classification	Prévision du taux de guérison des plaies
Siermala (2001)	Méthode basée sur les plus proches voisins	Prédiction des types de structures secondaires des protéines
Mayer et al. (2005)	Réseaux de neurones, k plus proches voisins	Prévision du stade de la fibrose du foie
Rupnik & Kukar (2007)	Règles d'association	Faciliter l'aide à la décision
Reiz & Csató (2009)	Réseaux Bayésiens	Prédiction de la chance de survie des patients après une chirurgie
Kiezun et al. (2009)	Régression logistique	Aide au diagnostic d'une crise cardiaque
Sung & Seong (2010)	Règles d'association	Classification des maladies avec douleurs thoraciques
Adnan et al. (2012)	Réseaux de neurones, arbres de décision, classificateurs Bayésiens, SVM	Prédiction de l'obésité chez les enfants
Aleksovska-Stojkovska & Loskovska (2013)	Règles d'association	Gestion de l'asthme chez les enfants d'âge scolaire
Çela & Frasheri (2013)	Arbres de décision, régression logistique, règles d'association, réseaux Bayésiens, réseaux de neurones, algorithmes génétiques, SVM	Diagnostic, pronostic et traitement de diverses maladies
Chhikara & Sharma (2014)	Algorithmes génétiques, arbres de décision, règles d'association, réseaux Bayésiens, SVM, K-ppv	Détection des maladies fréquentes (cardiovasculaires, cancer, diabète)
Dhorajiwala & Shaikh (2015)	Arbres de décision, algorithmes génétiques, SVM	Identification d'un diagnostic médical

Arora & Jaglan (2015)	Arbres de décision, réseaux de neurones, réseaux Bayésiens	Diagnostic et pronostic de diverses maladies
Baitharu & Pani (2016)	Arbres de décision, k plus proches voisins, Naïve Bayes	Classification des maladies avec troubles hépatiques
Ozaydine et al. (2016)	Arbres de décision, plus proches voisins, algorithmes génétiques, réseaux de neurones, régression logistique	Développement de systèmes d'aide à la décision médicale
Shitole & Wakchaure (2016)	Arbres de décision, algorithmes génétiques, Naïve Bayes, k plus proches voisins, réseaux de neurones, SVM	Développement de systèmes d'aide à la décision médicale
Koppad & Kumar (2018)	Régression logistique	Prédiction des maladies pulmonaires chroniques

Tableau II. Application de la fouille de données dans les SADM

La fouille de données a été largement utilisée dans le secteur médical. Les techniques de fouille de données se sont révélées très efficaces dans le développement des systèmes d'aide à la décision médicale, étant donné qu'elles permettent d'améliorer les soins et la prise en charge des patients.

3.6. Conclusion

Dans ce chapitre, nous avons présenté un aperçu sur les travaux récents qui ont utilisé les méthodes d'intelligence artificielle dans le cadre des soins de santé. L'intelligence artificielle est susceptible d'améliorer les soins de santé grâce à de nouvelles stratégies de prestation de soins, la participation des patients et une prise de décision éclairée. L'apprentissage automatique est une forme d'intelligence artificielle pouvant être utilisé pour automatiser la prise de décision médicale. Différentes techniques d'apprentissage supervisé ont été utilisées pour éviter les risques de diagnostics erronés et pour la prévision des résultats dans de nombreux scénarios cliniques. En outre, l'apprentissage supervisé permet de fournir plus d'informations pour la prise de décision médicale. Par conséquent, l'apprentissage automatique supervisé permet d'améliorer le bien-être des patients et la qualité des soins de santé.

Nous avons résumé des travaux de la littérature ayant exploité la fouille de données dans le cadre des soins de santé. La fouille de données est une méthodologie émergente dans le

secteur médical. En raison des données massives et du développement constant dans ce secteur, il est devenu nécessaire d'utiliser des techniques de fouille de données pour aider les systèmes de prise de décision et de prévision dans le domaine des soins de santé (Chhikara & Sharma, 2014). Diverses techniques de fouille de données ont été utilisées pour développer des systèmes d'aide à la décision médicale, notamment les arbres de décision, les réseaux Bayésiens, les règles d'association, les SVM, les réseaux de neurones, les algorithmes génétiques. La fouille de données peut grandement profiter au secteur des soins de santé en fournissant une aide à la décision médicale permettant aux professionnels de la santé d'améliorer la prise en charge des patients et la qualité des soins apportés aux patients.

Dans le chapitre suivant, nous allons présenter une approche guidée par fouille de données dans le cadre des urgences médicales et nous discuterons les résultats des expérimentations qui ont été menées sur des données réelles.

Chapitre 4

Prédiction de la durée de séjour des patients dans les urgences guidée par fouille de données

4.1. Objectifs

Dans ce chapitre, nous proposons un modèle de prédiction de la durée de séjour des patients dans les urgences à l'aide des techniques de fouille de données. L'objectif est d'illustrer, à l'aide d'une étude de cas concrète, comment la fouille de données peut être utile pour prévoir la durée de séjour. La prédiction de la durée de séjour a pour objectif d'améliorer la planification des ressources et anticiper l'occurrence des situations de tension dans les services d'urgence.

4.2. État de l'art

Les applications les plus courantes et les plus importantes de la fouille de données font appel à la modélisation prédictive. La prédiction peut être vue comme l'utilisation d'un modèle pour évaluer la valeur d'un attribut qu'un échantillon donné est susceptible d'avoir. Un modèle prédictif est construit à l'aide de la fouille de données qui extrait des informations utiles à partir d'un gros volume de données et aide à prendre une décision permettant d'améliorer la qualité des soins de santé. L'étude de la littérature est centrée sur les approches de classification supervisées. Les méthodes supervisées déterminent la valeur de la classe cible en fonction des attributs. Koh & Tan (2005) présentent la fouille de données comme une méthodologie et une technologie qui ne sont apparues que depuis 1994 (Trybula, 1997). Elle vise à identifier des corrélations et des modèles de données valides, nouveaux, potentiellement utiles et compréhensibles en combinant des ensembles de données volumineux. Les auteurs ont exploré les applications de la fouille de données dans divers domaines du secteur de la santé : l'évaluation de l'efficacité du traitement, la gestion de la santé, la gestion de la relation client et la détection de la fraude. Milovic (2012) a mentionné les applications de la fouille de données pour divers domaines de la santé, tels que les médecins qui utilisent des modèles en mesurant les indicateurs cliniques, les indicateurs de qualité, la satisfaction de la clientèle et les indicateurs économiques, la performance des médecins sous de multiples perspectives pour optimiser l'utilisation des ressources, la rentabilité et la prise de décision basée sur des preuves, l'identification des patients à haut risque et l'intervention de manière proactive, l'optimisation des soins de santé, etc.

Plus récemment, Esfandiari et al. (2014) ont présenté une étude de synthèse comprenant des articles publiés entre 1999 et 2013 dans le contexte des applications d'extraction de données médicales. Cinq approches de fouille de données ont été envisagées: la classification, la régression, le clustering, l'association et l'hybride. Selon une étude de la littérature (Esfandiari et al., 2014), les algorithmes de classification supervisée les plus populaires dans la fouille de données médicales sont les suivants:

- Les arbres de décision (DT).
- Le modèle de réseaux de neurones artificiels (ANN) de type perceptron multicouche.
- Les SVM (Support Vector Machine).
- Les Naïve Bayes (NB).

Walczak & Scharf (2000) ont utilisé un réseau de neurones artificiels pour prédire la quantité d'unités de transfusion nécessaires aux patients chirurgicaux pour une opération spécifique. Les résultats ont montré que les réseaux de neurones artificiels sont capables de réduire la quantité totale d'unités de sang commandées pour des opérations. Ainsi, les réseaux de neurones artificiels offrent un moyen de réduire les coûts des patients tout en maintenant un niveau élevé de soins aux patients. Chae et al. (2003) ont utilisé un arbre de décision pour analyser les indicateurs de qualité des soins de santé afin d'élaborer des stratégies d'amélioration de la qualité. Les auteurs ont identifié les facteurs importants influant sur la mortalité des patients hospitalisés: la durée de séjour, les catégories des maladies, les groupes d'âge. Les résultats ont fourni des statistiques cumulatives qui montrent comment les auteurs ont identifié les indicateurs de mortalité chez les patients hospitalisés. Kraft et al. (2003) sont les premiers à utiliser le diagnostic infirmier et les réseaux de neurones pour prédire la durée de séjour des patients souffrant de lésions de la moelle épinière. Différents types de réseaux de neurones ont été développés pour construire des modèles prédictifs de la durée de séjour: réseau dynamique, perceptron multicouche, réseau à fonction de base radiale. Les résultats ont montré que le modèle de réseau à fonction de base radiale a été sélectionné comme meilleur modèle de réseaux de neurones. Pour illustrer une application de fouille de données dans le secteur de la santé, Koh & Tan (2005) ont utilisé l'arbre de décision pour déterminer le lien entre certaines variables et l'apparition du diabète. Le but de cette application de fouille de données sur les soins de santé

est d'identifier les personnes à haut risque. Les résultats ont montré que l'âge est le facteur le plus important associé à l'apparition du diabète. Liu et al. (2006) ont appliqué les arbres de décision et les naïve Bayes sur une base de données extraite d'un d'hôpital gériatrique afin de prédire la durée de séjour des patients hospitalisés. Les résultats ont montré que le modèle naïve Bayes a eu de meilleures performances comparé à l'algorithme d'arbre de décision C4.5. Ainsi, l'application du modèle naïve Bayes pour traiter une quantité considérable de données manquantes peut considérablement augmenter la précision de la classification en terme de prévision de la durée de séjour. Combes et al. (2008) ont proposé un outil d'aide à la décision permettant d'estimer la durée appropriée d'un patient en salle d'opération. Deux techniques de fouille de données ont été utilisées pour prédire la durée des opérations chirurgicales : des ensembles approximatifs et des réseaux de neurones. La théorie des ensembles approximatifs a été utilisée pour générer des réductions dans la table de données. Les règles générées ont été utilisées pour classer les nouveaux sujets pour lesquels la valeur de décision n'est pas connue. Ensuite, la durée réelle de la chirurgie a été comparée à la durée prédite par les réseaux de neurones. L'objectif est d'identifier les classes de chirurgie susceptibles de prendre différentes durées en fonction du profil du patient. Les résultats obtenus ont montré que le choix du groupe de variables pourrait avoir un impact sur la qualité de la prédiction. De Toledo et al. (2009) ont utilisé des techniques d'arbres de décision pour prédire les résultats de l'hémorragie méningée. Les connaissances découvertes à partir des données deviennent explicites et transmissibles aux experts du domaine. C4.5 a obtenu les meilleurs résultats comparé aux autres algorithmes. Delen et al. (2009) ont développé un modèle de classification en utilisant les réseaux de neurones artificiels et les arbres de décision. Le modèle développé a été utilisé pour prédire si un individu bénéficie d'une couverture maladie ou non, en fonction des informations spécifiques concernant les caractéristiques sociodémographiques et le mode de vie, ainsi que de l'importance des divers facteurs dans le modèle de classification. Les résultats ont indiqué que le classificateur le plus précis pour ce phénomène était le modèle de réseaux de neurones artificiels à perceptron multicouche (MLP). Aljumah et al. (2013) ont utilisé des techniques de fouille de données pour découvrir des modèles qui identifient le meilleur mode de traitement du diabète pour différents groupes d'âge. Les prédictions sur l'efficacité de différentes méthodes de traitement ont été élucidées à l'aide de l'algorithme SVM. Les résultats ont indiqué que le traitement diététique est plus efficace chez les patients les plus âgés. Houthoof et al. (2015) ont développé des modèles

de prédiction de la durée de séjour des patients aux soins intensifs. Le modèle basé sur les SVM s'est avéré plus performant pour prédire la mortalité des patients et la durée de séjour prolongée. Les modèles de prédiction permettent d'appuyer les décisions prises par les médecins dans un contexte de soins intensifs. Alturki et al. (2019) ont étudié les facteurs prédictifs de réadmission en utilisant des algorithmes d'apprentissage automatique. Les SVM se distinguent comme un algorithme efficace pour prédire la durée du séjour. L'analyse des caractéristiques peut être utilisée pour déterminer la prestation d'interventions précoces exigeantes en ressources et identifier les patients à risque.

Cette étude de la littérature montre que la fouille de données a été largement appliquée dans le secteur hospitalier, en particulier pour la tâche de prévision, et permet de fournir des informations utiles pour améliorer l'efficacité des établissements hospitaliers. Le tableau III résume les travaux de la littérature regroupés par méthode de fouille de données.

Méthodes	Références	Domaine d'application
DT	Chae et al. (2003)	Identifier les facteurs influençant la mortalité des patients hospitalisés
	Koh & Tan (2005)	Trouver des variables associées à l'apparition du diabète pour identifier les personnes à haut risque
	De Toledo et al. (2009)	Construire un modèle de prévision des résultats de l'hémorragie sous-arachnoïdienne
ANN	Walczak & Scharf (2000)	Prédire la quantité d'unités de transfusion requises par les patients opérés
	Kraft et al. (2003)	Prédire la durée de séjour des patients souffrant de lésions de la moelle épinière
	Walsh et al. (2004)	Prédire la durée de séjour des enfants atteints de bronchiolite aux urgences
	Combes et al. (2008)	Prédire la durée des opérations chirurgicales
DT, ANN	Delen et al. (2009)	Prédire si une personne a une couverture de soins de santé
SVM	Aljumah et al. (2013)	Prédire l'efficacité des traitements du diabète
	Houthoofd et al. (2015)	Prédire la durée de séjour des patients aux soins intensifs
	Alturki et al. (2019)	Prédire la réadmission et identifier les patients à risque

NB	Liu et al. (2006)	Prédire la durée de séjour des patients gériatriques
----	-------------------	--

Tableau III. Algorithmes de fouille de données appliqués aux systèmes de soins de santé

4.3. Processus basé sur la fouille de données : Cas d'étude

Le Centre Hospitalier Régional de Lille (CHR-Lille) se situe au Nord-Pas-de-Calais, une région caractérisée par l'une des plus fortes densités de population en France. Le service d'urgence pédiatrique (SUP) du CHRU est ouvert 24 heures sur 24 et accueille en moyenne 23900 patients par an. Outre ses capacités internes, le service d'urgence pédiatrique partage de nombreuses ressources avec d'autres services hospitaliers telles que l'enregistrement administratif des patients, le laboratoire clinique, le scanner, et d'autres services hospitaliers (Harrou et al., 2015; Kadri et al., 2013).

Notre approche guidée par la fouille de données (Benbelkacem et al., 2014) est présentée dans la figure 4. L'objectif est de prédire la durée de séjour des patients dans le service des urgences pédiatriques.




Figure 4. Architecture générale de l'approche proposée

4.3.1. Collection des données

La première étape de l'approche proposée est la collecte et la préparation des données. Cette étape est composée de plusieurs sous-étapes: (1) les sources de données sont localisées, consultées et sélectionnées. (2) Les données sélectionnées sont placées dans un format tabulaire dans lequel les occurrences et les variables sont placées respectivement en lignes et colonnes (Giudici, 2005).

Notre cas d'étude a été réalisé à l'aide d'un ensemble de données extraites de la base de données du SUP du CHR-Lille. Comme l'objectif est de prédire le niveau de service du patient en situation de tension, une période hivernale allant de janvier à mars 2012, comprenant 6135 enregistrements, est sélectionnée.

4.3.2. Description de la base de données

Considérons un problème de classification pour prédire la durée de séjour des patients au niveau du SUP où $\Omega = \{\omega_1, \omega_2, \dots, \omega_n\}$ est un échantillon d'apprentissage. Ce problème peut être décrit par plusieurs variables exogènes, également appelées variables descriptives (Atmani & Beldjilali, 2007). Nous nous sommes concentrés sur les descripteurs les plus pertinents $X_1, \dots, X_{12}$ résumés dans le tableau IV.

Variables exogènes	Description
X_1	Temps d'arrivée au SUP
X_2	Moyen d'arrivée
X_3	Orientation des patients à la fin de la prise en charge aux urgences
X_4	Age du patient
X_5	Sexe du patient
X_6	Classification clinique des malades aux urgences (CCMU)
X_7	Echographie
X_8	Scanner
X_9	Radiographie
X_{10}	Examen biologique
X_{11}	Diagnostic principal
X_{12}	Groupe d'étude multicentrique du service d'urgence (GEMSA)

Tableau IV. Signification et description des variables exogènes

Chaque individu ω_i est associé à une classe C qui correspond à la durée de séjour (LOS). Nous avons discrétisé la durée de séjour en utilisant l'outil WEKA. L'ensemble de classes obtenu $C = \{c_1, c_2, c_3\}$ est défini comme suit:

- La classe $c_1 < 289$ *minutes* représente une courte durée de séjour;
- La classe $c_2 \in [289, 432]$ représente une durée de séjour moyenne;
- La classe $c_3 > 432$ *minutes* représente une longue durée de séjour.

La dernière classe est la plus intéressante pour la prédiction, en particulier pour détecter des situations de tension dans le service d'urgence pédiatrique.

4.3.3. Prétraitement des données

L'échantillon d'apprentissage est séparé en deux sous-ensembles:

- Echantillon d'apprentissage: permet de créer un modèle de prévision en appliquant une méthode de fouille de données.
- Echantillon test: est utilisé pour évaluer le modèle résultant et pour vérifier l'exactitude des prévisions.

Les données du monde réel peuvent être incomplètes, bruyantes et inconsistantes, ce qui peut dissimuler des modèles utiles. Ainsi, l'étape de prétraitement est nécessaire pour générer des données de qualité et améliorer l'efficacité des modèles de fouille de données (Zhang et al., 2003). Tout d'abord, les anomalies et les doublons sont supprimés. Ensuite, les attributs numériques sont discrétisés en divisant leur plage de valeurs en un nombre fini d'intervalles. Une méthode de sélection d'attributs (Hall, 1999) est utilisée pour évaluer la capacité prédictive des attributs en préférant les ensembles d'attributs hautement corrélés à la classe. Le fait que de nombreux attributs dépendent les uns des autres influence souvent la précision des modèles de prévision (Kotsiantis, 2007).

Le résultat de cette étape permet de définir l'ensemble des données qui seront utilisées dans les étapes suivantes.

4.3.4. Modèles de classification

Afin de trouver les meilleurs modèles, nous avons appliqué diverses techniques de classification supervisée sur l'échantillon d'apprentissage. Nous avons utilisé les algorithmes de classification de fouille de données les plus couramment appliqués dans le secteur des soins de santé, en se basant sur la littérature. Ces algorithmes sont également disponibles dans l'outil Weka (Witten et al., 2011).

- Arbres de décision: Id3, C4.5, BFTree et PART.
- Réseaux Bayésiens: Naïve Bayes (NB) et BayesNet.
- Support Vector Machine (SVM).

4.3.5. Évaluation des modèles de classification

Dans cette étape, les données de test sont utilisées afin de valider les modèles de classification. Pour obtenir des résultats fiables, les connaissances extraites doivent être évaluées

par une comparaison des résultats obtenus avec diverses méthodes de classification supervisée et en utilisant plusieurs mesures de performance (Dunham, 2006). La méthode la plus courante pour évaluer la performance des classificateurs est la validation croisée (Browne, 2000). Les mesures de performance peuvent être utilisées pour analyser les modèles prédictifs. Ces mesures se basent sur quatre valeurs de la matrice de confusion illustrée dans la figure 5: vrais positifs (TP), faux positifs (FP), vrais négatifs (TN) et faux négatifs (FN).

		Observed	
		True	False
Predicted	True	True Positive (TP)	False Positive (FP)
	False	False Negative (FN)	True Negative (TN)

Figure 5. Format de la matrice de confusion

Cinq mesures de performance sont utilisées: accuracy, precision, recall, statistique Kappa et la courbe ROC. Si les résultats de l'évaluation ne sont pas suffisamment efficaces, le processus reprend à partir de l'étape de prétraitement des données.

4.4. Résultats et discussions

L'évaluation des modèles est effectuée à l'aide de la validation croisée 10-fold sur l'ensemble des données des urgences pédiatriques. Les algorithmes basés sur l'arbre de décision peuvent générer des règles de classification ayant des structures de type if-then. Les méthodes d'arbre de décision que nous avons utilisées pour créer les modèles de classification incluent: Id3, C4.5, REPTree, BFTree et PART. Ces techniques d'arbre de décision fournissent un ensemble de règles qui peuvent être appliquées à de nouvelles données (données non classifiées), afin de prédire quels enregistrements auront un résultat donné. Dans notre cas, la variable à prédire est la durée de séjour des patients dans les urgences pédiatriques. Par exemple, en appliquant la règle en utilisant la méthode PART, "if $X_{11} = \text{Fever}$ and $X_4 < 150$ then $c1$ ", pour un patient âgé de 38 mois et souffrant de fièvre, nous obtenons la classe prédite $c1$ qui représente une courte durée de séjour. Ainsi, en appliquant les méthodes de fouille de données, nous pouvons prédire la durée de séjour des patients dans le service des urgences.

Le tableau V donne les performances des modèles de prédiction obtenus avec chaque classificateur en termes de precision, accuracy, recall, statistique Kappa et courbe ROC.

Méthodes	Accuracy	Precision	Recall	Statistique Kappa	Courbe ROC
NB	78.463	0.76	0.785	0.351	0.829
BayesNet	78.286	<u>0.763</u>	0.783	<u>0.360</u>	<u>0.83</u>
SVM	<u>79.942</u>	0.725	<u>0.799</u>	0.237	0.609
Id3	72.291	0.758	0.784	0.3	0.691
PART	78.576	0.742	0.786	0.298	0.778
C4.5	79.701	0.748	0.797	0.282	0.706
REPTree	78.945	0.724	0.789	0.210	0.728
BFTree	79.170	0.739	0.792	0.245	0.735

Tableau V. Évaluation des performances des modèles de prédiction du LOS

Le score maximal de l'accuracy 79,942 a été obtenu par les SVM tandis que le plus bas score 72,291 a été obtenu par Id3. Le score maximum de Kappa correspond à 0,36 avec BayesNet et le score Kappa le plus bas est de à 0,210 avec REPTree. Le score de précision le plus élevé appartient encore à BayesNet (0,763). De plus, nous pouvons constater que le recall était légèrement meilleur avec les SVM. Le score maximum de la courbe ROC correspond à 0,83 avec BayesNet et le score le plus bas a été obtenu par les SVM (0,609). Conformément à ces résultats, BayesNet et SVM offrent de meilleures performances que d'autres méthodes.

Soit $Vindicator(i,j)$: la valeur de l'indicateur $i \in \{Accuracy, Precision, recall, Kappa statistic, ROC area\}$ pour le modèle $j \in \{NB, BayesNet, SVM, Id3, PART, C4.5, REPTree, BFTree\}$. La figure 6 donne la comparaison de tous les modèles en fonction de $RateOfMax(i)$ étant défini par:

$$RateOfMax(i) = \frac{Vindicator(i,j)}{\max_{j \in SetofModels} (Vindicator(i,j))} \quad (2)$$

En évaluant les résultats fournis par les mesures de performance, nous constatons que les méthodes BayesNet et NB ont produit les meilleurs résultats. Cependant, les modèles d'arbre de décision sont pour la plupart, à plus de 80% plus proches du maximum. Nous pouvons conclure que les arbres de décision donnent des résultats comparables à ceux de NB et BayesNet. Dans ce cas, nous avons préféré les arbres de décision car ils sont réputés à avoir plusieurs ordres

de grandeur et ils sont plus rapides que les réseaux de neurones et les SVM (Benbelkacem et al., 2014).




Figure 6. Taux maximum

Comme le montre les résultats, cette étude peut être utile aux responsables des services d'urgence pédiatrique pour prévoir la durée de séjour et détecter le début de la situation de contrainte. Cette information peut être utilisée pour rendre la décision plus proactive. Cependant, comme présenté dans Koh & Tan (2005), cette étude présente certaines limites. Premièrement, cette étude peut être limitée par l'accessibilité des données en raison de l'hétérogénéité de la source des données (administration, laboratoire, service d'urgence pédiatrique, ...). Les données doivent être collectées et intégrées avant d'être utilisées. L'une des solutions proposées dans la littérature est l'utilisation de l'entrepôt de données mais c'est un projet coûteux et qui prend du temps. Deuxièmement, des données peuvent être manquantes ou non normalisées, telles que des informations enregistrées dans un format différent. Par exemple, dans la variable X_3 (Orientation), on peut trouver deux enregistrements différents «Sortie avec consultation externe les 7 prochains jours» et «Sortie avec consultation externe les 8 prochains jours». Cet élément peut être normalisé en tant que «Sortie» et avoir une autre colonne spécifiant le délai pour la consultation externe. Troisièmement, «l'application réussie de la fouille de données nécessite des connaissances du domaine ainsi que des méthodologies et des outils de fouille de données» (Koh & Tan, 2005).

4.5. Conclusion

Dans ce chapitre, nous avons présenté une approche basée sur les méthodes de classification supervisée afin de prédire la durée de séjour des patients dans le service d'urgence pédiatrique du centre régional de Lille, en France. La prédiction de la durée de séjour a pour objectif d'améliorer la planification des ressources dans les services d'urgence. La prédiction du LOS permet aux professionnels des urgences d'obtenir une estimation de la durée de séjour des patients dans le service d'urgence. Les professionnels des urgences pourront mieux planifier les ressources des patients en estimant la durée pour laquelle une ressource doit rester disponible.

Nous avons décrit les étapes nécessaires pour prétraiter et préparer les données. Ensuite, nous avons testé et comparé les performances des modèles de prédiction. Les résultats indiquent que BayesNet et NB ont donné de meilleurs résultats. Cependant, les méthodes d'arbre de décision ont donné des résultats comparables et peuvent être utilisées avec succès pour prédire la durée de séjour des patients. Les arbres de décision peuvent aider les responsables du service d'urgence dans leurs prises de décision quotidiennes.

Cette étude illustre l'intérêt des méthodes de classification pour rendre le système de prise en charge des urgences plus proactif face aux situations de tension. Cependant, certaines perspectives peuvent être considérées. Premièrement, un ensemble de données supplémentaire doit être pris en compte et de nouvelles expérimentations doivent être menées. Deuxièmement, d'autres méthodes de fouille de données, telles que les SVM (support vector machine), doivent être testées sur un plus large ensemble de données afin d'extraire des connaissances et de créer des modèles pouvant aider les gestionnaires du SUP dans la prise de décision concernant la gestion des activités du service d'urgence pédiatrique. Enfin, des méthodes de sélection d'attributs devraient être utilisées pour améliorer les performances des modèles de prédiction de la durée de séjour.

Dans le chapitre suivant, l'approche proposée est appliquée sur un ensemble plus important de données en utilisant différentes méthodes d'apprentissage automatique pour générer des modèles de prédiction performants à l'aide de la sélection d'attributs.

Chapitre 5

Prise en charge des urgences pédiatriques : Modèle de prévision par sélection de variables pertinentes

5.1. Objectifs

Ce chapitre vise à décrire à travers la première section (5.2) les étapes de la démarche méthodologique adoptée pour améliorer la prise en charge des patients dans le service des urgences. Ensuite, la deuxième section (5.3) présente les résultats des expérimentations effectuées sur des données réelles concernant des patients des urgences pédiatriques du CHU de Lille.

L'approche proposée dans ce chapitre est une contribution à l'approche proposée dans le chapitre précédent. Une méthode de sélection d'attributs est utilisée pour améliorer les performances des modèles de prédiction. Par ailleurs, un nombre significatif de données est pris en compte, ce qui permet d'effectuer une analyse descriptive sur les données permettant de faire ressortir d'autres attributs pertinents. L'objectif de l'approche proposée dans ce chapitre, consiste à résoudre l'un des problèmes courants dans les urgences, il s'agit de l'allocation des ressources. Les modèles de prévision de la durée de séjour visent à aider les urgentistes à planifier plus efficacement les ressources et aboutir à une meilleure prise en charge des patients.

5.2. Description de l'approche proposée

Le problème le plus fondamental de l'apprentissage automatique peut être décrit comme suit. Soit Ω un échantillon d'apprentissage composé des exemples $(x_1, y_1), \dots, (x_l, y_l)$. Chaque exemple (x_i, y_i) se constitue d'un objet x_i (généralement un vecteur d'attributs) et une classe y_i . Le problème est de prédire la classe y_k d'un nouvel objet x_k (Gammerman & Vovk, 2007). Nous proposons d'exploiter les techniques d'apprentissage automatique pour mettre en place une méthodologie d'aide à la prise en charge des urgences pédiatriques (Benbelkacem et al., 2019). Cette méthodologie porte sur la prédiction de la durée de séjour des patients afin d'anticiper l'occurrence des situations de tension dans les urgences et améliorer la planification des ressources. Les principales étapes de la méthodologie proposée sont résumées dans la figure 7. La première étape consiste à collecter des données à partir du service d'urgence pédiatrique du centre hospitalier régional (CHRU) de Lille. Les étapes suivantes abordent le prétraitement et l'analyse statistique des données. Ensuite, une méthode de sélection des attributs est utilisée pour trouver les descripteurs les plus pertinents pour la prédiction du temps de séjour des patients.

Enfin, des techniques d'apprentissage automatique sont utilisées pour développer des modèles de prédiction de la durée de séjour des patients dans le service d'urgence pédiatrique.




Figure 7. Schéma général de l'approche proposée

5.2.1. Collection des données

La démarche proposée commence par l'étape de collection de données. Les sources de données sont présentées sous forme de tableaux après avoir été localisées, consultées et sélectionnées (Giudici & Jiang, 2006). L'approche proposée utilise des données réelles extraites du SUP du CHRU de Lille. Chaque patient est caractérisé par des descripteurs et une durée de séjour.

5.2.2. Prétraitement des données

Les données collectées peuvent être incohérentes ou incomplètes. Le prétraitement des données permet d'obtenir des données de qualité pour produire des modèles de fouille de données plus efficaces (Zhang et al., 2003). Cette étape permet entre autres de traiter les valeurs manquantes des données (Cios et al., 2007).

5.2.3. Analyse descriptive des données

Cette étape consiste à établir une analyse statistique sur les données collectées. Il s'agit d'établir des liens statistiques ou fonctionnels entre les variables afin de trouver l'influence de certains facteurs ou variables sur la durée de séjour et notamment de déduire de nouvelles variables. Parmi ces facteurs, on peut citer le nombre d'arrivées des patients au SUP.

5.2.4. Sélection des données

5.2.4.1. Qu'est ce que la sélection des attributs ?

La prise en compte d'un nombre élevé d'attributs rend parfois les algorithmes de classification plus complexes et réduit leur efficacité. Il serait donc judicieux de sélectionner les attributs pertinents afin de réduire la dimension de l'espace des attributs d'entrée.

Féraud et al. (2010) définissent la sélection d'attributs comme « Un processus permettant de choisir un sous ensemble d'attributs pertinents, à partir d'un ensemble d'attributs optimal, selon un certain critère de performance ».

Un processus de sélection d'attributs (Dash & Liu, 1997) comporte quatre étapes principales : la génération, l'évaluation, le critère d'arrêt et la validation (voir figure 3). Les méthodes de sélection d'attributs permettent d'extraire un sous-ensemble d'attributs à partir de l'ensemble original des attributs (Yu & Liu, 2003). L'objectif des méthodes de sélection d'attributs consiste à identifier les attributs pertinents, améliorer la qualité des méthodes de classification, et réduire l'espace de stockage et le temps d'apprentissage (Mokeddem et al., 2014).

5.2.4.2. Catégories des méthodes de sélection des attributs

Les méthodes de sélection d'attributs peuvent être regroupées en trois grandes catégories, les méthodes filtres (*filter*), les méthodes enveloppes (*wrapper*) et les méthodes embarquées (*embedded*).

- **Méthodes filtres ou filter**

Dans les méthodes filtres, les descripteurs sont classés en fonction de certains critères statistiques. Une fonction d'évaluation basée sur les caractéristiques de l'ensemble de données est utilisée pour la sélection des attributs. Les descripteurs ayant le score le plus élevé sont sélectionnés. Les méthodes filtres sont rapides et indépendantes du classificateur et peuvent facilement évoluer avec des bases de données volumineuses. Différents classificateurs peuvent être évalués avec les méthodes filtres. L'inconvénient commun des méthodes filtres est qu'elles ignorent l'interaction avec le classificateur (Kumari & Swarnkar, 2011).

- **Méthodes enveloppes ou wrapper**

Les méthodes wrapper utilisent l'algorithme inductif comme fonction d'évaluation (Langley, 1994). L'algorithme de classification est utilisé dans la procédure de recherche et la sélection d'attributs. Dans cette configuration, divers sous-ensembles d'attributs sont générés et évalués. Toutefois, l'évaluation d'un sous-ensemble spécifique de descripteurs nécessite d'effectuer la classification avec un modèle de classification spécifique, ce qui rend cette approche coûteuse en temps de calcul (Kumari & Swarnkar, 2011).

- **Méthodes embarquées ou embedded**

Les méthodes embarquées utilisent l'information interne du modèle de classification (Lal et al., 2006). Les processus de sélection des attributs et de classification sont effectués conjointement.

5.2.5. Modélisation des données

La modélisation des données vise à développer un modèle de prédiction en utilisant des techniques d'apprentissage automatique. Ces techniques permettent de découvrir des connaissances et des modèles utiles à partir des données.

Pour trouver les meilleurs modèles, nous avons appliqué les algorithmes de classification les plus couramment utilisés dans les systèmes de santé (Jothi et al., 2015).

- Classificateur Bayésien: Naïve Bayes (NB).
- Algorithmes d'arbre de décision: C4.5, PART, RF. C4.5 est l'algorithme le plus connu de la littérature pour générer des arbres de décision, PART est un algorithme d'induction de règles, RF est un algorithme de forêts aléatoires.
- SVM (Support Vector Machine).
- K plus proches voisins (K-ppv).

Les arbres de décision sont reconnus pour leur simplicité et leur efficacité. Le traitement des données manquantes est l'un des atouts des réseaux Bayésiens en plus de leur applicabilité flexible. La principale force des SVM consiste en leur capacité à traiter une grande variété de problèmes de classification. Parmi les avantages des K-ppv, on peut citer la facilité de compréhension et la robustesse face aux données bruitées.

5.3. Expérimentations et discussion des résultats : Application sur un cas réel

5.3.1. Description des données

Cette étude est menée sur un ensemble de données extrait de la base de données du SUP du CHRU de Lille entre les années 2011 et 2012. L'ensemble de données collectées comprend 44992 patients où chaque patient w_i est décrit par 12 descripteurs $X_1, X_2, \dots, X_{12}$. A chaque patient w_i est assignée une durée de séjour Y qui correspond à la durée du patient dans le SUP. La description des attributs est donnée dans le tableau VI.

Attributs	Description
X_1	Date d'arrivée au SUP
X_2	Temps d'arrivée
X_3	Moyen d'arrivée (personnel, ambulance, pompiers, ...)
X_4	Age du patient (entre 0 et 180 mois)
X_5	Sexe du patient

X_6	Diagnostic principal (pathologie du patient)
X_7	Classification clinique des malades aux urgences (CCMU)
X_8	Groupe d'étude multicentrique du service d'urgence (GEMSA)
X_9	Examen biologique
X_{10}	Echographie
X_{11}	Radiographie
X_{12}	Scanner
Y	Durée de séjour du patient dans le SUP

Tableau VI. Description des attributs

5.3.2. Préparation des données

Les données collectées ont été nettoyées en éliminant les doublons et en traitant les valeurs atypiques et les données manquantes. Par la suite, des méthodes de discrétisation ont été appliquées sur les attributs continus.

L'âge des patients dans le SUP est d'environ 180 mois. Cependant, les données collectées comprenaient 371 patients âgés entre 181 et 1322 mois (110 ans). Certaines données ont été supprimées de l'ensemble de données pour ne conserver que les patients avec un âge inférieur à 180 mois. Après le prétraitement des données, une base nettoyée de 39661 patients a été obtenue.

5.3.3. Analyse statistique des données

Nous avons étudié le nombre d'arrivées des patients au service d'urgence pédiatrique selon trois périodes différentes : le nombre d'arrivées par mois, le nombre d'arrivées par jour et le nombre d'arrivées par heure.

a) Arrivées des patients par mois

Le nombre d'arrivées par mois est présenté dans la figure 8. Le nombre d'arrivées varie entre 3500 et 4000 entre janvier et juin. Par contre, le nombre d'arrivées diminue entre juillet et septembre. Selon le personnel d'urgence, la période de l'année a une influence sur la durée de séjour et surtout durant la période épidémique qui se déroule entre novembre et mars. En observant la figure 8, nous pouvons distinguer trois périodes différentes. Les différentes périodes de l'année sont définies dans le tableau VII.




Figure 8. Nombre d'arrivées des patients par mois

Périodes	Valeurs
Période 1	Janvier à Juin
Période 2	Juillet à Septembre
Période 3	Octobre à Décembre

Tableau VII. Périodes de l'année

b) Arrivées quotidiennes des patients

Les données utilisées dans la figure 9 représentent les arrivées quotidiennes des patients dans le SUP entre janvier 2011 et décembre 2012. Le nombre d'arrivées est d'environ 5700 le jeudi et samedi. Le nombre d'arrivées diminue le reste de la semaine. Il est à noter que le nombre d'arrivées des patients est plus élevé le week-end et atteint 6335 arrivées le dimanche. La figure 10 montre le nombre d'arrivées des patients par 24h le dimanche. Cette analyse montre que le nombre d'arrivées des patients varie selon les jours de la semaine. Par conséquent, nous avons trouvé utile d'ajouter le jour d'arrivée des patients à la liste des descripteurs.




Figure 9. Nombre d'arrivées quotidiennes des patients




Figure 10. Nombre d'arrivées des patients par 24h le dimanche

c) Arrivées des patients par heure

La figure 11 montre le nombre d'arrivées des patients par heure. On observe que le nombre d'arrivées des patients est faible entre minuit et 7h. A partir de 8h du matin, le nombre d'arrivées augmente progressivement pour atteindre environ 3200 arrivées vers 19h. D'autre part, le nombre d'arrivées des patients diminue après 19h. À partir de cette analyse, trois périodes journalières distinctes peuvent être déduites dans le tableau VIII.




Figure 11. Nombre d'arrivées des patients par heure

Périodes	Valeurs
Nuit	$0 \leq \text{heure} < 7$
Jour	$7 \leq \text{heure} < 19$
Soir	$19 \leq \text{heure} \leq 23$

Tableau VIII. Périodes journalières

Suite à l'analyse statistique des données, quatre descripteurs ayant une influence sur la durée de séjour ont été obtenus. Les nouveaux descripteurs définis dans le tableau IX seront ajoutés à la liste des descripteurs précédemment définis (tableau VI). Les patients seront donc décrits par 16 attributs.

Attributs	Description
X_{13}	Période de l'année
X_{14}	Mois d'arrivée
X_{15}	Jour de la semaine
X_{16}	Période de la journée

Tableau IX. Description des nouveaux attributs

5.3.4. Sélection des attributs basée sur la corrélation

Les descripteurs non pertinents doivent être filtrés avant d'appliquer les techniques de fouille de données. La sélection des attributs les plus pertinents permet d'évaluer la capacité de

prédiction des descripteurs, préférant les ensembles d'attributs fortement corrélés à la classe. Les méthodes de sélection des attributs comprennent la distance euclidienne, le gain d'informations, la sélection de caractéristiques basée sur la corrélation, CFS, Chi-square, T-test, etc. Dans la littérature (Hall, 1999; Hall & Smith, 1998), il a été démontré que l'utilisation d'algorithmes d'apprentissage automatique sur des données traitées par la méthode CFS (Correlation-based Feature Selection) pouvait améliorer la précision et la compréhensibilité des modèles induits. Dans cette étude de recherche, la méthode de sélection de fonctions basée sur la corrélation CFS est utilisée pour la sélection des attributs pertinents car cette méthode permet de trouver des sous-ensembles de variables utiles pour la prédiction et fortement corrélés avec la classe. CFS (Correlation-based Feature Selection) est un algorithme de filtrage simple qui classe les sous-ensembles d'entités selon une fonction d'évaluation heuristique basée sur la corrélation. Il évalue un sous-ensemble de caractéristiques en considérant la capacité de prédiction individuelle de chaque entité (Hall, 1999).

$$CFSs = \frac{k\overline{r_{cf}}}{\sqrt{k+k(k-1)\overline{r_{ff}}}} \quad (3)$$

Où $CFSs$ représente le score d'un sous-ensemble d'attributs s contenant k attributs, $\overline{r_{cf}}$ est la moyenne entre les corrélations attribut-classe ($f \in S$), $\overline{r_{ff}}$ est la moyenne entre les corrélations attribut-attribut.

La méthode CFS a été utilisée pour étudier la corrélation entre les variables et pour choisir les descripteurs les plus pertinents pour la prédiction de la durée de séjour des patients dans le service d'urgence pédiatrique. Comme l'indique le tableau X, la méthode CFS a permis de sélectionner sept descripteurs pertinents parmi les variables candidates.

	Avant la sélection	Après la sélection
Nombre d'attributs	16	7
Attributs	$X_1, \dots, X_{16}$	$X_6, X_8, X_{10}, X_{13}, X_{14}, X_{15}, X_{16}$

Tableau X. Descripteurs avant et après la sélection d'attributs

5.3.5. Modèles de prédiction

La modélisation des données est l'étape clé du processus. Pour mener à bien les expérimentations, nous avons utilisé les techniques d'apprentissage automatique principalement

utilisées pour résoudre le problème de la prédiction dans les situations d'urgence pédiatrique. Le modèle de prédiction a été construit à l'aide de l'algorithme d'arbre de décision C4.5 qui a été comparé à d'autres techniques de fouille de données: Naïve Bayes (NB), arbre de décision (PART), forêt aléatoire (RF), les k plus proches voisins (k-NN) et les SVM.

C4.5 est l'algorithme le plus connu de la littérature pour la construction des arbres de décision. L'algorithme C4.5 (Quinlan, 1993) utilise une fonction d'évaluation de l'entropie de l'information comme critère de sélection. La fonction d'évaluation de l'entropie est calculée comme suit (Lin & Chen, 2012).

- Calculer $Info(S)$ pour identifier la classe dans l'échantillon d'apprentissage S .

$$Info(S) = - \sum_{i=1}^k \{ [freq(C_i, S)/|S|] \log_2 [freq(C_i, S)/|S|] \} \quad (4)$$

Où $|S|$ est le nombre de cas dans l'ensemble d'apprentissage, C_i correspond à une classe, $i = 1, 2, \dots, k$, k est le nombre de classes et $freq(C_i, S)$ est le nombre de cas dans C_i

- Calculer la valeur d'information attendue $Info_x(S)$ de la caractéristique x pour partitionner S .

$$Info_x(S) = - \sum_{i=1}^L [(|S_i|/|S|) Info(S_i)] \quad (5)$$

Où L est le nombre de sorties de la caractéristique x , S_i est un sous-ensemble de S correspondant à la $i^{ème}$ sortie, $|S|$ est le nombre de cas dans le sous-ensemble S_i

- Calculer les informations obtenues après le partitionnement conformément à la caractéristique X .

$$Gain(X) = Info(S) - Info_x(S) \quad (6)$$

- Calculer la valeur d'information de la partition $SplitInfo(X)$ pour S partitionné dans L .

$$SplitInfo(X) = - \sum_{i=1}^L \left[\frac{|S_i|}{|S|} \log_2 \frac{|S_i|}{|S|} \right] \quad (7)$$

- Calculer le ratio de gain de $Gain(X)$ sur $SplitInfo(X)$.

$$GainRatio(X) = Gain(X) / SplitInfo(X) \quad (8)$$

$Gain(X)$ est la quantité d'informations fournie par X dans l'ensemble d'apprentissage. La caractéristique avec le plus haut $GainRatio(X)$ est adoptée en tant que racine de l'arbre de décision.

La précision des modèles de prédiction a été évaluée avec et sans sélection d'attributs. Les résultats sont donnés dans le tableau XI.

Techniques de fouille de données	Tous les attributs	Attributs sélectionnés
C4.5	79.68	79.68
NB	79.68	79.68
PART	77.37	79.41
RF	74.17	75.09
SVM	79.68	79.68
k-NN	79.48	79.55

Tableau XI. Précision des modèles de prédiction avec et sans sélection d'attributs

En comparant les performances des différents modèles de prédiction, on observe que les résultats sont meilleurs avec les méthodes NB, C4.5, SVM et k-NN avec des performances identiques d'environ 79% avec ou sans sélection d'attributs. Avec les autres méthodes, les modèles basés sur un sous-ensemble d'attributs (attributs sélectionnés) se sont révélés plus efficaces que les modèles basés sur l'ensemble des attributs (tous les attributs). En analysant le tableau XI, on peut constater que les performances sont légèrement améliorées avec la sélection des attributs.

La figure 12 illustre les performances des modèles de prédiction basés sur la sélection d'attributs. Les performances des modèles de prédiction varient entre 70% et 80% avec la sélection des attributs.




Figure 12. Performances des modèles de prédiction basés sur la sélection d'attributs

5.3.6. Évaluation des performances

Etant donné la nature des résultats, la suite des expérimentations va se dérouler sur les modèles de prédiction basés sur la sélection d'attributs. Pour évaluer les modèles, l'ensemble de données est d'abord divisé en deux sous ensembles: i) l'échantillon d'apprentissage, pour construire les modèles ii) et l'échantillon test, pour évaluer les modèles. Ensuite, des erreurs de prédiction sont calculées et des mesures de performances sont évaluées pour comparer les modèles de prédiction générés par les méthodes NB, C4.5 et SVM. De plus, le temps de traitement est évalué pour chaque méthode.

a) Calcul des erreurs de prédiction

- **Temps** : Le temps est calculé en secondes, il s'agit du temps requis pour compléter la modélisation de l'ensemble de données.
- **Erreur absolue moyenne ou Mean Absolute Error (MAE)** : C'est la moyenne de la valeur absolue de la différence entre la valeur prédite et la valeur réelle.

$$MAE = \frac{1}{n} \sum_{i=1}^n |P_i - A_i| \quad (9)$$

- **Erreur quadratique moyenne ou Root Mean Squared Error (RMSE)** : L'erreur quadratique moyenne est la racine carrée de l'erreur quadratique moyenne.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (P_i - A_i)^2} \quad (10)$$

- **Erreur absolue relative ou Relative Absolute Error (RAE)** : L'erreur absolue relative est définie par la somme de la différence entre la valeur prédictive et la valeur donnée, divisée par la somme de la différence entre la valeur donnée et la moyenne de la valeur donnée.

$$RAE = \frac{\sum_{i=1}^n |P_{ij} - A_i|}{\sum_{i=1}^n |A_i - A_m|} \quad (11)$$

Où P_i , P_{ij} sont les valeurs prédictives, A_i est la valeur réelle, A_m est la moyenne de tous les A_i et n est le nombre de prévisions effectuées.

Le tableau XII indique les résultats de l'évaluation du temps de traitement et des erreurs de prédiction pour les modèles de fouille de données sélectionnés précédemment.

Techniques de fouille de données	Temps (sec)	MAE	RMSE	RAE
NB	0.07	0.13	0.26	99.75
C4.5	0.62	0.13	0.26	99.98
SVM	1230.6	0.25	0.33	182.8

Tableau XII. Évaluation des erreurs de prédiction

A partir du tableau XII nous pouvons observer la différence entre les erreurs de prédiction des algorithmes NB, C4.5 et SVM. Les expérimentations impliquent des mesures d'erreur très couramment utilisées, MAE, RMSE, MAE, ainsi que le temps de traitement. Pour prédire la durée de séjour des patients, les NB ont duré 0.07 secondes, C4.5 a pris 0.62 secondes alors que les SVM ont pris plus de temps. NB et C4.5 ont donné une erreur MAE de 0.13 et une erreur RMSE de 0.26 tandis que les SVM ont donné une erreur MAE de 0.25 et une erreur RMSE de 0.33. L'erreur de prédiction RAE diffère légèrement entre NB et C4.5.

b) Mesures de performance

Les mesures de performance sont basées sur les valeurs de la matrice de confusion : TP, FP, TN, FN (voir figure 5). Les mesures de performance suivantes ont été utilisées pour analyser les modèles prédictifs.

- **Accuracy:** Il s'agit de la proportion des éléments bien classés, définie par :

$$\frac{TP+TN}{TP+TN+FP+FN} \quad (12)$$

- **Precision:** Il s'agit du taux de classification des vrais positifs, étant définie par :

$$\frac{TP}{TP+FP} \quad (13)$$

- **Sensitivity:** c'est l'évaluation et le classement de chaque échantillon en se basant sur la classe positive, définie par :

$$\frac{TP}{TP+FN} \quad (14)$$

- **Courbe ROC:** c'est une représentation du taux de vrais positifs défini par $\frac{TP}{TP+FN}$ en fonction du taux de faux positifs défini par $\frac{FP}{FP+TN}$ pour un modèle donné (Han et al., 2012).

Le tableau XIII présente les performances des modèles de prédiction obtenus avec chaque classificateur en termes de : accuracy, precision, sensitivity, statistiques Kappa et courbe ROC.

Techniques de fouille de données	Accuracy	Precision	Sensitivity	Courbe ROC
NB	79.6803	0.635	0.797	0.52
C4.5	79.6828	0.635	0.797	0.5
SVM	79.6828	0.635	0.797	0.501

Tableau XIII. Évaluation des performances des modèles de prévision sélectionnés

Le tableau XIII indique que l'accuracy maximale est d'environ 79,68, la précision est égale à 0,635 et sensitivity est 0,797 avec les trois méthodes. Les valeurs de la courbe ROC sont 0,52 pour les naïves Bayes (NB), 0.5 pour C4.5 et 0.501 pour les SVM. D'après ces résultats, nous notons que l'utilisation des méthodes C4.5 et SVM donne de meilleures performances pour les modèles de prévision.

5.4. Conclusion

Nous avons exploité les techniques d'apprentissage automatique pour mettre en œuvre un modèle de prévision de la durée de séjour des patients dans le service des urgences. L'approche proposée a été appliquée sur des données réelles concernant des patients du service des urgences pédiatriques de l'hôpital universitaire de Lille. Tout d'abord, une analyse statistique a été effectuée afin de déterminer l'influence de nouvelles variables sur la durée de séjour. Ensuite, la méthode CFS a été utilisée pour sélectionner un sous ensemble de descripteurs parmi les plus pertinents pour la prédiction de la durée de séjour. Puis, des techniques d'apprentissage automatique ont été utilisées pour mettre en œuvre un modèle de prédiction de la durée de séjour. Les techniques que nous avons utilisées ont été sélectionnées à partir des algorithmes de classification les plus couramment appliqués dans les systèmes de soins de santé, notamment les arbres de décision, la méthode Bayésienne naïve Bayes, les SVM et les k-NN. Les résultats se sont avérés meilleurs avec les méthodes NB, C4.5 et SVM. De plus, les modèles

basés sur un sous-ensemble d'attributs se sont révélés plus efficaces que les modèles basés sur l'ensemble des attributs. Les résultats obtenus par les modèles de prédiction sont encourageants et pourraient servir à aider les responsables des services d'urgence dans leur processus de prise de décision afin de prévenir les situations de tension et améliorer la planification des ressources.

Comme perspective, nous proposons d'utiliser la combinaison de classificateurs afin d'améliorer les performances des classificateurs individuels. Enfin, les professionnels de la santé devraient être impliqués dans le processus afin de fournir des informations et mettre à profit leurs connaissances sur le domaine.

Conclusion générale

6. Conclusion générale

Nous avons proposé une approche d'aide à la prise en charge des urgences pédiatriques basée sur les techniques d'apprentissage automatique. Les services des urgences sont confrontés à de multiples problèmes justifiant l'intérêt de l'étude sur la prise en charge des patients. La durée de séjour prolongée des patients constitue l'un des problèmes les plus fréquents dans les services des urgences. Nous nous sommes fixés comme premier objectif d'étudier l'impact des techniques d'apprentissage automatique dans le secteur des soins de santé. L'étude de la littérature nous a permis de cibler les techniques d'apprentissage supervisé les plus efficacement utilisées dans les services d'urgences médicales. Le second objectif porte sur la prévision de l'occurrence des situations de tension dans les services des urgences pédiatriques.

Une méthode de sélection d'attributs a été utilisée pour identifier les descripteurs les plus pertinents pour le développement des modèles de prédiction à l'aide des techniques d'apprentissage automatique. La sélection des attributs a permis d'améliorer les performances des modèles de prédiction. La méthodologie proposée vise à prédire la durée de séjour des patients afin de prévenir l'avènement des situations de tension et anticiper l'occurrence du surpeuplement des services d'urgence. Dans le cas d'un surpeuplement, le besoin identifié pour les soins des patients dépasse les ressources disponibles. La planification devient nécessaire pour remédier au problème d'allocation de ressources. En effet, la prédiction de la durée de séjour peut s'avérer utile pour améliorer la planification des ressources.

Des expérimentations ont été faites sur une base de données réelle extraite du service des urgences pédiatriques du CHU de Lille. Les résultats des tests se sont avérés prometteurs et ont montré l'efficacité de l'utilisation des techniques d'apprentissage automatique pour la prise en charge des urgences. La prédiction de la durée de séjour permet d'aider les professionnels des urgences à planifier plus efficacement les ressources et les soins des patients et, par conséquent, permet d'aboutir à une meilleure prise en charge des patients dans les services d'urgences pédiatriques.

Comme projection future de ce travail de recherche, il serait intéressant de mener de nouvelles expérimentations et de tester d'autres méthodes d'apprentissage, tels que les réseaux de neurones dans le cas d'une approche d'apprentissage profond (*Deep learning*). Il s'agit d'une

méthode d'apprentissage prometteuse qui joue un rôle primordial dans la mise à disposition de solutions d'analyse prédictive. L'approche d'apprentissage profond basée sur les réseaux de neurones récurrents (*recurrent neural networks*) pourrait être utilisée dans un système d'aide à la décision Big Data afin de prédire les tensions générées par le flux de patients et la très longue durée de séjour dans les services des urgences.

Bibliographie

- Adnan, M.H., Husain, W., & Rashid, N.A. (2012). Data mining for medical systems: a review. *First International Conference on Advances in Computer and Information Technology*.
- Aghajani, S., & Kargari, M. (2016). Determining factors influencing length of stay and predicting length of stay using data mining in the general surgery department. *Hospital Practices and Research* 1(2), 53-58.
- Ajmi, I., Zgaya, H., Gammoudi, L., Hammadi, S., Martinot, A., Beuscart, R., & Renard, J.M. (2015). Mapping patient path in the pediatric emergency department: A workflow model driven approach. *Journal of Biomedical Informatics* 54, 315-328.
- Aleksovska-Stojkovska, L., & Loskovska, S. (2013). Data mining in clinical decision support systems. In: Gaol F. (eds) Recent Progress in Data Engineering and Internet Technology. *Lecture Notes in Electrical Engineering* 156, Springer, Berlin, Heidelberg.
- Aljumah, A.A., Ahamad, M.G., & Siddiqui, M.K. (2013). Application of data mining: Diabetes health care in young and old patients. *Journal of King Saud University-Computer and Information Sciences* 25, 127-136.
- Alnuaimi, N., Masud, M.M., & Mohammed, F. (2015). Examining the effect of feature selection on improving patient deterioration prediction. *International Journal of Data Mining & Knowledge Management Process* 5(6).
- Alturki, L., Aloraini, K., Aldughayshim, A., & Albahli, S. (2019). Predictors of readmissions and length of stay for diabetes related patients, *IEEE/ACS 16th International Conference on Computer Systems and Applications*, 1-8.
- Apete, G.K. (2011). Optimisation médico-économique et organisation des services d'urgences hospitalières apport des systèmes multi-agents, Thèse de Doctorat, Université de Lille 2.
- Arora, R., & Jaglan, S. (2015). An overview of data mining in medical field, *International Journal of Engineering and Technical Research* 3(7).
- Atmani, B., & Beldjilali, B. (2007). Neuro-IG: A hybrid system for selection and elimination of predictor variables and non relevant individuals. *Informatica* 18, 163-186.
- Atmani, B., Benbelkacem, S., & Benamina, M. (2013). Planning by case-based reasoning based on fuzzy logic. *International Conference of Artificial Intelligence and Fuzzy Logic*.
- Auria, L., & Moro, R.A. (2008). Support vector machines (SVM) as a technique for solvency analysis. Discussion paper of Deutsches Institut für Wirtschaftsforschung.
- Awad, A., Bader-El-Den, M., & McNicholas, J. (2016). Modeling and predicting patient length of stay: a survey. *International Journal of Advanced Scientific Research and Management* 1(8).
- Azari, A., Janeja, V.P., & Mohseni, A. (2012). Predicting hospital length of stay (PHLOS): A multi-tiered data mining approach, *IEEE 12th International Conference on Data Mining Workshops*, 17-24.
- Baitharu, T.R., & Pani, S.K. (2016). Analysis of data mining techniques for healthcare decision support system using liver disorder dataset. *Procedia Computer Science* 85, 862-870.

- Baki, B. (2006). Planification et ordonnancement probabilistes sous contraintes temporelles. Thèse de Doctorat, Université de Caen.
- Basavaraju, P., & Varde, A.S. (2016). Supervised learning techniques in mobile device apps for androids. *SIGKDD Explorations* 18(2).
- Beaudry, E. (2011). Planification d'actions concurrentes sous contraintes et incertitude. Thèse de Doctorat, Université de Sherbrooke.
- Benbelkacem, S. (2012). Aide à la décision médicale : planification guidée par datamining et raisonnement à partir de cas, Thèse de Magister, Université d'Oran 1.
- Benbelkacem, S., Atmani, B., & Benamina, M. (2013). Planning based on classification by induction graph. *Computer Science & Information Technology*. doi:10.5121/csit.2013.3823
- Benbelkacem, S., Kadri, F., Chaabane, S. & Atmani, B. (2014). A data mining based approach to detect strain situations in hospital emergency department systems. *Conférence de Modélisation et Simulation*, Nancy, France.
- Benbelkacem, S., Kadri, F., Atmani, B., & Chaabane, S. (2019). Machine learning for emergency department management. *International Journal of Information Systems in the Service Sector* 11(3), 19-36. doi:10.4018/IJISS.2019070102
- Bennett, P, & Hardiker, N.R. (2017). The use of computerized clinical decision support systems in emergency care: A substantive review of the literature. *Journal of the American Medical Informatics Association* 24(3), 655-668.
- Bishop, C.M. (1995). Neural networks for pattern recognition. Oxford University Press, Inc., New York NY.
- Browne, M.W. (2000). Cross-validation Methods. *Journal of Mathematical Psychology* 44, 108-132.
- Bruballa, E., Wong, A., Epelde, F., Rexachs, D., & Luque, E. (2016). A model to predict length of stay in a hospital emergency department and enable planning for non-critical patients admission. *International Journal of Integrated Care* 16(6).
- Carter, E.M., & Potts, H.W. (2014). Predicting length of stay from an electronic patient record system: A primary total knee replacement example. *BMC Medical Informatics and Decision Making* 14(26).
- Çela, E., & Frasheri, N. (2013). Data mining techniques and tools used in healthcare databases. *International Conference on Research and Education—Challenges Towards the Future*.
- Chabot, J.M. (2009). Le raisonnement et la décision en médecine. *Revue du praticien* 59(4), 573-578.
- Chae, Y.M., Kim, H.S., Tark, K.C., Park, H.J., & Ho, S.H. (2003). Analysis of healthcare quality indicator using data mining and decision support system. *Expert Systems with Applications* 24(2), 167-172.
- Chen, S., Guo, X., & Ju, X. (2018). The design of personalized artificial intelligence diagnosis and the treatment of health management systems simulating the role of general practitioners.

- In: Chen H., Fang Q., Zeng D., Wu J. (eds) Smart Health. ICSH 2018. *Lecture Notes in Computer Science 10983*. Springer, Cham.
- Chen, N., Liu, W., Bai, R., & Chen, A. (2019). Application of computational intelligence technologies in emergency management: A literature review. *Artificial Intelligence Review* 52(3), 2131–2168. <https://doi.org/10.1007/s10462-017-9589-8>
- Cheng, J., & Greiner, R. (2001). Learning bayesian belief network classifiers: Algorithms and system. In: Stroulia E., Matwin S. (eds) Advances in Artificial Intelligence, *Lecture Notes in Computer Science*, Springer Berlin Heidelberg, 141-151.
- Chhikara, S., & Sharma, P. (2014). Data mining techniques on medical data for finding locally frequent diseases. *International Journal for Research in Applied Science and Engineering Technology* 2(5).
- Cios, K.J., Pedrycz, W., Swiniarski, R.W., & Kurgan, L.A. (2007). Data mining: A knowledge discovery approach. Springer-Verlag New York, Inc.
- Cleret, M., Le Beux, P., & Le Duff, F. (2001). Les systèmes d'aide à la décision médicale. *Les Cahiers du numérique* 2, N° 2/2001, 125-154.
- Combes, C., Meskens, N., Rivat, C., & Vandamme, J.P. (2008). Using a KDD process to forecast the duration of surgery. *International Journal of Production Economics* 112(1), Elsevier.
- Core Public Health Functions for BC, Model Core Program Paper: Health Emergency Management, 2006.
- Cortes, C., & Vapnik, V. (1995). Support-vector networks. *Machine Learning* 20, 273-297. <https://doi.org/10.1023/A:1022627411411>
- Cosgrave, J. (1996). Decision making in emergencies. *Disaster Prevention and Management* 5(4), 28-35. <https://doi.org/10.1108/09653569610127424>
- Dai, J., Wang, S., & Yang, X. (1994). Computerized support systems for emergency decision making. *Annals of Operations Research* 51(7), 313-325. <https://doi.org/10.1007/BF02048553>
- Dash, M., & Liu, H. (1997). Feature selection for classification. *Intelligent Data Analysis* 1(3), 131-156. <https://doi.org/10.3233/IDA-1997-1302>
- De Toledo, P., Rios, P.M., Ledezma, A., Sanchis, A., Alen, J.F., & Lagares, A. (2009). Predicting the outcome of patients with subarachnoid hemorrhage using machine learning techniques. *IEEE Transactions on Information Technology in Biomedicine* 13, 794-801.
- Degoulet, P., & Fieschi, M. (1991). Traitement de l'information médicale. Méthodes et applications hospitalières, Masson.
- Delassus, E. (2011). La spécificité de la décision médicale. hal-00607419v2.
- Delen, D., Fuller, C., McCann, C., & Ray, D. (2009). Analysis of healthcare coverage: A data mining approach. *Expert Systems with Application* 36(2), 995-1003.
- Dey, P.K., Hariharan, S., & Ho, W. (2007). Managing healthcare technology in quality management framework, *International Journal of Technology Management* 40.

- Dhorajiwala, H.S., & Shaikh, E.A. (2015). Survey on decision support system for medical diagnosis using data mining. *International Journal of Engineering Research and General Science* 3(6).
- DHOS (2003), Direction de l'Hospitalisation et de l'Organisation des Soins. Circulaire N°195/DHOS/O1/2003/ du 16 avril 2003 relative à la prise en charge des urgences.
- Diwani, S.A., & Sam, A. (2013). Framework for data mining in healthcare information system in developing countries: a case of Tanzania. *International Journal of Computational Engineering Research* 3(10).
- Downs, J., & Reichgelt, H. (1991). Integrating classical and reactive planning within an architecture for autonomous agents. In: Hertzberg J. (eds) *European Workshop on Planning. Lecture Notes in Computer Science* 522, Springer, Berlin, Heidelberg.
- Dunham, M.H. (2006). Data Mining: Introductory and Advanced Topics. Pearson Education.
- Elsa, G. (2011). Un aspect du rôle infirmier autonome dans un service d'urgences somatiques. Baccalauréat en sciences HES-SO en soins infirmiers, Haute Ecole de Santé Fribourg.
- Esfandiari, N., Babavalian, M.R., Moghadam, A.M., & Tabar, V.K. (2014). Knowledge discovery in medicine: Current issue and future trend. *Expert Systems with Applications* 41, 4434-4463.
- Etchart, M., & Levraut, J. (2006). Gestion des flux de patients aux urgences : Gestion des flux d'aval. Journées Méditerranéennes d'Anesthésie Réanimation et Urgences, Service d'Accueil des Urgences CHU de Nice.
- Fan, L., & Poh, K.L. (2009). Improving the Naïve Bayes classifier. In: Rabuñal Dopico J., Dorado J., Pazos A. (eds) *Encyclopedia of Artificial Intelligence*, 879-883. Hershey, PA: IGI Global. doi:10.4018/978-1-59904-849-9.ch13
- Fayyad, U.M., Piatetsky-Shapiro, G., & Smyth, P. (1996). From data mining to knowledge discovery: An Overview. In: Advances in Knowledge Discovery and Data Mining, *American Association for Artificial Intelligence*, Menlo Park, CA.
- Feng, M., Li, A., Jia, C., & Liu, Z. (2016). Unconventional emergencies management based on domain knowledge. *Procedia Computer Science* 91, 268-275.
- Féraud, R., Boullé, M., Clérot, F., Fessant, F., & Lemaire, V. (2010). The orange customer analysis platform. In: Perner P. (eds) *Advances in Data Mining. Applications and Theoretical Aspects. Lecture Notes in Computer Science* 6171, Springer, Heidelberg.
- Fikes, R.E., & Nilsson, N.J. (1971). STRIPS: A new approach to the application of theorem proving to problem solving. *Artificial Intelligence* 2, 189-208.
- Fogel, A.L., & Kvedar, J.C. (2018). Artificial intelligence powers digital medicine. *npj Digital Medicine* 1(5), 1-4.
- Forero, R., & Hillman, K. (2008). Access block and overcrowding: a literature review. Report commissioned by the Australasian College for Emergency Medicine. The Simpson Centre for Health Services, University of New South Wales, 1-26.

- Gammerman, A., & Vovk, V. (2007). Hedging predictions in machine learning: The second computer journal lecture. *The Computer Journal* 50(2), 151-163.
- Geffner, H. (2014). Non-classical planning with a classical planner: The power of transformations. In: Fermé E., Leite J. (eds) Logics in Artificial Intelligence, *Lecture Notes in Computer Science* 8761, Springer, Cham.
- Giudici, P. (2005). Applied data mining: Statistical methods for business and industry. John Wiley & Sons Inc.
- Giudici, P., & Jiang, W. (2006). A review of: Applied data mining - Statistical methods for business and industry. *IIE Transactions* 38(12).
- Goh, K.L., & Singh, A.K. (2015). Comprehensive literature review on machine learning structures for web spam classification. *Procedia Computer Science* 70, 434-441.
- Grebennik, I., Reshetnik, V., Ovezgeldyyev, A., Ivanov, V., & Urniaieva, I. (2019). Strategy of effective decision-making in planning and elimination of consequences of emergency situations. In: Murayama Y., Velev D., Zlateva P. (eds) Information Technology in Disaster Risk Reduction. *IFIP Advances in Information and Communication Technology* 550, Springer, Cham.
- Grigoryan, D., Muradov, A., Balyan, S., Abrahamyan, S., Katvalyan, A., Korkhov, V., Iakushkin, O., Kulabukhova, N.V., & Shchegoleva, N. (2018). Creating artificial intelligence solutions in E-Health Infrastructure to support disabled people. In: Gervasi O. et al. (eds) Computational Science and Its Applications ICCSA 2018. *Lecture Notes in Computer Science* 10963, Springer, Cham.
- Grunwald, J.A., & Bearman, C. (2017). Identifying and resolving coordinated decision making breakdowns in emergency management. *International Journal of Emergency Management* 13(1).
- GTI (1998), Le Groupe Tactique d'Intervention en collaboration avec l'Association des médecins d'urgence du Québec. Les urgences au Québec 1990/1997. Bilan, perspectives et normes, Document de consultation.
- Hall, M.A. (1999). Correlation-based feature selection for machine learning. Thèse de Doctorat, Université de Waikato, Hamilton.
- Hall, M., & Smith, L. (1998). Practical feature subset selection for machine learning. *Proceedings of the 21st Australasian Computer Science Conference*, Springer, 181-191.
- Han, J., Kamber, M., & Pei, J. (2012). Data Mining: Concepts and Techniques. In: Han J., Kamber M., Pei J. (eds) The Morgan Kaufmann Series in Data Management Systems, *Data Mining (Third Edition)*, Morgan Kaufmann, 1-38.
- Hanifi, M. (2009). Extraction de caractéristiques de texture pour la classification d'images satellites, Thèse de Doctorat, Université de Toulouse.
- Harrou, F., Kadri, F., Chaabane, S., Tahon, C., & Sun, Y. (2015). Improved principal component analysis for anomaly detection: Application to an emergency department. *Computers & Industrial Engineering* 88, 63-77.

- Houthoofd, R., Ruysinck, J., van der Hertten, J., Stijven, S., Couckuyt, I., Gadeyne, B., Ongenaes, F., Colpaert, K., Decruyenaere, J., Dhaene, T., & De Turck, F. (2015). Predictive modelling of survival and length of stay in critically ill patients using sequential organ failure scores. *Artificial Intelligence in Medicine* 63, 191-207.
- Jane, J.B., & Ganesh, E.N. (2019). A feature selection prediction technique for healthcare using naive bayes algorithm. *International Journal of Recent Technology and Engineering* (8)1.
- Jarrar, M.S., Khelifi, S., Ben Amor, W., El afrit, S., & Ghannouchi, S. (2008). L'accueil et la durée de la prise en charge des patients au service des urgences du CHU Farhat Hached, étude prospective. *Journal maghrébin d'anesthésie-réanimation et de médecine d'urgence* 15, 251-257.
- Jothi, N., Rashid, N.A., & Husain, W. (2015). Data mining in healthcare - a review. *Procedia Computer Science* 72, 306-313.
- Kadri, F., Pach, C., Chaabane, S., Berger, T., Trentesaux, D., Tahon, C., & Sallez, Y. (2013). Modelling and management of strain situations in hospital systems using an ORCA approach. *Proceedings of 2013 International Conference on Industrial Engineering and Systems Management*, 1-9.
- Kadri, F., Chaabane, S., Harrou, F., & Tahon, C. (2014). Modélisation et prévision des flux quotidiens des patients aux urgences hospitalières en utilisant l'analyse de séries chronologiques. *7ème Conférence de Gestion et Ingénierie Des Systèmes Hospitaliers*, Liège, Belgique.
- Karmani, P., Chandio, A.A., Korejo, I.A., & Chandio, M.S. (2019). A review of machine learning for healthcare informatics specifically tuberculosis disease diagnostics. In: Bajwa I., Kamareddine F., Costa A. (eds) *Intelligent Technologies and Applications. Computer and Information Science* 932, Springer, Singapore.
- Khalidi, R., El Afia, A., & Chiheb, R. (2019). Forecasting of weekly patient visits to emergency department: real case study. *Procedia Computer Science* 148, 532-541.
- Kiezun, A., Lee, I.T.A., & Shomron, N. (2009). Evaluation of optimization techniques for variable selection in logistic regression applied to diagnosis of myocardial infarction. *Bioinformatics* 3, 311-313.
- Koh, H.C., & Tan, G. (2005). Data mining applications in healthcare. *Journal of Healthcare Information Management* 19(2), 64-72.
- Koppad, H.S., & Kumar, A.S. (2018). Efficacy of knowledge mining and machine learning techniques in healthcare industry. In: Margret A.S., Wiil U. (eds) *Knowledge Computing and Its Applications*, Springer, Singapore.
- Korfiatis, V.C., Asvestas, P.A., Delibasis, K.K., & Matsopoulos, G.K. (2013). A classification system based on a new wrapper feature selection algorithm for the diagnosis of primary and secondary polycythemia. *Computers in biology and medicine* 43(12), 2118–2126.
- Kotsiantis, S.B. (2007). Supervised machine learning: A review of classification techniques. *Proceedings of the 2007 Conference on Emerging Artificial Intelligence Applications in*

- Computer Engineering: Real Word AI Systems with Applications in eHealth, HCI, *Information Retrieval and Pervasive Technologies*, 3-24.
- Kraft, M.R., Desouza, K., & Androwich, I. (2003). Data mining in healthcare information systems: case study of a Veterans? Administration spinal cord injury population. *Proceedings of the 36th Annual Hawaii International Conference on System Sciences*.
- Kumari, B., & Swarnkar, T. (2011). Filter versus wrapper feature subset selection in large dimensionality micro array: A review. *International Journal of Computer Science and Information Technologies* 2(3), 1048-1053.
- Lal, T.N., Chapelle, O., Weston, J., & Elisseeff, A. (2006). Embedded methods. In: Guyon I., Nikravesh M., Gunn S., Zadeh L.A. (eds) *Feature Extraction: Foundations and Applications. STUDEFUZZ 207*, Springer, Heidelberg.
- Langley, P. (1994). Selection of relevant features in machine learning. *Proceedings of the AAAI Fall Symposium on Relevance*.
- Lauly, S. (2016). Exploration des réseaux de neurones à base d'auto-encodeur dans le cadre de la modélisation des données textuelles. Thèse de Doctorat, Université de Sherbrooke.
- Lebedev, G., Klimenko, H., Kachkovskiy, S., Konushin, V., Ryabkov, I., & Gromov, A. (2018). Application of artificial intelligence methods to recognize pathologies on medical images. *Procedia Computer Science* 126, 1171-1177.
- Lin, S.W., & Chen, S.C. (2012). Parameter determination and feature selection for C4.5 algorithm using scatter search approach. *Soft Computing* 16(1), 63-75.
- Liu, P., Lei, L., Yin, J., Zhang, W., Naijun, W., & El-Darzi, E. (2006). Healthcare data mining: prediction inpatient length of stay. *3rd International IEEE Conference on Intelligent Systems*, 832-837.
- Lobach, D.F., Kawamoto, K., Anstrom, K.J., Russell, M.L., Woods, P., & Smith, D. (2007). Development, deployment and usability of a point-of-care decision support system for chronic disease management using the recently-approved HL7 decision support service standard. *Studies in Health Technology and Informatics* 129, 861-865.
- Magoulas, G.D., & Prentza, A. (2001). Machine learning in medical applications. In: Paliouras G., Karkaletsis V., Spyropoulos C.D. (eds) *Machine Learning and Its Applications. Lecture Notes in Computer Science 2049*. Springer, Berlin, Heidelberg.
- Mangai, K., & Harris, P. (2016). A novel approach for resource allocation in emergency department of hospitals. *International Journal of Advanced Research in Computer Science and Software Engineering* 6(3), 269-275.
- Marinagi, C.C., Panayiotopoulos, T., & Spyropoulos, C.D. (2005). AI planning and intelligent agents. In: Vlahavas I., Vrakas D. (eds) *Intelligent Techniques for Planning*, 225-258. Hershey, PA: IGI Global. doi:10.4018/978-1-59140-450-7.ch007
- Marshall, T., Champagne-Langabeer, T., Castelli, D., & Hoelscher, D. (2017). Cognitive computing and eScience in health and life science research: artificial intelligence and obesity intervention programs. *Health Information Science and Systems* 5(1). <https://doi.org/10.1007/s13755-017-0030-0>

- Mayer, B.W., Rangwala, H.S., Gupta, R., Srivastava, J., Karypis, G., Kumar, V., & de Groen, P.C. (2005). Feature mining for prediction of degree of liver fibrosis, *Annual Symposium of American Medical Informatics Association*.
- McCue, C. (2015). *Data Mining and Predictive Analysis: Intelligence Gathering and Crime Analysis*, Second Edition.
- MEAH (2007). Mission nationale d'expertise et d'audit Hospitaliers. Réduire les temps d'attente et de passage aux urgences. Retours d'expériences. Tome 3, Partie 1.
- Michalski, S.R., Carbonell, G.J., & Mitchell, M.T. (1986). *Machine learning an artificial intelligence approach Volume II*, Morgan Kaufmann Publishers Inc., San Francisco, CA.
- Miller, D.D., & Brown, E.W. (2018). Artificial intelligence in medical practice: The question to the answer? *American Journal of Medicine* 131(2), 129-133.
- Milovic, B. (2012). Prediction and decision making in health care using data mining. *International Journal of Public Health* 1(2), 69-78.
- Mokeddem, S., Atmani, B., & Mokaddem, M. (2014). A new approach for coronary artery diseases diagnosis based on genetic algorithm. *International Journal of Decision Support System Technology* 6(4), 1-15.
- Morgans, A., & Burgess, S.J. (2011). What is a health emergency? The difference in definition and understanding between patients and health professionals. *Australian Health Review* 35(3), 284-289. doi: 10.1071/AH10922
- Morton, A., Marzban, E., Giannoulis, G., Patel, A., Aparasu, R., & Kakadiaris, I.A. (2014). A comparison of supervised machine learning techniques for predicting short-term in-hospital length of stay among diabetic patients. *13th International Conference on Machine Learning and Applications*, 428-431.
- Musen, M.A., Shahar, Y., & Shortliffe, E.H. (2014). Clinical decision-support systems. In: Shortliffe E.H., Cimino J.J. (eds) *Biomedical informatics: computer applications in health care and biomedicine*. London/New York, Springer.
- Ozaydin, B., Hardin, J.M., & Chhieng, D.C. (2016). Data mining and clinical decision support systems. In: Berner E. (eds) *Clinical Decision Support Systems. Health Informatics*, Springer, Cham.
- Panchami, V., & Radhika, N. (2014). A novel approach for predicting the length of hospital stay with DBSCAN and supervised classification algorithms. *Proceedings of the Fifth International Conference on the Applications of Digital Information and Web Technologies IEEE*, 207-212.
- Pereira, S., Torres, L., Portela, F., Santos, M.F., Machado, J., & Abelha, A. (2016). Predicting triage waiting time in maternity emergency care by means of data mining. In: Rocha Á., Correia A., Adeli H., Reis L., Mendonça Teixeira M. (eds) *New Advances in Information Systems and Technologies. Advances in Intelligent Systems and Computing* 445, Springer.
- Quinlan, J.R. (1986). Induction of decision trees. *Machine Learning* 1(81), 81-106. <https://doi.org/10.1007/BF00116251>

- Quinlan, J.R. (1993). *C4.5: Programs for machine learning*. San Francisco, CA, USA: Morgan Kaufmann Publishers Inc.
- Régnier, P. (2005). Algorithmes pour la planification. Habilitation à diriger les recherches, Université Paul Sabatier, Toulouse.
- Reiz, B., & Csató, L. (2009). Bayesian network classifier for medical data analysis. *International Journal of Computers Communications & Control* 4, 65-72.
- Robnik-Sikonja, M., Cukjati, D., & Kononenko, I. (2001). Evaluation of prognostic factors and prediction of chronic wound healing rate by machine learning tools. In: Quaglini S., Barahona P., Andreassen S. (eds) Artificial Intelligence in Medicine. *Lecture Notes in Computer Science 2101*, Springer, Berlin, Heidelberg.
- Roy, B., & Bouyssou, D. (1993). Aide multicritères à la décision: méthode et cas. *Economica*, Paris.
- Rupnik, R., & Kukar, M. (2007). Data mining based decision support system to support association rules. *Electrotechnical Review* 74(4), 195-200.
- Seidl, T. (2009). Nearest neighbor classification. In: LIU L., ÖZSU M.T. (eds) Encyclopedia of Database Systems, Springer, Boston, MA.
- Seroussi, B., & Bouaud, J. (2014). Systèmes informatiques d'aide à la décision en médecine : panorama des approches utilisant les données et les connaissances. *Pratique Neurologique - FMC* 5(4), 303-316.
- Sethi P., & Jain M. (2010). A comparative feature selection approach for the prediction of healthcare coverage. In: Prasad S.K., Vin H.M., Sahni S., Jaiswal M.P., Thipakorn B. (eds) Information Systems, Technology and Management. *Communications in Computer and Information Science* 54, Springer, Heidelberg.
- Shan, S., & Yan, Q. (2017). The emergency response decision support system framework. In: Emergency Response Decision Support System, Springer Briefs in Business, Springer, Singapore.
- Shitole, M., & Wakchaure, M.A. (2016). Survey: techniques of data mining for clinical decision support system. *International Journal of Advance Research and Innovative Ideas in Education* 2(1).
- Siermala, M. (2001). Prediction of protein secondary structures of all types using new hypersphere machine learning method. In: Quaglini S., Barahona P., Andreassen S. (eds) Artificial Intelligence in Medicine. *Lecture Notes in Computer Science 2101*, Springer, Berlin, Heidelberg.
- Simon, H.K., Hirsh, D.A., Rogers, A.J., Massey, R., & DeGuzman, M.A. (2009). Pediatric emergency department overcrowding: electronic medical record for identification of frequent, lower acuity visitors. Can we effectively identify patients for enhanced resource utilization? *The Journal of Emergency Medicine* 36(3), 311-316.
- Sinclair, D. (2007). Emergency department overcrowding-implications for paediatric emergency medicine. *Paediatr Child Health* 12(6), 491-494.

- Stecker, M.M., Stecker, M., & Falotico, J. (2017). Predictive model of length of stay and discharge destination in neuroscience admissions. *Surgical Neurology International* 8(17).
- Steen, O., Pope, A., Rauner, M., Holmberg, N., Woodworth, S., O’Riordan, S., Niessner, H., & Nevill, K. (2017). A comprehensive decision support system for enhanced emergency decision management and training. In: Murayama Y., Velez D., Zlateva P., Gonzalez J. (eds) *Information Technology in Disaster Risk Reduction. IFIP Advances in Information and Communication Technology* 501. Springer, Cham.
- Sung, H.H., & Seong H.J. (2010). A hybrid data mining method for the medical classification of chest pain. *International Journal of Computer and Information Engineering* 4, 33-38.
- Szepesvári, C. (2010). Algorithms for reinforcement learning. *Synthesis Lectures on Artificial Intelligence and Machine Learning*, Morgan & Claypool Publishers.
- Taboada, M., Cabrera, E., & Luque, E. (2011). A Decision support system for hospital emergency departments built using agent-based techniques. In: Demazeau Y., Pěchouček M., Corchado J.M., Pérez J.B. (eds) *Advances on Practical Applications of Agents and Multiagent Systems. Advances in Intelligent and Soft Computing* 88, Springer, Berlin, Heidelberg.
- Trunkey, D.D. (2007). The emerging crisis in trauma care: a history and definition of the problem. *Clin Neurosurg* 54, 200-205.
- Trybula, W. (1997). Data Mining and Knowledge Discovery. *Annual Review of Information and Technology* 32, 197-229.
- Van de Walle, B., & Turoff, M. (2008). Decision support for emergency situations. Handbook on Decision Support Systems 2. *International Handbooks Information System*. Springer, Berlin, Heidelberg.
- Veyre, A.V. (2009). Les motifs de recours aux urgences pédiatriques : étude prospective menée pendant l’hiver 2006 au CHY du Kremlin-Bicêtre. Thèse de Doctorat, Université Paris 7 – Denis Diderot.
- Walczak, S., Scorpio, R.J., & Pofahl, W.E. (1998). Predicting hospital length of stay with neural network. *Proceedings of the Eleventh International FLAIRS Conference*.
- Walczak, S., & Scharf, J.E. (2000). Reducing surgical patient costs through use of an artificial neural network to predict transfusion requirements. *Decision Support Systems* 30, 125-138.
- Walczak, S., Pofahl, W.E., & Scorpio, R.J. (2003). A decision support tool for allocating hospital bed resources and determining required acuity of care. *Decision Support Systems* 34(4), 445-456. [https://doi.org/10.1016/S0167-9236\(02\)00071-4](https://doi.org/10.1016/S0167-9236(02)00071-4)
- Witten, I.H., Frank, E., & Hall, M.A. (2011). *Data Mining: Practical Machine Learning Tools and Techniques*. Morgan Kaufmann Publishers Inc., San Francisco.
- Xiang, Y., & Zhuang, J. (2016). A medical resource allocation model for serving emergency victims with deteriorating health conditions. *Annals of Operations Research* 236, 177-196.
- Yu, L., & Liu, H. (2003). Feature selection for high-dimensional data: A fast correlation-based filter solution. In Fawcett T., Mishra N. (eds) *Proceedings, Twentieth International Conference on Machine Learning* 2, 856-863.

- Zeinali, F., Mahootchi, M., & Sepehri, M.M. (2015). Resource planning in the emergency departments: A simulation-based metamodeling approach. *Simulation Modelling Practice and Theory* 53, 123-138.
- Zhang, Y. (2018). Constructing knowledge base of emergency based on hierarchical rough set theory. *Procedia Computer Science* 131, 699-705.
- Zhang, S., Zhang, C., & Yang, Q. (2003). Data preparation for data mining. *Applied Artificial Intelligence* 17, 375-381.
- Zhang, J., Zhang, M., Ren, F., & Liu, J. (2016). An innovation approach for optimal resource allocation in emergency management. *IEEE Transactions on Computers*.
- Zhao, Y., & Zhang, Y. (2008). Comparison of decision tree methods for finding active objects. *Advances in Space Research* 41, 1955-1959.
- Zhu, X., & Goldberg, A.B. (2009). Introduction to semi-supervised learning. *Synthesis Lectures on Artificial Intelligence and Machine Learning* 3(1), 1-130.

Résumé

Quotidiennement, au niveau du service des urgences pédiatriques, les enfants sont souvent confrontés à des détresses vitales. L'insuffisance des structures d'accueil par rapport à la fréquence des arrivées des cas d'urgence et le manque en moyens thérapeutiques et de diagnostique causent d'importants problèmes qui justifient l'intérêt d'étudier la prise en charge des urgences médicales qui peut être considérée comme un processus d'aide à la décision destiné à améliorer les services de santé. Le personnel hospitalier et les urgentistes manquent d'outils pour faire face à de telles situations. Ces outils sont primordiaux pour gérer les ressources humaines et matérielles du service des urgences ainsi que pour la planification de la prise en charge de celles-ci. En réponse à ces besoins, et dans le cadre de cette thèse, nous proposons une démarche d'aide à la prise en charge des urgences guidée par apprentissage automatique.

Mots clés

Aide à la décision médicale ; Apprentissage automatique ; Fouille de données ; Planification ; Urgences pédiatriques ; détresses vitales ; intelligence artificielle ; services de santé ; modélisation des données ; modèles de prédiction.

Soutenue le 20/01/2022

Mention très honorables