

UNIVERSITÉ DU QUÉBEC À MONTRÉAL

ANALYSE ET PRÉDICTION DES DÉLAIS D'ADMISSION DES PATIENTS À L'URGENCE DE L'HÔPITAL
DE LA CITÉ-DE-LA-SANTÉ DE LAVAL

MÉMOIRE

PRÉSENTÉ

COMME EXIGENCE PARTIELLE

MAÎTRISE ÈS SCIENCES TECHNOLOGIE DE L'INFORMATION

PAR

NEJIB KACHROUDI

SEPTEMBRE 2025

UNIVERSITÉ DU QUÉBEC À MONTRÉAL
Service des bibliothèques

Avertissement

La diffusion de ce mémoire se fait dans le respect des droits de son auteur, qui a signé le formulaire *Autorisation de reproduire et de diffuser un travail de recherche de cycles supérieurs* (SDU-522 – Rév.12-2023). Cette autorisation stipule que «conformément à l'article 11 du Règlement no 8 des études de cycles supérieurs, [l'auteur] concède à l'Université du Québec à Montréal une licence non exclusive d'utilisation et de publication de la totalité ou d'une partie importante de [son] travail de recherche pour des fins pédagogiques et non commerciales. Plus précisément, [l'auteur] autorise l'Université du Québec à Montréal à reproduire, diffuser, prêter, distribuer ou vendre des copies de [son] travail de recherche à des fins non commerciales sur quelque support que ce soit, y compris l'Internet. Cette licence et cette autorisation n'entraînent pas une renonciation de [la] part [de l'auteur] à [ses] droits moraux ni à [ses] droits de propriété intellectuelle. Sauf entente contraire, [l'auteur] conserve la liberté de diffuser et de commercialiser ou non ce travail dont [il] possède un exemplaire.»

REMERCIEMENTS

Je tiens à exprimer mes sincères remerciements à mon directeur de recherche, le professeur Janosh Ortmann, pour son encadrement et ses précieux conseils tout au long de ce projet. Je remercie également toute l'équipe de l'Infocentre, en particulier Michel Lefrançois, France Brisebois et Patrick Ripeau, pour leur soutien et leur collaboration. Enfin, je souhaite exprimer ma profonde gratitude au docteur Patrick Tardif de l'hôpital de la cité-de-la-santé de Laval pour son aide précieuse et sa contribution significative à mon projet de recherche.

Je tiens à exprimer ma profonde gratitude à ma famille, qui m'a soutenu(e) tout au long de ce parcours. Votre amour, votre patience et votre encouragement inébranlable ont été une source précieuse de motivation.

À mes parents, qui ont toujours cru en moi et m'ont encouragé à poursuivre mes études, merci pour votre soutien. Vos prières et votre bienveillance m'ont permis d'aller au bout de ce projet avec confiance et sérénité.

À mes frères et sœurs, dont les encouragements ont été une véritable force, je vous remercie pour votre soutien moral et vos mots réconfortants dans les moments difficiles.

DÉDICACE

À mes parents,

Qui m'ont toujours soutenu avec amour, dévouement et encouragement dans toutes les étapes de ma vie. Votre confiance et vos sacrifices ont été une source constante d'inspiration pour atteindre cet objectif.

À ma petite famille (mon épouse et mes filles Noujoud et Mayar),

Pour leur bienveillance, leur patience et leur amour inconditionnel. Votre soutien quotidien, vos encouragements et votre compréhension ont rendu ce chemin plus léger et enrichissant. Vous êtes ma plus grande source de motivation et de bonheur.

À mes frères et sœurs,

Pour leur soutien constant, leur écoute attentive et leur présence indéfectible. Vous avez toujours su être là dans les moments de doute et de joie, m'aidant à avancer avec sérénité et confiance.

AVANT-PROPOS

Ce mémoire est le fruit de plusieurs années d'études, de réflexion et de travail intense. Depuis le début de mon parcours académique, j'ai toujours été fasciné par les outils d'intelligence d'affaires (BI) et leur apport dans le système de santé, un sujet qui soulève des questions complexes et passionnantes, tout en ayant un impact significatif dans les domaines professionnels et académiques.

L'idée de cette recherche est née de ma volonté de contribuer à une meilleure compréhension des processus liés à la gestion des patients à l'urgence. Ce travail s'inscrit dans le cadre de mon programme de maîtrise en technologies de l'information, avec le soutien précieux de la direction du département d'analytique, opérations et technologies d'information (AOTI).

Je tiens à exprimer ma gratitude envers toutes les personnes qui m'ont guidé, soutenu et inspiré tout au long de mes recherches. Ce mémoire n'aurait pas vu le jour sans leur précieuse collaboration et leur encouragement constant. Enfin, je dédie ce travail à tous ceux qui partagent une passion similaire pour l'amélioration des systèmes de santé grâce aux outils d'intelligence d'affaires (BI).

TABLE DES MATIÈRES

DÉDICACE	iii
AVANT-PROPOS	iv
TABLE DES MATIÈRES	v
LISTE DES FIGURES.....	xi
LISTE DES TABLEAUX	xv
LISTE DES ABRÉVIATIONS, DES SIGLES ET DES ACRONYMES.....	xvi
LISTE DES MOTS CLÉS	xvii
RÉSUMÉ	xviii
ABSTRACT	xix
INTRODUCTION	20
CHAPITRE 1 PROBLÉMATIQUE, QUESTIONS ET OBJECTIFS DE RECHERCHE.....	25
1.1 Introduction à la problématique générale.....	25
1.1.1 Problématique générale	25
1.1.2 Cas spécifique : l'hôpital de la cité-de-la-santé de Laval	27
1.2 Objectif de recherche.....	28
1.3 Question de recherche.....	28
1.4 Portée du projet de recherche	30
1.5 Conclusion	30
CHAPITRE 2 ÉTAT DE L'ART.....	31
2.1 Introduction	31
2.2 Définition et mesure de la durée moyenne de séjour des patients sur civière à l'urgence	32
2.2.1 Définition de la durée moyenne de séjour des patients sur civière à l'urgence	32
2.2.2 Comment mesurer la durée moyenne de séjour des patients sur civière à l'urgence.....	32
2.3 Éléments affectant la durée moyenne de séjour des patients sur civière.....	33
2.3.1 Patient en attente d'une consultation avec un médecin spécialiste.....	33
2.3.2 Patient en attente des examens complémentaires (Imagerie)	33
2.3.3 Patient en attente d'hospitalisation	33
2.3.4 Patient en attente d'une chirurgie	34
2.4 Méthode analytique des données	34
2.4.1 Définition et différents modèles d'analytique de données.....	34

2.4.2	Définition de l'analyse descriptive.....	35
2.4.3	Définition de l'analyse prédictive	36
2.4.4	Différentes méthodes de prédiction.....	36
2.4.5	Différents algorithmes d'apprentissage automatique.....	37
2.4.5.1	La régression linéaire	38
2.4.5.2	Le modèle K-Nearest Neighbours (KNN)	38
2.4.5.3	Arbre de décision.....	38
2.4.5.4	Les forêts de décision ou les forêts aléatoires (Random Forests)	39
2.4.5.5	Les séries temporelles	39
2.4.5.6	Les réseaux neuronaux	39
2.4.6	Définition de l'analyse prescriptive	39
2.5	Utilité de l'analytique de données aux urgences et aux hôpitaux.....	40
2.5.1	Lien entre l'analytique de données et les besoins de l'hôpital	40
2.5.2	Utilité de l'analyse descriptive aux urgences et aux hôpitaux.....	40
2.5.3	Utilité de l'analyse prédictive aux urgences et aux hôpitaux	41
2.5.4	Utilité de l'apprentissage automatique supervisé aux urgences et aux hôpitaux.....	42
2.5.5	Utilité de la régression linéaire aux urgences et aux hôpitaux.....	42
2.5.6	Utilité de Modèle KNN aux urgences et aux hôpitaux.....	43
2.5.7	Utilité de l'arbre de décision aux urgences et aux hôpitaux	43
2.5.8	Utilité des forêts d'arbres décisionnels aux urgences et aux hôpitaux	43
2.5.9	Utilité des séries temporelles aux urgences et aux hôpitaux	43
2.5.10	Utilité des réseaux neuronaux aux urgences et aux hôpitaux.....	43
2.5.11	Utilité de l'analyse prescriptive au service des urgences et aux hôpitaux	44
2.6	Synthèse critique.....	44
2.7	Application des méthodes analytiques au contexte de l'Hôpital de la Cité-de-la-Santé de Laval.....	44
2.8	Conclusion	44
CHAPITRE 3 DÉMARCHE MÉTHODOLOGIQUE DE RECHERCHE		45
3.1	But et pertinence du projet	45
3.1.1	But du projet.....	45
3.1.2	Pertinence pour le Projet.....	45
3.1.3	Critères de Succès/Évaluation	45
3.2	Présentation de démarche méthodologique	46
3.2.1	Choix méthodologique.....	46
3.2.2	L'approche méthodologique.....	47
3.3	Collecte de données.....	48
3.3.1	Période d'étude et population.....	48
3.3.2	Échantillon	48
3.4	Les systèmes d'information organisationnels.....	49
3.4.1	Les différents systèmes d'information	49
3.4.2	Les données utilisées pour le tableau de bord (Variables et Mesures)	49
3.4.2.1	Critères de sélection des variables	49
3.4.2.2	Mesures dérivées.....	50

3.4.3	Analyse critique.....	51
3.4.4	Lien opérationnel.....	51
3.5	Outil de collecte de données	51
3.6	Test de robustesse de l'outil	52
3.7	Confidentialité des données	52
3.8	Certificat d'éthique	53
3.9	Instruments de mesure	53
3.10	Analyse de données	54
3.10.1	Tableau de bord descriptif : Évaluation de l'état de l'urgence selon la DMS.....	54
3.10.2	Variables et mesures.....	54
3.10.3	Développement des modèles prédictifs.....	55
3.10.3.1	Qualité des données utilisées	55
3.10.3.2	Étapes implémentation en Python	55
3.10.3.3	Objectifs et avantages	56
3.10.4	Modèle prescriptif d'aide à la décision.....	56
3.11	Conclusion.....	57
CHAPITRE 4 IMPLÉMENTATION ET ANALYSE DES RÉSULTATS DU TABLEAU DE BORD DESCRIPTIF		58
4.1	Présentation du tableau de bord descriptif pour la DMS des patients à l'urgence.....	58
4.2	Répartition de la durée moyenne de séjour des patients à l'urgence.....	58
4.2.1	Sommaire global de la durée de séjour des patients à l'urgence.....	58
4.2.2	Répartition détaillée de la DMS sur civière en 2023	60
4.2.3	Répartition détaillée de la DMS sur civière en 2022	62
4.2.4	Répartition détaillée de la DMS sur civière en 2021	63
4.2.5	Répartition de la DMS des patients sur civière selon le type d'orientation	63
4.2.6	Répartition de la DMS des patients sur civière selon la priorité	64
4.2.7	Répartition de la DMS des patients sur civière par groupe d'âge	66
4.3	Distribution de la DMS sur civière.....	67
4.3.1	Courbe loi normale	67
4.3.2	Courbe loi exponentielle.....	68
4.3.3	Boîte à moustache	70
4.3.4	Distribution de la durée de séjour des patients à l'urgence par intervalle — Test ANOVA	71
4.3.5	Distribution de la durée de séjour des patients à l'urgence par priorité — Test ANOVA	72
4.3.6	Distribution de la durée de séjour des patients à l'urgence par orientation — Test ANOVA	74
4.4	Comparaison entre la durée moyenne et la durée médiane de séjour des patients sur civière à l'urgence.....	76
4.4.1	Analyse détaillée pour l'année 2023	76
4.5	Distribution de la DMS en fonction des différents délais d'attente	79
4.5.1	Distribution globale de la DMS en fonction de différents délais d'attente	79
4.5.2	Distribution de la DMS des patients en fonction des différents délais d'attente par plage horaire 80	
4.5.2.1	Plage horaire : 0 h à 7 h	81

4.5.2.2	Plage horaire : 7 h à 16 h	82
4.5.2.3	Plage horaire : 16 h à minuit.....	84
4.6	Analyse du délai d'attente des consultations spécialisées	86
4.6.1	Sommaire global de l'attente des consultations spécialisées	86
4.6.2	Analyse détaillée du délai d'attente des consultations spécialisées — décembre 2023	86
4.6.3	Distribution du délai d'attente des consultations spécialisées (loi normale).....	87
4.6.3.1	Distribution des valeurs avec ajustement exponentiel	88
4.6.3.2	Boîte à Moustache	89
4.6.4	Corrélation entre le délai d'attente des consultations spécialisées et la DMS sur civière.....	90
4.6.5	Corrélation entre le temps d'attente pour des consultations spécialisées par spécialité et la DMS sur civière	93
4.6.6	Test ANOVA sur le délai d'attente des consultations spécialisées	95
4.7	Analyse du délai d'attente à l'hospitalisation.....	97
4.7.1	Sommaire global du délai d'attente pour l'hospitalisation	97
4.7.2	Distribution du délai d'attente pour l'hospitalisation	100
4.7.2.1	Courbe Loi normale	100
4.7.2.2	Courbe loi exponentielle.....	101
4.7.2.3	Boîte à moustache	103
4.7.3	Corrélation entre le délai d'attente à l'hospitalisation et la DMS sur civière.....	104
4.7.4	Corrélation entre le délai d'attente à l'hospitalisation et la DMS sur civière selon la spécialité	106
4.7.5	Analyse de la variance du délai d'attente à l'hospitalisation selon la spécialité des patients sur civière	108
4.8	Analyse du délai d'attente pour les examens d'imagerie.....	110
4.8.1	Sommaire global du délai d'attente pour les examens d'imagerie	110
4.8.2	Distribution du délai d'attente pour les examens d'imagerie	112
4.8.2.1	Représentation des distributions selon la loi normale et la loi exponentielle	112
4.8.2.2	Représentation en boîte à moustaches.....	113
4.8.3	Analyse de la corrélation entre le délai d'attente des examens d'imagerie et la DMS sur civière	113
4.8.4	Analyse de la corrélation selon le type d'examen d'imagerie	114
4.8.5	Analyse de la variance des demandes d'examens d'imagerie.....	116
4.9	Analyse du nombre d'infirmières en relation avec la DMS des patients sur civière	117
4.9.1	Répartition du nombre d'infirmières selon la DMS des patients sur civière.....	117
4.9.2	Analyse de la corrélation entre le nombre d'infirmières et la DMS des patients sur civière	118
4.10	Analyse du nombre de médecins en relation avec la DMS.....	120
4.10.1	Répartition du nombre de médecins en fonction de la DMS	120
4.11	Analyse des chevauchements des flux de patients à l'urgence	121
4.12	Principaux constats observés sur la DMS des patients à l'urgence (2021-2023).....	122
4.13	Conclusion	123
CHAPITRE 5 IMPLÉMENTATION DE MODÈLES PRÉDICTIFS		125
5.1	Préparation et création de variables de prédiction	125

5.1.1	Variables des patients	125
5.1.2	Variables de triage à l'urgence	125
5.1.3	Les signes vitaux.....	126
5.1.4	Variables de l'historique de l'urgence	127
5.1.5	Historique d'hospitalisation	129
5.2	Évaluation des modèles pour la prédiction.....	129
5.2.1	Ajustement du modèle	129
5.2.2	Évaluation globale.....	130
5.2.3	Évaluation en temps réel	131
5.3	Modélisation	131
5.3.1	Préparation des données.....	131
5.3.2	Gestion des valeurs manquantes.....	132
5.3.3	Encodage des variables catégorielles	133
5.3.4	Processus de prédiction	135
5.4	Performance des modèles spécifiques	136
5.4.1	Modèle de régression linéaire	136
5.4.2	Régression logistique	137
5.4.3	Modèle KNN.....	139
5.4.4	Modèle Arbre de décision.....	139
5.4.5	Modèle de gradient de Boosting Regressor	140
5.4.6	Modèle de forêt aléatoire (RF)	141
5.5	Comparaison des performances des modèles	142
5.5.1	Choix retenus et justification	143
5.6	Tableau de bord prédictif.....	143
5.6.1	Création de modèles.....	143
5.6.2	Collecte de données.....	144
5.6.3	Exécution et prédiction.....	144
5.6.4	Visualisation des données.....	145
5.7	Architecture de la solution.....	145
5.8	Conclusion	146
CHAPITRE 6 ANALYSE CRITIQUES DE RÉSULTATS		147
6.1	Analyse de la distribution des erreurs de prédiction	147
6.1.1	Analyse des erreurs brutes	147
6.1.2	Analyse des erreurs absolues	148
6.1.3	Impact de la profondeur maximale des arbres de décision sur l'erreur absolue moyenne (MAE)	149
6.1.4	Analyse des erreurs résiduelles	150
6.2	Analyse des corrélations entre les variables.....	151
6.3	Identification des variables importantes	151
6.4	Analyse des résultats pour la probabilité d'admission en service	153
6.4.1	Analyse des résultats de la matrice de confusion.....	153

6.4.2	Évaluation de la précision des résultats.....	154
6.4.3	Analyse de la probabilité moyenne d'admission par service	155
6.5	Performance du modèle	156
6.6	Limite de l'analyse prédictive.....	156
6.7	Implications pratiques de l'analyse prédictive.....	157
6.8	Conclusion	157
CONCLUSION		158
ANNEXE A Liste des captures d'écran des trajectoires des patients.....		166
ANNEXE B Liste des captures d'écran du tableau de bord de la DQEPE — Service de l'Infocentre, l'hôpital de la cité-de-la-santé de Laval.....		170
ANNEXE C Liste des captures d'écran des tableaux de bord de l'Index Santé du MSSS du Québec		172
ANNEXE D Liste des captures d'écran des tableaux de l'Institut canadien d'information sur la santé		176
ANNEXE E Liste des captures d'écran du modèle analytique		177
ANNEXE F Les principaux jeux de données pour le développement du projet sur la DMS		178
ANNEXE G Certificat d'éthique.....		183
ANNEXE H Formulaire d'approbation organisationnelle à l'utilisation des données d'entreprise.....		184
ANNEXE I Architecture de la solution.....		186
RÉFÉRENCES		187
BIBLIOGRAPHIE.....		188

LISTE DES FIGURES

Figure 4.1 sommaire globale de la durée de séjour des patients à l'urgence	59
Figure 4.2 sommaire globale de la durée de séjour des patients à l'urgence	60
Figure 4.3 Répartition de la DMS des patients sur civière - décembre 2023	61
Figure 4.4 Répartition de la DMS des patients sur civière - juillet 2023	61
Figure 4.5 Répartition de la DMS des patients sur civière en 2022	62
Figure 4.6 Répartition de la DMS des patients sur civière - octobre 2022	62
Figure 4.7 Répartition de la DMS des patients sur civière - février 2022.....	63
Figure 4.8 Répartition de la DMS des patients sur civière en 2021	63
Figure 4.9 Répartition par type d'orientation « Retour à Domicile ».....	64
Figure 4.10 Répartition par type d'orientation « Admission Hospitalisation ».....	64
Figure 4.11 Répartition détaillée de la DMS sur civière selon les niveaux de priorité.....	65
Figure 4.12 Répartition détaillée de la DMS sur civière selon les groupes d'âge de 1 à 60 ans	66
Figure 4.13 Répartition détaillée de la DMS sur civière selon les groupes d'âge de 60 ans et plus	67
Figure 4.14 Courbe loi normale de la distribution de la DMS des patients sur civière.....	67
Figure 4.15 Courbe loi normale distribution de la DMS sur civière par rapport à la DMS totale à l'urgence IQR=1.5	68
Figure 4.16 Courbe Loi exponentielle : Distribution de la DMS des patients sur civière	69
Figure 4.17 Courbe Loi exponentielle : Distribution de la DMS des patients sur civière IQR=1.5	69
Figure 4.18 Boîte à moustaches de la DMS des patients sur civière à l'urgence	70
Figure 4.19 Distribution de la DMS des patients sur civière à l'urgence par intervalle	72
Figure 4.20 Distribution de la DMS des patients sur civière par Priorité	73
Figure 4.21 Distribution de la DMS des patients sur civière par Priorité IQR =1,5	73
Figure 4.22 Distribution de la DMS des patients sur civière à l'urgence par Orientation.....	75
Figure 4.23 Distribution de la DMS des patients sur civière à l'urgence par Orientation.....	76

Figure 4.24 Comparaison entre la durée moyenne et la durée médiane de séjour à l'urgence 2023	77
Figure 4.25 Comparaison entre la DMS et la durée médiane de séjour des patients — décembre 2023..	77
Figure 4.26 Liste des durées plus longues (valeurs aberrantes)	78
Figure 4.27 Distribution de la DMS en fonction des délais d'attente	80
Figure 4.28 Distribution de la DMS par rapport aux délais d'attente (plage horaire : 00h-07h).....	82
Figure 4.29 Distribution de la DMS en fonction des délais d'attente (plage horaire : 07h-16h)	84
Figure 4.30 Distribution de la DMS en fonction des délais d'attente (plage horaire : 16 h->minuit).....	85
Figure 4.31 Délai d'attente des consultations spécialisées.....	86
Figure 4.32 Délais d'attente des consultations spécialisées — décembre 2023	87
Figure 4.33 Distribution du délai d'attente des consultations spécialisées (Loi normale)	88
Figure 4.34 Distribution du délai d'attente des consultations spécialisées (Loi exponentielle).....	88
Figure 4.35 Distribution du délai d'attente des consultations spécialisées.....	89
Figure 4.36 Corrélation entre le temps d'attente des consultations spécialisées et la DMS des patients sur civière	90
Figure 4.37 Corrélation entre le temps d'attente des consultations spécialisées et la DMS sur civière donnée nettoyée IQR=2.5	91
Figure 4.38 Corrélation annuelle entre le temps d'attente des consultations spécialisées et la DMS sur civière	92
Figure 4.39 Corrélation entre le temps d'attente des consultations spécialisées et la DMS sur civière par année donnée nettoyée IQR=2.5	93
Figure 4.40 Corrélation entre le temps d'attente pour des consultations spécialisées par spécialité et la DMS sur civière.....	94
Figure 4.41 Corrélation entre le temps d'attente pour des consultations spécialisées par spécialité et la DMS sur civière (données nettoyées IQR=1.5).....	95
Figure 4.42 Test ANOVA sur le délai d'attente pour des consultations spécialisées	96
Figure 4.43 Test ANOVA sur le délai d'attente des consultations spécialisées (IQR = 1,5).....	97
Figure 4.44 Sommaire global du délai d'attente pour l'hospitalisation.....	98
Figure 4.45 Tendance du délai d'attente à l'hospitalisation (exemple : décembre 2023).....	100

Figure 4.46 Distribution du délai d'attente pour l'hospitalisation (Loi normale)	101
Figure 4.47 Distribution du délai d'attente d'hospitalisation (Loi exponentielle)	102
Figure 4.48 Distribution du délai d'attente pour l'hospitalisation.....	103
Figure 4.49 Distribution du délai d'attente pour l'hospitalisation (données nettoyées, IQR = 1,5)	104
Figure 4.50 corrélation entre le délai d'attente à l'hospitalisation et la DMS sur civière	105
Figure 4.51 Corrélation entre le délai d'attente à l'hospitalisation et la DMS sur civière (Z-score ≤ 3) ...	106
Figure 4.52 Corrélation entre le délai d'attente à l'hospitalisation et la DMS sur civière par spécialité..	107
Figure 4.53 Corrélation entre le délai d'attente à l'hospitalisation et la DMS sur civière par spécialité (Z-score ≤ 3)	108
Figure 4.54 Test ANOVA du délai d'attente à l'hospitalisation selon la spécialité	109
Figure 4.55 Test ANOVA du délai d'attente à l'hospitalisation selon la spécialité	110
Figure 4.56 Sommaire global du délai d'attente pour les examens d'imagerie	111
Figure 4.57 Distribution du délai d'attente pour les examens d'imagerie selon la loi exponentielle	112
Figure 4.58 Distribution du délai d'attente des examens d'imagerie.....	113
Figure 4.59 Corrélation de délai d'attente des examens d'imagerie	114
Figure 4.60 Corrélation selon le type d'examen d'imagerie	115
Figure 4.61 Corrélation par type d'examen d'imagerie IQR 1.5.....	116
Figure 4.62 Corrélation selon type d'examen d'imagerie après nettoyage des données (IQR =1,5)	117
Figure 4.63 Analyse du nombre d'infirmières en fonction de la DMS	118
Figure 4.64 Corrélation entre le nombre d'infirmières et la DMS des patients sur civière	119
Figure 4.65 Distribution de la durée de séjour sur civière en fonction du nombre d'infirmiers	119
Figure 4.66 Nombre de médecins par intervalle par jour	121
Figure 4.67 Analyse des chevauchements des flux de patients à l'urgence	122
Figure 5.1 Processus de prédiction	131
Figure 5.2 Résultats de la régression logistique	138
Figure 5.3 Résultats du modèle KNN.....	139

Figure 5.4 Résultats de l'arbre de décision	140
Figure 5.5 Résultats du modèle de gradient de Boosting Regressor	141
Figure 5.6 Résultats du modèle de forêt aléatoire.....	142
Figure 5.7 Tableau de bord prédictive	145
Figure 6.1 Distribution des erreurs brutes	148
Figure 6.2 Distribution des erreurs absolues	149
Figure 6.3 Impact de la profondeur maximale des arbres de décision sur l'erreur absolue moyenne	150
Figure 6.4 Valeurs prédite par rapport aux valeurs réelles.....	150
Figure 6.5 Poids des caractéristiques dans la prédiction	152
Figure 6.6 Matrice de confusion pour l'évaluation de la probabilité d'admission	154
Figure 6.7 Résultats de précision de la probabilité d'admission en service.....	155
Figure 6.8 Probabilité moyenne d'admission par service	156

LISTE DES TABLEAUX

Tableau 4.1 principaux constats observés sur la DMS des patients à l’urgence (2021-2023)	123
Tableau 5.1 variables associées au patient	125
Tableau 5.2 variable de triage de patient à l’urgence.....	126
Tableau 5.3 les signes vitaux	127
Tableau 5.4 variable de l’historique à l’urgence	128
Tableau 5.5 variable de l’historique d’hospitalisation	129
Tableau 5.6 Gestion des valeurs manquantes pour les signes vitaux.....	132
Tableau 5.7 Regroupement mode d’arrivée	133
Tableau 5.8 Regroupement par orientation	133
Tableau 5.9 Regroupement des diagnostics	134
Tableau 5.10 Regroupement des codes de raison de la visite	135
Tableau 5.11 Résultats de modèle régression linéaire	136
Tableau 5.12 les variables les plus fortement corrélées avec durée de séjour	137
Tableau 5.13 Résultats de modèle régression Ridge	137
Tableau 6.1 les dix principales corrélations avec la durée de séjour	151

LISTE DES ABRÉVIATIONS, DES SIGLES ET DES ACRONYMES

ADT : Admission, Départ, Transfert.

ANOVA : Analyse de la variance

CHSLD : Centre d'Hébergement des Soins de Longue Durée.

CHU : Centre hospitalier universitaire.

CHGE : Chirurgie générale.

CISSS de Laval : Centre Intégré de Santé et de Services sociaux de Laval.

DMS : Durée moyenne de séjour.

DQEPE : Direction de la Qualité, Évaluation, Performance et Éthique.

DSI : Direction des Soins infirmiers.

EPTC : Éthique de la recherche avec des êtres humains

IEDM : Institut Économique de Montréal.

IQR : Intervalle interquartile ou écart interquartile

KNN: k plus proches voisins

LOS : Length of Stay (durée du séjour)

MAE : Moyenne absolue d'erreur.

MF : Médecin de Famille.

MSE : Mean Square Error (carré moyen des erreurs)

MSSS : ministère de la Santé et des Services sociaux.

NEURO : Neurologie.

OECD : Organisation de coopération et de développement économiques.

ORTHO : Orthopédie.

P1 : Priorité 1, prise en charge immédiate (réanimation).

P2 : Priorité 2, prise en charge moins de 15 minutes (très urgent).

P3 : Priorité 3, prise en charge en moins de 30 minutes (urgent).

P4 : Priorité 4, prise en charge en moins de 60 minutes (moins urgent).

P5 : Priorité 5, prise en charge en moins de 120 minutes (non Urgent).

RMSE : racine carrée de l'erreur quadratique moyenne.

R²: Coefficient de détermination,

RPA : Résidence privée pour les aînés.

TI : Technologie de l'Information.

LISTE DES MOTS CLÉS

Patient, temps d'attente, délai moyen de séjour, civière, urgence, hôpital, hospitalisation, examens médicaux complémentaires, consultation d'un médecin spécialiste, admission à l'hôpital, imagerie, descriptive, prédictive, prescriptive, apprentissage automatique supervisé, quantitatif, flux de patients, programmation linéaire, forage de données, Test ANOVA.

RÉSUMÉ

Introduction : Ce projet de recherche, réalisé dans le cadre de ma maîtrise en technologies de l'information, étudie l'utilisation des outils d'intelligence d'affaires (BI) pour optimiser la gestion des processus des patients à l'urgence de l'Hôpital de la Cité de la Santé à Laval. L'objectif principal étant d'identifier les facteurs influençant la durée de séjour des patients sur civière à l'urgence et de proposer des solutions pour améliorer les flux de patients et l'allocation des ressources. La durée moyenne de séjour (DMS) constitue un indicateur clé de la performance du système de santé. Ce projet repose sur une combinaison d'analyses descriptives, prédictives et prescriptives, renforcées par des tableaux de bord interactifs pour soutenir la prise de décision. Les données analysées couvrent une période de trois ans (janvier 2021 à décembre 2023).

Méthodes : Une approche analytique a été adoptée pour étudier la DMS des patients sur civière. L'analyse descriptive a permis de dresser un état des lieux des processus actuels, tandis que l'analyse prédictive a été employée pour anticiper la DMS des patients en temps réel. Enfin, une analyse prescriptive a été développée pour fournir des recommandations stratégiques aux gestionnaires hospitaliers. Les données ont été collectées à partir de trois systèmes d'information : *Medurg* (urgence), *Radimag* (imagerie) et *Clinibase-CI* (hospitalisation).

Résultats : Selon l'analyse ANOVA, les analyses ont identifié les principaux goulots d'étranglement, notamment les délais d'attente pour l'admission hospitalière, les consultations spécialisées et les examens d'imagerie, qui contribuent significativement à la prolongation de la DMS. Les patients en psychiatrie présentent les durées de séjour les plus longues. Le modèle prédictif de forêt aléatoire a atteint une précision de 78 %, confirmant sa capacité à anticiper la DMS.

Conclusion : Ce projet démontre que l'intégration des outils d'intelligence d'affaires (BI) peut significativement améliorer la gestion des flux de patients et réduire les temps d'attente aux urgences. Les solutions préconisées incluent l'optimisation des processus d'admission, la réaffectation des ressources et l'utilisation de modèles prédictifs pour une gestion proactive. Ces résultats offrent une base solide pour la mise en œuvre de stratégies visant à améliorer l'efficacité du système de santé tout en augmentant la satisfaction des patients.

Mots-clés : La durée de séjour des patients sur civière, Intelligence d'affaires, Analyse descriptive, Analyse prédictive, Urgence, Hospitalisation, Imagerie, réduire les temps d'attente aux urgences.

ABSTRACT

Introduction: This research project, conducted as part of a master's degree in information technologies, explores the use of Business Intelligence (BI) tools to optimize patient flow management in the emergency department of « l'Hôpital de la Cité-de-la-Santé de Laval ». The primary goal is to identify factors influencing the length of stay (LOS) on stretchers in the emergency department and propose solutions to improve patient flow and resource allocation. LOS serves as a key performance indicator for the healthcare system. The project combines descriptive, predictive, and prescriptive analyses, supported by interactive dashboards to aid decision-making. The data analyzed spans three years (January 2021 to December 2023).

Methods: An analytical approach was used to study stretcher LOS. Descriptive analysis provided an overview of current processes, predictive analysis anticipated real-time LOS, and prescriptive analysis offered strategic recommendations for hospital managers. Data was collected from three information systems: Medurg (emergency), Radimag (imaging), and Clinibase CI (hospitalization).

Results: ANOVA analysis identified key bottlenecks, including delays in hospital admission, specialized consultations, and imaging exams, which significantly contribute to extended LOS. Patients in psychiatry and hematology had the longest stays. Predictive models, such as random forests, achieved 78% accuracy, confirming their ability to forecast LOS.

Conclusion: This project demonstrates that integrating BI tools can significantly enhance patient flow management and reduce emergency wait times. Proposed solutions include optimizing admission processes, reallocating resources, and leveraging predictive models for proactive management. These findings provide a robust foundation for implementing strategies to improve healthcare system efficiency and patient satisfaction.

Keywords: Patient stretcher length of stay, Business Intelligence, Descriptive analysis, Predictive analysis, Emergency, Hospitalization, Imaging, Reducing emergency wait times.

INTRODUCTION

Ce chapitre introduit le projet de recherche en en présentant les principaux éléments. Il débute par la mise en contexte du projet, suivie de la présentation du sujet de recherche. Les méthodes employées dans le cadre de l'étude y sont ensuite décrites. La structure du mémoire est ensuite exposée, avant d'expliquer les raisons pour lesquelles Santé Québec considère ce projet comme une initiative innovante. Le chapitre se conclut par un résumé synthétique du projet.

Mise en contexte : Le parcours d'un patient dans les services d'urgence se déroule en plusieurs étapes, souvent marquées par de longs temps d'attente (Annexe A — PA-1) (Appleby et al., 2005, p. 21). Notamment, l'attente des patients sur civière à l'urgence, cette attente constitue une préoccupation majeure dans le secteur de la santé, tant au niveau national qu'international.

L'article de Sørup *et al.* (2013), examine comment les temps d'attentes des patients sont utilisés comme indicateurs clés de performance dans les systèmes de soins de santé aux États-Unis, au Royaume-Uni et au Canada, soulignant leur importance pour évaluer l'efficacité des soins. Pour Driesen (2018), les causes de la durée prolongée de séjour aux urgences dans un hôpital universitaire aux Pays-Bas sont organisationnelles et hors du contrôle des services d'urgences.

Au Canada, l'engorgement des urgences découle principalement dans le transférer rapidement les patients admis vers des lits d'hospitalisation, phénomène amplifié par la forte présence de patients en niveau de soins alternatifs (ALC) faute de ressources en soins à domicile et en soins de longue durée. Les prises de position et synthèses récentes de l'Association canadienne des médecins d'urgence (CAEP) et les revues sur l'ALC confirment que le manque de lits en aval et l'insuffisance d'options de sortie sont des déterminants majeurs de la surcapacité aux urgences (Alecs *et al.*, 2023 ; Maisonnave *et al.*, 2024)

Au Québec, on a constaté que le temps d'attente dans les services d'urgences constitue un problème majeur. Selon Cousineau (2022), la durée moyenne d'attente des patients sur civière au Québec est de 17 heures. Le rapport de Déry (2019) mentionne que, malgré une diminution du nombre de patients visitant les urgences en 2018-2019, les temps d'attente ont augmenté. Il mentionne que le nombre de séjours de plus de 24 heures a connu une hausse significative (Annexe B- TB — 1).

L'institut économique de Montréal souligne un manque d'entrepreneuriat dans la gestion des hôpitaux, ce qui a contribué à l'augmentation des délais d'attente (Déry, 2018). Enfin, les données fournies par le site Index Santé du ministère de la Santé et des Services sociaux (MSSS) révèlent une situation alarmante dans les urgences des hôpitaux du Québec. Pour en montrer l'ampleur, nous avons examiné deux dates différentes. Premier exemple : le 2 janvier 2024, le taux d'occupation des urgences a atteint 137 % avec un délai moyen de séjour des patients sur civière de 18 heures et 44 minutes (Figure 1.3). Deuxième exemple : le 12 mars 2024, la durée moyenne de séjour des patients sur civière était de 16 heures et 59 minutes (Annexe B : SA-3). Selon Archambault (2022), les patients passent parfois plus de deux jours sur civière. Ce temps d'attente prolongé est attribué à un manque de lits d'hôpital et à une pénurie de personnel.

L'attente prolongée aux urgences peut aggraver l'état de santé des patients, dans certains cas, entraîner des décès, comme le rapporte Radio-Canada (2023b). Selon Perruche *et al.* (2008) ce temps d'attente cause du stress et de l'anxiété chez les patients et leurs proches. Le rapport de l'OECD (2023) indique que de réduire le temps d'attente, y compris dans les services d'urgence, améliore la qualité des soins et les résultats pour les patients. De même, Oberlin (2020) indique que l'engorgement des services d'urgence a un impact négatif sur la santé des patients et sur la qualité des soins.

Le temps d'attente des patients sur civière aux urgences, également appelé la durée moyenne de séjours des patients sur civière à l'urgence (DMS), correspond à la durée entre l'arrivée du patient, son évaluation, et son départ pour son admission ou son congé (Boulenger et Vaillancourt, 2013, p. 3).

Pour l'urgence de l'hôpital de la Cité-de-la-Santé de Laval, le site Index Santé du MSSS du Québec révèle un taux d'occupation de 137 % le 3 janvier 2024 (voir Annexe C : SA-4). Selon le tableau de bord de fluidité de la DQEPE, la DMS des patients sur civière était de 20,1 heures le 17 octobre 2023 (Annexe B: TB — 2). Selon Belaidi (2007), les données sur la DMS des patients aux urgences au Québec doivent être surveillées et analysées afin d'identifier les tendances, les points de pression et les domaines nécessitant des améliorations. L'auteur mentionne que la présentation régulière des données relatives aux services d'urgence est essentielle pour permettre aux décideurs d'élaborer des stratégies visant à améliorer l'efficacité du système de santé des urgences.

Dans ce contexte, les gestionnaires de l'hôpital de la Cité-de-la-Santé de Laval cherchent à améliorer le processus de parcours des patients à l'urgence, depuis leur arrivée jusqu'à leur congé ou leur admission, en réduisant le temps d'attente des patients sur civière (Belorgey, 2011).

Sujet de recherche : L'objectif principal de cette étude est d'examiner et d'analyser la durée moyenne de séjour (DMS) des patients sur civière à l'urgence de l'hôpital de la Cité-de-la-Santé de Laval. En menant une exploration approfondie pour mieux comprendre les défis auxquels est confrontée l'urgence de cet hôpital.

De plus, il s'agit d'identifier les opportunités d'optimisation de processus afin de garantir une durée de séjour plus efficace et des soins de qualité pour les patients sur civière aux urgences (Coutin et Vaucel, 2014). La DMS des patients sur civières à l'urgence est un indicateur critique de l'efficacité du système de santé, il impacte la qualité des soins et la satisfaction des patients, mais aussi la productivité ainsi que l'état de santé du personnel médical et paramédical (Lee *et al.*, 2022).

Pour cette étude, nous avons recueilli les données des patients ayant fréquenté l'urgence de l'hôpital de la Cité-de-la-Santé de Laval, et identifié les variables influençant la DMS des patients sur civière à l'urgence, sur une période allant du 1er janvier 2021 jusqu'à 31 décembre 2023.

Méthodes : L'article de Thompson et al. (2020), publié dans MIS Quarterly, met en lumière le rôle crucial des technologies de l'information (TI) et de l'analyse des données dans l'évolution des soins médicaux vers des approches moins intensives et plus axées sur la prévention. De même, l'article de Lin et al. (2017), publié dans MIS Quarterly, souligne l'importance de l'analytique des données pour améliorer la prise de décision clinique et favoriser des soins de santé préventifs et personnalisés.

Dans notre étude, nous avons donc adopté une méthodologie fondée sur l'analytique de données. Cette approche comprend plusieurs étapes distinctes pour améliorer le processus d'admission des patients à l'urgence. Premièrement, nous réaliserons une étude analytique descriptive pour détailler la DMS des patients sur civière à l'urgence. Nous développerons un tableau de bord descriptif pour analyser le système actuel et identifier les domaines nécessitant des améliorations (Carrier *et al.*, 1993 ; Da Costa *et al.*, 2022 ; K'ourio *et al.*, 2018). Deuxièmement, nous mènerons une étude analytique prédictive visant

à anticiper la DMS des patients sur civières à l'urgence chaque jour (Carter et Potts, 2014 ; Kadri *et al.*, 2014).

Enfin, nous réaliserons une analyse prescriptive permettant de formuler des recommandations destinées aux gestionnaires, notamment au directeur adjoint de la performance et de la qualité, ainsi qu'à la responsable du service de l'urgence, dans le but d'améliorer le processus d'admission des patients à l'urgence (Pettit *et al.*, 2024).

Pour pouvoir réaliser ces 3 étapes, nous collecterons des données sur les patients à partir de divers systèmes d'information : les données de l'urgence via *Medurg*, celles de l'imagerie via *Radimag*, et de l'hospitalisation via *Clinibase_CI*. Les horaires des infirmiers seront extraits du système *Espresso*, et les horaires des médecins proviendront du système *Pétal*.

Une fois les données collectées, nous procéderons au nettoyage et à la transformation des données, suivis de la validation de leur fiabilité en collaboration avec les pilotes des différents systèmes sources. Enfin, nous déterminerons les variables et les mesures nécessaires.

Structure du document : La description du projet de recherche sera détaillée dans les chapitres suivants :

- Chapitre 1 : Problématique, question de recherche, objectifs et portée de l'étude.
- Chapitre 2 : Revue de littérature.
- Chapitre 3 : Méthodologie, incluant les approches, outils et techniques utilisés.
- Chapitre 4 : Implémentation et analyse du tableau de bord descriptif.
- Chapitre 5 : Implémentation et paramétrage des modèles prédictifs.
- Chapitre 6 : Analyse critique des résultats du modèle prédictif.
- Conclusion : Synthèse des contributions, limites et recommandations.

Le schéma des étapes de recherche (Annexe A — PA-2) illustre le processus suivi pour cette étude.

Projet d'innovation : Ce projet a été reconnu comme une initiative d'innovation par la Direction de l'intelligence d'affaires et de l'analytique avancée de Santé Québec, en raison de son approche novatrice dans l'optimisation des séjours des patients sur civière à l'urgence. Il repose sur l'intégration d'analyses prédictives avancées permettant d'anticiper avec précision la durée de séjour des patients, une première à l'échelle provinciale.

Cette démarche révolutionne la gestion hospitalière en offrant aux décideurs des outils d'aide à la décision basés sur des modèles prédictifs, facilitant ainsi l'assignation des lits, l'optimisation des ressources médicales et la réduction des engorgements aux urgences. Son acceptation en tant que projet innovant témoigne de la pertinence de cette approche et de son potentiel à transformer durablement l'organisation des soins dans les établissements de santé québécois.

Conclusion : La DMS des patients sur civières à l'urgence étant un indicateur clé du système de santé, sa compréhension et son optimisation sont cruciales, pour assurer des soins de qualité, améliorer la satisfaction des patients, utiliser les ressources de manière optimale, maintenir un flux efficace des patients efficients et répondre aux normes réglementaires. Dans le prochain chapitre, nous entamons la problématique, les questions de recherche et les objectifs de recherche.

CHAPITRE 1

PROBLÉMATIQUE, QUESTIONS ET OBJECTIFS DE RECHERCHE

Dans ce chapitre, nous abordons la problématique de notre projet de recherche. La section 1.1 introduit la problématique générale. La section 1.2 définit l'objectif de recherche. La section 1.3 expose la question principale et les sous-questions de recherche. La section 1.4 précise la portée du projet. Enfin la section 1.5 présente un bref résumé.

1.1 Introduction à la problématique générale

1.1.1 Problématique générale

Le temps d'attente des patients dans les services d'urgence constitue un problème dans les systèmes de santé à travers le monde. Il impacte la qualité des soins et la satisfaction des patients. Il peut aggraver leur état de santé et entraîner des complications. Selon Appleby et al. (2005), le temps d'attente prolongé est un problème persistant dans le système de santé au Royaume-Uni, où il est difficile de réduire de manière durable le temps d'attente pour les consultations et les diagnostics.

L'étude de McIntyre (2019) montre que l'augmentation des temps d'attente dans les services de santé est un indicateur de pression exercée sur les systèmes de santé publique à l'échelle mondiale (Annexe A-PA-2). Cette saturation des urgences est due à un manque de coordination entre les services ainsi qu'à une communication déficiente.

Au Canada, selon les données de l'Institut canadien d'Information sur la Santé (2024), la durée de séjour des patients dans les services d'urgence s'est allongée en 2022-2023 par rapport à 2021-2022 (Annexe D — CA-1). Neuf visites sur dix se sont conclues dans un délai de 49 heures en 2022-2023, contre 40,7 heures en 2021-2022.

Au Québec, la durée médiane de séjour des patients est passée de 9,18 heures en 2018 à 11,32 heures en 2022 (Annexe C-SA-1). Selon Ouellette-Vézina (2023), le temps d'attente dans les services d'urgence au Québec a augmenté ces dernières années. De plus, une étude de l'IEDM (un groupe de réflexion favorable aux politiques de libre marché, La liberté économique et la réduction de l'intervention de l'État) indique qu'en 2022, presque un patient sur quatre a dû attendre plus de 24 heures sur une civière dans les urgences (Faubert, 2023).

Ce temps d'attente prolongé peut avoir un impact négatif sur l'état de santé des patients, sur l'efficacité et la performance des hôpitaux et sur le système de santé dans son ensemble, c'est-à-dire l'ensemble des organisations, des ressources et des activités visant à améliorer et à maintenir la santé de la population.

- **Impact sur les patients** : Le temps d'attente prolongé nuit aux patients en augmentant le stress et l'anxiété, et en détériorant leur perception des soins et leur satisfaction (Kim et Lee, 2022 ; Thompson *et al.*, 1996).
- **Impact sur l'hôpital** : D'après Tessier *et al.* (2019), le temps d'attente prolongé influence le taux d'occupation aux urgences et entraîne des coûts plus élevés pour soigner un patient à l'hôpital. Woodworth et Holmes (2020) ont évalué l'impact du temps d'attente dans les services d'urgence sur le coût des soins aux États-Unis, en utilisant une répartition presque aléatoire des patients parmi les infirmières de triage. Ils concluent que chaque prolongation de 10 minutes de temps d'attente d'un patient dans un état grave augmente en moyenne de 6 % le coût des soins pour l'hôpital. De plus Tessier *et al.* (2019) indiquent qu'une réduction de la DMS entraîne des économies pour les hôpitaux en diminuant les coûts liés aux ressources utilisées et en libérant des lits disponibles.
- **Impact sur le système de santé** : Le temps d'attente prolongé dans les services d'urgence peut affecter le système de santé de plusieurs manières :
 - Le temps d'attente prolongé peut aggraver l'état de santé des patients nécessitant des soins urgents, ce qui entraîne une nécessité de traitement plus complexe et coûteux.
 - Départ des patients avant leur prise en charge.
 - Le temps d'attente prolongé peut accroître la pression et le stress sur le personnel médical et paramédical, conduisant potentiellement à l'épuisement professionnel.
 - Un service d'urgence surchargé peut retarder l'accès aux soins pour d'autres patients ayant des problèmes médicaux moins urgents, nécessitant également l'attention du personnel médical.
 - L'encombrement aux urgences provoque des répercussions sur d'autres services du système de santé, notamment des retards dans les admissions hospitalières depuis l'urgence.
 - Le coût associé à la gestion des listes d'attente et à la prise en charge de conditions de santé aggravées augmente le fardeau financier pour le système de santé.

1.1.2 Cas spécifique : l'hôpital de la cité-de-la-santé de Laval

Un patient se présente à l'urgence de l'hôpital de la cité-de-la-santé de Laval pour un problème de santé (Annexe A-PA-3). Au triage, le personnel médical évalue son état de santé selon l'indice de priorité de l'urgence (P1 à P5). Ensuite, le patient attend dans une salle d'attente en prévision de sa première consultation avec un urgentologue. Après cette évaluation, le patient est placé sur une civière en attente à la suite des soins.

Le temps d'attente prolongé dans les services d'urgence peut être attribué à plusieurs facteurs. Premièrement, l'occupation prolongée des civières est souvent due à des patients en attente de soins ou de transfert, aggravée par des retards de transfert, des processus de congé lents et un manque de personnel. De plus, le manque de lits d'hospitalisation contribue à ces délais. Les patients peuvent également attendre des consultations avec des médecins spécialistes, ce qui prolonge leur séjour. Enfin, l'attente pour la réalisation d'examen complémentaires, tels que des procédures d'imagerie, ajoute aux délais. Ces facteurs combinés impactent la qualité des soins et l'expérience des patients.

Le tableau de bord de fluidité de la DQEPE fournit des informations quotidiennes sur le statut global de l'urgence, incluant la durée moyenne de séjour (DMS) des patients sur civière. Par exemple, le 17 octobre 2023, la DMS était de 20,1 heures (Annexe B — TB — 3). De plus, selon les données du site Index Santé du MSSS du Québec indique une DMS de 18 heures et 44 minutes pour le 2 janvier 2024 (Annexe C-SA — 1)

Notre projet a pour objectif d'identifier les facteurs qui prolongent le temps d'attente des patients sur civière aux urgences de l'Hôpital Cité-de-la-Santé de Laval, ainsi que de proposer des stratégies pour optimiser la gestion des flux de patients. Nous explorons des approches basées sur l'analyse de données afin d'améliorer l'efficacité des soins d'urgence et de réduire ces temps d'attente. L'analyse de données permet d'examiner les diverses corrélations entre les facteurs influençant le temps d'attente sur civière. Cette recherche se distingue par son approche novatrice, regroupant trois méthodologies analytiques : une analyse descriptive pour comprendre la situation actuelle, une analyse prédictive pour anticiper les évolutions futures, et une analyse prescriptive pour formuler des recommandations concrètes visant à réduire les délais d'attente.

1.1.3 Définition des concepts clés

Dans le cadre de cette recherche, il est essentiel de préciser certains concepts fondamentaux afin de faciliter la compréhension du lecteur. Comme mentionné dans la section 1.1.1, un patient admis à l'urgence peut traverser différents processus, parmi lesquels les principaux sont les suivants :

- Le processus des examens complémentaires (imagerie) regroupe l'ensemble des investigations techniques, telles que la radiographie, le scanner ou l'IRM, qui visent à appuyer la prise de décision médicale (*Qualité des services de santé Ontario*, 2025).
- Le processus de consultation avec un médecin spécialiste correspond aux démarches effectuées par le médecin de l'urgence pour obtenir l'évaluation du patient par un spécialiste, généralement nécessaires pour confirmer un diagnostic établi par le médecin urgentologue ou pour ajuster le traitement (MSSS, 2024).
- Le processus d'hospitalisation, qui désigne l'ensemble des étapes allant de l'admission du patient jusqu'à son installation dans une unité de soins (MSSS, 2022).

Ces définitions constituent le cadre conceptuel nécessaire à la compréhension des objectifs de la présente section.

1.2 Objectif de recherche

L'objectif de cette recherche est de mieux comprendre les causes des limites actuelles dans le processus d'admission des patients à l'urgence de l'hôpital de la cité-de-la-santé de Laval, afin d'améliorer ce processus. Cela peut se faire : soit par l'optimisation du processus d'hospitalisation des patients, soit par l'amélioration de processus des consultations avec des médecins spécialistes, ou encore par l'optimisation de processus des examens complémentaires (Imagerie).

1.3 Question de recherche

Pour définir efficacement notre recherche, nous avons formulé, en collaboration avec les parties prenantes de l'hôpital (gestionnaires, Médecins), une question de recherche générale. Cette question oriente les limites de notre étude en annonçant les concepts clés qui seront explorés, comme indiqué dans le résumé de la recherche du Boulenger et Vaillancourt (2013) sur le temps d'attente dans le secteur public de la santé au Québec. La pertinence de la question de recherche est cruciale pour orienter la suite de nos travaux (Fortin et Gagnon, 2016, chapitre 4).

Pour élaborer cette question, nous avons mené des réunions avec les parties prenantes, notamment les gestionnaires, les médecins et les autres membres du personnel hospitalier. Ces échanges ont permis de discuter des défis liés au processus d'admission et d'identifier certaines pistes d'analyse jugées pertinentes pour mieux comprendre le phénomène. Ces pistes, issues de la démarche exploratoire, concernent notamment :

- l'impact du manque de lits disponibles à l'hôpital pour admission (Gutkin, 2011).
- l'attente avant l'accès à un médecin spécialiste (Belorgey, 2011, p. 25).
- le rôle des délais associés aux examens complémentaires (imagerie, etc.) (SRLF et Springer-Verlag, 2014).
- l'effet du délai avant une opération de chirurgie urgente (Oberlin *et al.*, 2020).

Ces éléments ne constituent pas des sous-questions de recherche indépendantes, mais plutôt des dimensions explorées dans le cadre de notre démarche. Leur identification découle à la fois d'une analyse des processus hospitaliers et des recommandations des parties prenantes (Gutkin, 2011 ; Belorgey, 2011, p. 25 ; SRLF et Springer-Verlag, 2014 ; Oberlin *et al.*, 2020). En les intégrant ainsi, nous évitons de limiter notre étude à une simple vérification d'hypothèses prédéterminées et nous conservons la nature exploratoire de notre mémoire, tout en assurant la cohérence entre les observations empiriques et les indicateurs sélectionnés.

Ainsi, le choix des variables d'intérêt correspondant aux quatre sous-questions a été guidé par un double impératif : d'une part, l'univers des données réellement disponibles dans les systèmes hospitaliers, et d'autre part, les recommandations issues de l'expertise des gestionnaires et des médecins, directement impliqués dans l'organisation et la qualité des soins (Gutkin, 2011 ; Belorgey, 2011, p. 25). Cette sélection repose également sur une analyse approfondie des processus cliniques et organisationnels observés, afin de retenir des variables à la fois accessibles, pertinentes et représentatives. Chaque variable a ainsi été choisie pour sa valeur explicative et sa capacité à mesurer de manière fiable les délais et la qualité des soins, en particulier les temps d'attente à l'urgence, considérés comme un indicateur critique de performance et de satisfaction des patients (SRLF et Springer-Verlag, 2014 ; Oberlin *et al.*, 2020). Cette démarche méthodologique, conciliant contraintes de disponibilité et pertinence clinique, assure la cohérence entre les questions de recherche et les indicateurs sélectionnés, tout en renforçant la validité et l'applicabilité des résultats de l'étude.

1.4 Portée du projet de recherche

Cette étude vise à fournir un outil aux gestionnaires de l'hôpital de la cité-de-la-santé de Laval pour les aider à améliorer le processus d'admission des patients à l'urgence. Il est important de préciser que l'étude utilise des outils de TI uniquement pour l'amélioration de ce processus. Les aspects médicaux spécifiques ainsi les facteurs externes, tels que les politiques de santé publique du Québec, sont exclus de cette recherche.

Afin de démontrer de manière explicite que les objectifs fixés dans le cadre de ce projet ont été atteints, le tableau ci-dessous présente la correspondance entre les objectifs initialement définis et les résultats obtenus.

Tableau 1.1 Synthèse des objectifs atteints dans le cadre du projet

Objectif du projet	Résultat obtenu	Commentaires
Développer un tableau de bord descriptif	Identification des variables influençant la durée de séjour des patients à l'urgence.	Le tableau de bord descriptif permet de définir et d'identifier les variables qui impactent la durée de séjour. Exemple : Figure 4.50 – Corrélation entre le délai d'attente à l'hospitalisation et la DMS sur civière
Fournir un soutien décisionnel aux gestionnaires	Modèle prédictif développé pour estimer le temps d'attente d'un patient à l'urgence	Résultat présenté en Figure 5.7 – Résultats du modèle de forêt aléatoire
	Modèle prédictif développé pour estimer la probabilité moyenne d'admission par service	Figure 6.7 – Matrice de confusion pour l'évaluation de la probabilité d'admission

1.5 Conclusion

Dans ce chapitre, nous avons présenté les éléments clés de notre étude sur le temps d'attente prolongé des patients sur civière à l'urgence. Nous avons défini la problématique, énoncé les objectifs, et formulé des questions pour guider notre exploration. Nous avons également précisé la portée de notre recherche. Le chapitre suivant sera dédié à l'état de l'art, où nous examinerons les concepts clés de ce travail.

CHAPITRE 2

ÉTAT DE L'ART

Ce chapitre présente l'état de l'art concernant le temps d'attente prolongé des patients sur civière à l'urgence. La section 2.1 introduit les principaux concepts, méthodes et approches analytiques constituant le cadre de référence de ce projet de recherche. La section 2.2 définit le délai moyen de séjour des patients sur civière à l'urgence et précise la méthode de mesure utilisée. La section 2.3 analyse les facteurs influençant ce délai. La section 2.4 examine les approches analytiques de données proposées dans la littérature pour traiter cette problématique. La section 2.5 souligne l'importance de l'analyse des données pour la gestion des urgences et des hôpitaux. La section 2.6 propose une synthèse critique des connaissances existantes. La section 2.7 illustre l'application des méthodes analytiques dans le contexte de l'hôpital de la Cité-de-la-Santé de Laval. Enfin, la section 2.8 présente un résumé des points abordés.

2.1 Introduction

Ce chapitre examine l'état de l'art sur le temps d'attente prolongé aux services d'urgence, en mettant l'accent sur la durée moyenne de séjour des patients sur civière (DMS) à l'Hôpital Cité-de-la-Santé de Laval. L'objectif est de situer notre question de recherche dans le contexte des connaissances existantes et d'identifier les travaux antérieurs pertinents. Notre question de recherche vise à déterminer les raisons expliquant le temps d'attente prolongé des patients sur civière à l'urgence. Pour répondre à cette question, nous allons :

- Contextualiser la Problématique : analyser les études précédentes pour identifier les facteurs influençant le temps d'attente aux urgences et les principales causes du temps d'attente prolongé.
- Identifier les Lacunes : détecter les limites des recherches existantes et les aspects de la DMS qui ont été moins explorés, ce qui justifie la nécessité de notre propre étude.
- Positionner notre Contribution : montrer en quoi notre étude sur la DMS se distingue des recherches antérieures, en soulignant l'originalité et la spécificité de notre approche pour comprendre le temps d'attente prolongé.

Ce chapitre fournira un cadre théorique essentiel pour notre étude en intégrant les connaissances actuelles et en mettant en évidence les pistes pour une analyse approfondie du temps d'attente prolongé des patients sur civière.

2.2 Définition et mesure de la durée moyenne de séjour des patients sur civière à l'urgence

2.2.1 Définition de la durée moyenne de séjour des patients sur civière à l'urgence

Selon McIntyre (2019), le temps d'attente des patients dans les services d'urgence varie en fonction du point de départ et d'arrivée. Ce temps d'attente englobe les soins de première ligne, les soins spécialisés, les consultations avec les professionnels de la santé, ainsi que l'attente dans les salles d'accueil. Au Québec, un rapport publié par le Commissaire à la santé et au bien-être du Québec (2016) présente une analyse détaillée du parcours type des patients aux urgences. Il identifie plusieurs étapes clés — arrivée, triage, consultation médicale, attente de consultations spécialisées, hospitalisation ou congé — chacune pouvant représenter un point de départ ou d'arrivée distinct. Le document met notamment en évidence que le délai d'accès à des spécialistes constitue souvent la phase la plus longue, avec un délai moyen de 8 heures, et que la durée moyenne de séjour sur civière varie de 14 à 37 heures selon l'établissement.

Le temps d'attente peut représenter l'intervalle entre la consultation avec un urgentologue et un médecin spécialiste, entre la consultation avec un spécialiste et le début de traitement, entre la prescription d'un test de diagnostic et sa réalisation, ou encore entre la décision d'opérer et la sortie de l'hôpital.

À l'urgence de l'Hôpital de la Cité-de-la-Santé de Laval, le temps médian de séjour d'un patient sur civière est mesuré selon l'indicateur 1.09.01 du ministère de la Santé et des Services sociaux, toujours actifs en 2024. Cette mesure calcule la durée moyenne entre l'inscription à l'urgence (triage ou accueil) et la sortie (congé ou admission), comme définie par le MSSS. Selon le Plan stratégique en vigueur, les cibles annuelles sont actuellement de 17 h pour 2023-2024, avec un objectif progressif d'atteindre 14 h à l'horizon 2026-2027.

2.2.2 Comment mesurer la durée moyenne de séjour des patients sur civière à l'urgence

Pour mesurer la DMS des patients sur civière à l'urgence, de l'hôpital de la cité-de-la-santé de Laval utilise la formule de l'indicateur 1.09.01 (ministère de la Santé et des Services sociaux, 2020). La DMS des patients sur civière est la moyenne des durées de séjour de tous les patients sur civière à l'urgence. La formule est la somme des durées de séjour des patients sur civière, divisée par le nombre total de patients sur civière. Cela fournit une estimation du temps moyen que chaque patient peut anticiper lors de son passage dans le service d'urgence. Selon les normes du MSSS du Québec, la durée moyenne de séjour (DMS) sur civière devrait être limitée à 8 heures pour les patients non admis et à 12 heures pour ceux admis.

2.3 Éléments affectant la durée moyenne de séjour des patients sur civière

2.3.1 Patient en attente d'une consultation avec un médecin spécialiste

Après avoir été placé sur une civière, un patient peut être dirigé vers un médecin spécialiste, comme un cardiologue. À l'urgence de l'hôpital de la Cité-de-la-Santé de Laval, les patients attendent en moyenne 9,1 heures pour une consultation avec un médecin spécialiste (Annexe A-PA-4). Cette valeur est mesurée à un moment précis de la journée, soit le matin. Bien que le délai global puisse être inférieur, il reste significatif.

Selon les deux articles publiés par ICI.Radio-Canada.ca (2023a) et de Faubert (2023), le Québec a connu une augmentation de plus de 50 % du nombre des patients en attente d'une consultation avec un médecin spécialiste depuis le début de la pandémie en 2020. Cette situation peut s'expliquer par la pénurie des spécialistes disponibles, les contraintes de temps liées à l'afflux élevé de patients, une organisation sous-optimale des soins et des démarches administratives laborieuses.

(Mulinganya *et al.*, 2018 ; McIntyre et Clara K, 2019 ; Barua et Mackenzie, 2019) Soulignent que le temps d'attente pour une consultation spécialisée contribue à l'engorgement des services d'urgence, cause la fatigue, tout en générant la fatigue, l'anxiété et l'insatisfaction chez les patients.

2.3.2 Patient en attente des examens complémentaires (Imagerie)

Lorsqu'un patient est placé sur civière à l'urgence, son médecin peut recommander des examens complémentaires pour évaluer son état de santé, tel que ceux réalisés en imagerie médicale. Pendant cette période d'attente, le personnel médical surveille les patients. (Prabhu *et al.*, 2022) ont utilisé des données rétrospectives issues d'un grand centre hospitalier de niveau 1 (traumatologie) pour bâtir un modèle de simulation basé sur des événements discrets. Leur objectif : évaluer comment les délais liés aux examens d'imagerie, ainsi que l'agrégation de ces examens (regrouper plusieurs examens pour un même patient), influent sur la durée totale du séjour aux urgences. Les résultats démontrent que réduire les délais d'imagerie et regrouper seulement 10 % des examens peut entraîner une diminution significative - statistiquement significative ($p < 0,05$) — de la durée de séjour des patients dans l'unité d'urgences.

2.3.3 Patient en attente d'hospitalisation

Selon les données de 2018–2019, le temps moyen d'attente dans les urgences pour obtenir un lit d'hôpital est monté à 9,7 heures, contre 7,7 heures en 2015–2016. Cette situation est largement attribuée à un manque de lits d'hospitalisation disponibles, notamment parce que des lits sont occupés par des patients

en « niveau de soins alternatif » (ALC) ne nécessitant plus de soins aigus — souvent en attente de soins à domicile ou en centre de soins prolongés. (*Value & efficiency - health quality ontario*, 2019).

Le rapport (No respite for Ontario patients, 2024) alerte sur la crise de capacité hospitalière en Ontario : la province n'a pas suffisamment de lits pour répondre aux besoins. En juin 2024, le délai moyen d'attente pour un lit d'hôpital était de 19 heures, bien au-delà de l'objectif de 8 heures. Le sous-investissement dans le secteur hospitalier, combiné au manque de lits, aggrave la congestion dans les

pour l'institut canadien de l'information sur la santé, les patients sont souvent en attente d'un lit d'hospitalisation ou d'une salle d'opération (2023). À l'urgence de l'hôpital de la Cité-de-la-Santé de Laval, le temps d'attente pour hospitalisation est de 10,3 heures (Annexe A-PA-5).

2.3.4 Patient en attente d'une chirurgie

Selon l'étude sur la perturbation de la planification opérationnelle par les urgences (Tancrez *et al.*, 2011, p. 10), un patient à l'urgence nécessitant une opération peut devoir attendre une salle d'opération disponible. L'étude de (Meschino *et al.*, 2020) , rétrospective sur 1 505 cas de chirurgie d'urgence a analysé l'impact du délai admission-intervention (> 24 h, > 72 h) et de l'horaire opératoire (de jour, hors heures régulières, nuit). Elle conclut qu'un délai > 72 h est associé à une mortalité accrue et les interventions de nuit multiplient par 3,15 le risque de mortalité. L'étude souligne la nécessité d'un accès rapide et organisé aux blocs pour les urgences

2.4 Méthode analytiques des données.

Cette section examine comment l'analyse des données peut contribuer à réduire le temps d'attente des patients aux urgences, en articulant les apports scientifiques et opérationnels pour notre hôpital. L'objectif scientifique est de mieux comprendre les facteurs influençant la durée moyenne de séjour (DMS) sur civière, tandis que l'objectif opérationnel vise à fournir des pistes concrètes pour améliorer la gestion des ressources hospitalières.

2.4.1 Définition et différents modèles d'analytique de données

Dans le cadre de notre recherche pour la maîtrise en technologie de l'information, nous examinons des ouvrages et des sources littéraires qui explorent l'utilisation de la technologie de l'information comme outil pour identifier des stratégies de gestion (Lin *et al.*, 2017 ; Thompson *et al.*, 2020).

Selon Sharda (2018), l'analytique de données est considérée par de nombreux spécialistes comme un processus facilitant la prise de décision et l'élaboration de recommandations pour les gestionnaires, grâce à l'exploitation des connaissances extraites des données historiques. Cette approche intègre la technologie de l'information, les méthodologies de gestion et les outils statistiques pour résoudre des problèmes concrets. Elle utilise l'analyse de données pour comprendre les événements, prévoir les futurs possibles et choisir les meilleures stratégies. Il existe trois principaux modèles d'analytique de données : l'analyse descriptive, l'analyse prédictive et l'analyse prescriptive (Annexe E-MO — 1) (Sharda *et al.*, 2018, p. 49).

Analyse critique : L'analyse descriptive constitue un outil précieux pour comprendre et visualiser les tendances passées, mais elle demeure insuffisante lorsqu'il s'agit d'anticiper les fluctuations futures. À ce titre, l'analyse prédictive présente un potentiel plus opérationnel, puisqu'elle permet d'anticiper les pics d'activité et la demande en lits. Toutefois, sa fiabilité reste étroitement liée à la qualité et à l'exhaustivité des données disponibles. Enfin, l'analyse prescriptive va plus loin en proposant des recommandations concrètes pour orienter la prise de décision. Néanmoins, son efficacité dépend largement de la capacité des gestionnaires à mettre en œuvre les solutions suggérées.

2.4.2 Définition de l'analyse descriptive

Selon Sharda (2018, p. 50), l'analyse descriptive examine en détail les données pour comprendre la nature des événements ou identifier les caractéristiques clés d'un sujet. Elle se concentre sur l'aspect « quoi », en mettant en évidence les tendances, les caractéristiques dominantes, et les relations au sein des données. De plus, l'analyse descriptive permet de présenter les données de manière significative à l'aide de tableaux et de graphiques (Sharda *et al.*, 2018, p. 101). Dans le même ouvrage de Sharda (2018, p. 143) on explique que le tableau de bord est un outil qui illustre les indicateurs de performance clé (KPIs) pour une entreprise, offrant aux décideurs exécutifs une vue rapide et précise de la situation au sein de l'organisation.

Analyse critique : Les études de Mulinganya (2018) et de Boulenger et Vaillancourt (2013) démontrent que l'analyse descriptive constitue un outil pertinent pour comprendre les déterminants du temps d'attente. Toutefois, cette approche demeure limitée puisqu'elle se concentre sur l'explication des tendances passées et ne permet pas d'anticiper l'effet de changements organisationnels sur la durée moyenne de séjour (DMS). Dans le cadre de notre projet, le tableau de bord descriptif jouera ainsi un rôle

fondamental en servant de point de départ pour l'identification des variables clés et la préparation des analyses prédictives.

2.4.3 Définition de l'analyse prédictive

Selon Sharda (2018, p. 251), l'analyse prédictive utilise des données du passé pour anticiper les événements futurs. Cette approche se concentre sur la prévision en analysant les données historiques et actuelles. Elle utilise les techniques d'apprentissage automatique, qu'elles soient supervisées ou non supervisées, pour classer les données, faire des prédictions, et découvrir des relations entre des événements (Sharda *et al.*, 2018, p. 227).

Analyse critique : Bien que les modèles prédictifs atteignent des performances élevées (AUC entre 0,87 et 0,92), leur validité reste fortement conditionnée par le contexte local et les particularités propres à chaque hôpital. Les modèles complexes, tels que les réseaux neuronaux, offrent une grande précision, mais leur faible interprétabilité peut constituer un frein à leur adoption par le personnel hospitalier. Dans le cadre de notre étude, l'analyse prédictive sera mobilisée pour estimer la durée moyenne de séjour (DMS), mais elle devra être soigneusement calibrée à partir des données locales et validée en collaboration avec les gestionnaires afin d'assurer sa pertinence et son acceptabilité.

2.4.4 Différentes méthodes de prédiction

Selon Sharda (2018, p. 227), l'apprentissage automatique se divise en deux catégories principales:

- L'apprentissage automatique supervisé : Les algorithmes d'apprentissage supervisé sont utilisés pour la classification et la prédiction, en se basant sur les données où la valeur du résultat d'intérêt est déjà connue. Dans notre cas, il concerne la durée moyenne de séjour (DMS) des patients sur civière. Ces données sont dites « étiquetées », car chaque enregistrement comprend l'étiquette correspondant à la valeur du résultat.
- L'apprentissage automatique non supervisé : Cette méthode est utilisée pour identifier des structures cachées dans les ensembles de données sans étiquettes préalablement définies. Contrairement à l'apprentissage supervisé, où chaque exemple dans l'ensemble de données est associé à une étiquette ou à un résultat spécifique, l'apprentissage non supervisé traite des données sans étiquettes assignées. Il cherche à comprendre les données par lui-même, sans intervention extérieure.

Nous avons écarté la technique d'apprentissage automatique non supervisé, car, dans notre cas, la DMS est une variable déjà connue. De plus, les recherches sur la prédiction de la DMS des patients à l'hôpital privilégient l'utilisation d'algorithmes d'apprentissage supervisé en raison de leur efficacité prouvée (Sharda et al., 2018).

Il existe deux grands modèles d'apprentissage automatique supervisé (Shmueli *et al.*, 2018)

- La classification : Ces algorithmes sont utilisés lorsque la variable cible est catégorielle. L'objectif est de prédire à quelle catégorie appartient une nouvelle observation. Par exemple, il pourrait s'agir de diagnostiquer si un patient a une maladie spécifique (Sharda *et al.*, 2018, p. 221). Dans notre recherche, nous écartons les méthodes de classification, car notre objectif est de prédire la DMS des patients sur civière, et non de catégoriser la DMS.
- La régression : les algorithmes de régression permettent d'estimer avec précision la durée de séjour spécifique pour chaque patient admis sur civière, en prenant en compte une multitude de variables et de caractéristiques pertinentes. Parmi ces facteurs, la raison de consultation, le nombre de lits disponibles, la disponibilité de salle d'imagerie et la présence de médecins spécialistes jouent un rôle crucial dans l'évaluation de la DMS des patients aux urgences. Avec cette approche de régression, il est possible de prédire de manière précise la DMS, ce qui facilite une meilleure allocation des ressources hospitalières. Elle contribue à optimiser la gestion des flux des patients, à améliorer la planification des admissions et à réduire le temps d'attente des patients (Sharda *et al.*, 2018, p. 227).

Analyse critique : Les algorithmes de régression constituent une approche pertinente pour la prédiction de la durée moyenne de séjour (DMS), puisqu'ils permettent d'intégrer simultanément plusieurs variables, telles que le nombre de lits disponibles, la présence de spécialistes ou encore la réalisation d'exams complémentaires. Toutefois, ces méthodes supervisées reposent sur l'utilisation de données étiquetées de bonne qualité, et toute lacune ou biais dans les bases de données risque de compromettre la fiabilité et la robustesse des prédictions obtenues.

2.4.5 Différents algorithmes d'apprentissage automatique

Dans cette section, nous présentons les algorithmes d'apprentissages automatiques supervisés, adaptés aux problèmes de régression, sélectionnés pour notre étude. Le choix de ces algorithmes repose sur une analyse approfondie de la littérature, en tenant compte de la complexité des données et de leur efficacité démontrée dans des travaux antérieurs pour prédire avec précision.

2.4.5.1 La régression linéaire

Selon Sharda (2018, p. 113), pour analyser la relation entre deux variables, on crée un graphique de dispersion, où l'axe des ordonnées représente les valeurs de la variable réponse et l'axe des abscisses, celle de la variable explicative (Annexe E-MO -2). L'analyse de régression simple cherche à modéliser mathématiquement cette relation. Elle permet de déterminer l'équation d'une droite qui passe au plus près des points tracés (représentant des données d'observations historiques), afin de minimiser la distance entre ces points et la ligne (les valeurs prédites sur l'axe des ordonnées). Ce processus implique de déterminer la pente et l'ordonnée à l'origine de la ligne de régression, de manière à minimiser la somme des carrés des écarts verticaux entre les points réels et les points prédits. Ce modèle de prédiction est : simple à interpréter et rapide, mais limitée aux relations linéaires.

Fonction : la ligne de régression est décrite par l'équation $y_i = \beta_0 + \beta_1 x_i + e_i$, où y_i est la variable dépendante, x_i est la variable explicative, β_0 est l'ordonnée à l'origine, β_1 représente la pente de la ligne droite, et e_i correspond à l'erreur résiduelle pour le i -ème individu.

2.4.5.2 Le modèle K-Nearest Neighbours (KNN)

Le modèle *k-Nearest Neighbours (KNN)*, utilisé pour la classification et la régression, en se basant sur la proximité des données. L'algorithme recherche les k voisins les plus proches dans l'espace des caractéristiques, où k est défini par l'utilisateur (Shmueli *et al.*, 2018, chapitre 7). Garcia-Carretero (2020) a appliqué l'algorithme *KNN* pour prédire la réadmission des patients diabétiques. En analysant les dossiers médicaux de 1000 patients diabétiques, les patients à haut risque de réadmission ont été identifiés en fonction de caractéristiques cliniques, démographiques et de traitement. Ce modèle est robuste pour les petites variations et les données non linéaires, mais sensibles au choix de k et à la densité des données

2.4.5.3 Arbre de décision.

L'arbre de décision classe les données en un nombre fini de classes basées sur les valeurs des variables d'entrée (Sharda, 2018, p. 227). Il commence par un nœud racine et aboutit à des nœuds de feuilles représentant les décisions ou prédictions finales. Chaque nœud interne teste une caractéristique, et chaque branche issue de ce nœud indique un résultat possible du test. Ce processus se poursuit récursivement, divisant les données en sous-ensembles plus petits jusqu'à ce que des critères prédéfinis soient atteints. Donc ce modèle capture les interactions complexes entre variables, qui offrent une meilleure précision, mais peuvent être sujets au surapprentissage si non régularisé.

2.4.5.4 Les forêts de décision ou les forêts aléatoires (Random Forests)

Selon Shmueli (2018, Chapitre 13), les forêts aléatoires constituent un cas particulier du *bagging*, une technique visant à améliorer le pouvoir prédictif en combinant plusieurs classificateurs ou algorithmes de prédiction. Ce modèle améliore la précision des prédictions et atténue le problème de surapprentissage associé aux arbres de décision unique en combinant les prédictions de plusieurs arbres.

2.4.5.5 Les séries temporelles

Une série temporelle est une séquence de données recueillies à des intervalles réguliers. Chaque donnée est associée à un point temporel, ce qui permet d'analyser les tendances au fil du temps (Sharda, 2018, p.113). Cette méthode aide à comprendre les variations dans le temps et à prévoir les événements futurs. Elle est efficace pour analyser les fluctuations des admissions au fil du temps (Zhou *et al.*, 2018). Leur limitation principale est qu'elles nécessitent des séries longues et homogènes.

2.4.5.6 Les réseaux neuronaux

Les réseaux de neurones sont inspirés des réseaux neuronaux biologiques du cerveau humain (Shmueli, 2018, Chapitre 11). Ils sont conçus pour reconnaître des motifs et résoudre des problèmes complexes en apprenant à partir de grandes quantités de données. Leur principale force réside dans leur performance prédictive élevée, capturant des relations complexes entre les variables prédictives et la variable de résultat, ce qui est souvent difficile à réaliser avec d'autres modèles prédictifs. Ce modèle est très performant pour capturer des relations complexes (Tsai *et al.*, 2016), mais leur interprétation reste difficile pour les gestionnaires.

2.4.6 Définition de l'analyse prescriptive

L'analyse prescriptive est utilisée en gestion et en prise de décision. Cette approche prescrit des actions spécifiques basées sur des prédictions et des analyses pour obtenir les meilleurs résultats. Contrairement au modèle descriptif, qui décrit les phénomènes ou les comportements existants. Le modèle prescriptif fournit des recommandations pour résoudre un problème ou optimiser des performances. Selon Sharda (Sharda *et al.*, 2018, chapitre 6), ce modèle aide les décideurs à prendre la bonne décision, ou à automatiser des processus décisionnels, et est également appelé analytique décisionnelle.

Analyse critique : L'analyse prescriptive joue un rôle essentiel en traduisant les résultats scientifiques en actions opérationnelles, mais son succès repose largement sur l'adhésion et la capacité des gestionnaires à mettre en œuvre les recommandations proposées. Elle vient ainsi compléter l'analyse prédictive en fournissant des stratégies concrètes visant à améliorer l'efficacité hospitalière et à optimiser l'utilisation des ressources.

Lien avec le projet :

Chaque algorithme est évalué pour sa pertinence opérationnelle : précision des prédictions, capacité à gérer les variables locales, et facilité d'intégration dans la prise de décision hospitalière.

2.5 Utilité de l'analytique de données aux urgences et aux hôpitaux

Cette section examine l'importance de l'analytique de données dans les urgences et les hôpitaux. Les sous-sections couvrent les sujets suivants : analyse descriptive (3.5.1), analyse prédictive (3.5.2), apprentissage automatique supervisé (3.5.3), régression linéaire (3.5.4), KNN (3.5.5), arbre de décision (3.5.6), forêts d'arbres décisionnels (3.5.7), séries temporelles (3.5.8), réseaux neuronaux (3.5.9) et analyse prescriptive (3.5.10).

2.5.1 Lien entre l'analytique de données et les besoins de l'hôpital

L'analytique de données constitue un levier stratégique pour répondre aux besoins opérationnels de l'hôpital. En exploitant les données cliniques et administratives, elle permet d'identifier des tendances, de prévoir la demande en ressources et d'optimiser la prise de décision. Par exemple, la prédiction des durées de séjour des patients à l'urgence facilite la planification des lits, la gestion du personnel et la réduction des temps d'attente. Ainsi, l'analytique de données crée un lien direct entre l'exploitation scientifique des informations et l'amélioration concrète de l'efficacité hospitalière.

2.5.2 Utilité de l'analyse descriptive aux urgences et aux hôpitaux

L'étude descriptive permet de comprendre les dynamiques d'attente des patients dans les services d'urgence en fournissant des données détaillées sur les motifs de visite, le temps d'attente et les résultats des traitements. Selon l'étude (Lee *et al.*, 2022), l'analyse des caractéristiques des patients et des hôpitaux permet de mieux comprendre les déterminants d'un séjour prolongé aux urgences et leur impact sur les résultats cliniques. Les auteurs montrent que des facteurs comme l'âge avancé, la présence de comorbidités ou encore les conditions d'admission influencent significativement la durée de séjour aux

urgences et la mortalité hospitalière. Cette approche met en évidence l'importance de surveiller et d'optimiser les processus organisationnels afin de réduire les délais d'attente et d'améliorer la prise en charge des patients critiques.

L'étude descriptive réalisée par Mulinganya (2018) examine les tendances du temps d'attente à l'hôpital et leur impact sur la satisfaction des patients, soulignant l'importance de stratégies efficaces pour gérer le flux des patients. Pour Coutin et Vaucel (2014), ils montrent l'importance d'une étude descriptive pour analyser l'évolution du temps d'attente dans l'unité d'urgence gynécologique et obstétricale du CHU de Nantes en France entre 2005 et 2012. De même Boulenger et Vaillancourt (2013, p. 20) ont utilisé des statistiques descriptives pour évaluer l'impact économique du temps d'attente sur les services sociaux au Québec. Ces recherches montrent l'importance de l'étude descriptive pour améliorer les services de santé. Pour comprendre la situation actuelle de l'urgence de l'hôpital de la Cité-de-la-Santé de Laval et suivre l'évolution de la DMS des patients sur civière à l'urgence en fonction de différents facteurs, nous allons développer un tableau de bord descriptif. Ce tableau aura pour objectif d'analyser les événements passés afin de dégager des informations utiles et anticiper les tendances futures en se basant sur ces données.

2.5.3 Utilité de l'analyse prédictive aux urgences et aux hôpitaux

L'application des analyses prédictives dans les services d'urgence permet de mieux gérer les ressources hospitalières et d'améliorer les soins aux patients. Selon l'article publié dans *PLoS One* en juillet 2018 (Hong *et al.*, 2018), des algorithmes d'apprentissage automatique (régression logistique, gradient boosting et réseaux de neurones profonds) ont été entraînés à partir de données de triage et d'historique médical issues d'environ 560 486 visites aux urgences (ED) entre mars 2014 et juillet 2017. Les modèles utilisant uniquement les informations de triage atteignaient un AUC d'environ 0,87, tandis que l'utilisation combinée des données de triage et de l'historique médical permettait d'améliorer notablement la performance, avec un AUC allant jusqu'à 0,92. Une version simplifiée du modèle (à faible dimension), reposant sur des variables clés comme le niveau ESI, les médicaments hors hospitalisation, des données démographiques et des statistiques de recours à l'hôpital, obtenait également un AUC élevé de 0,91, démontrant ainsi qu'une sélection pertinente de données pouvait suffire pour prédire avec précision l'admission hospitalière dès la phase de triage.

L'étude de Carter (2014) a examiné les facteurs significatifs affectant la durée de séjour à l'hôpital, en utilisant les remplacements totaux du genou comme exemple. Elle a développé un modèle prédictif basé sur ces facteurs pour aider à la planification des ressources et à la gestion des attentes des patients. Les données extraites du système de dossiers patients électroniques ont permis de créer un modèle précis à

75 % pour prédire la durée de séjour, contribuant ainsi à l'amélioration de la planification des ressources et à la formulation de recommandations pour les patients.

Selon l'article (Courville *et al.*, 2023), l'application des algorithmes d'apprentissage automatique aux traumatismes crâniens permet d'obtenir une précision prédictive supérieure à celle des modèles statistiques conventionnels. L'analyse de quinze études a révélé que treize d'entre elles rapportaient une amélioration significative de la performance avec des taux de précision dépassant fréquemment 80 % pour anticiper la mortalité et les issues défavorables mesurées par l'échelle de Glasgow. Les variables cliniques les plus déterminantes identifiées étaient notamment le score de Glasgow Coma Scale à l'admission, l'âge du patient, l'acidose plasmatique et la glycémie. Ces résultats suggèrent que les modèles de type forêts aléatoires, SVM et réseaux de neurones artificiels pourraient constituer des outils d'aide à la décision clinique précieux pour la stratification précoce du risque et l'orientation thérapeutique, tout en soulignant la nécessité de valider leur généralisation par des études prospectives multicentriques.

Enfin, selon Sharda (2018, p. 429), une étude utilisant des modèles prédictifs pour analyser les tendances des maladies à partir de dossiers médicaux électroniques montre que cette approche peut améliorer la compréhension des maladies et les différences entre les populations urbaines et rurales.

2.5.4 Utilité de l'apprentissage automatique supervisé aux urgences et aux hôpitaux

La technique de l'apprentissage supervisé joue un rôle dans la prédiction de la DMS des patients sur civière aux urgences. Les exemples de Sarty (2023) et de Levin (2018) démontrent l'efficacité de ce modèle pour une gestion plus efficace des ressources hospitalières. Un modèle prédictif construit à partir de données issues des visites aux urgences, incluant les informations de triage, l'historique médical et l'ensemble des variables cliniques, permet d'anticiper l'issue d'une consultation (admission ou congé) dès l'arrivée du patient grâce à l'apprentissage automatique (Hong *et al.*, 2018). Dans l'article de Pak (2021), Il examine comment l'emploi d'algorithme d'apprentissage automatique peut affiner la précision des prévisions relatives au temps d'attente des patients.

2.5.5 Utilité de la régression linéaire aux urgences et aux hôpitaux

L'utilisation de la régression linéaire dans les urgences et les hôpitaux est cruciale pour améliorer l'efficacité et la qualité des soins des patients. Selon l'étude de Elazhary et al. (2016), le modèle de régression linéaire multivariée identifie les facteurs associés aux départs avant prise en charge médicale dans les salles d'urgence. Il conclut que la réduction de la durée de séjour des patients non hospitalisés et la présence d'un médecin dédié aux patients ambulatoires sont efficaces pour diminuer ces incidents.

2.5.6 Utilité de Modèle KNN aux urgences et aux hôpitaux

Le modèle KNN offre des applications pratiques pour améliorer à la fois l'efficacité opérationnelle et les résultats de santé des patients. Il est utilisé pour prédire la probabilité qu'un patient vu aux urgences nécessite une admission hospitalière. Cette prédiction est basée sur des données cliniques aidant à optimiser l'utilisation des ressources hospitalières et à planifier les besoins en lits (Guazzo *et al.*, 2021).

2.5.7 Utilité de l'arbre de décision aux urgences et aux hôpitaux

En situation d'urgence, les arbres de décision fournissent un cadre pour accélérer la prise en charge des patients. Cela peut améliorer le flux des patients, réduire l'encombrement des urgences et par la suite améliorer la satisfaction des patients (Hachesu *et al.*, 2013).

2.5.8 Utilité des forêts d'arbres décisionnels aux urgences et aux hôpitaux

Les forêts d'arbres décisionnels sont des outils puissants, particulièrement utiles dans le contexte des urgences. Leurs utilisations offrent des avantages pour améliorer les soins aux patients, facilitent la prise de décision clinique et optimisent la gestion des ressources. L'utilisation de classificateurs de *boosting* de gradient dans l'étude de Gawande et Patil (2022) montre que les niveaux de précision sont plus élevés à la prédiction de la réadmission des patients.

2.5.9 Utilité des séries temporelles aux urgences et aux hôpitaux

Pour(Zhou *et al.*, 2018), l'analyse des séries temporelles permet de modéliser les variations quotidiennes et mensuelles du nombre de nouvelles admissions hospitalières. En comparant les modèles, SARIMA, NARNN (réseau de neurones autorégressif non linéaire) et un modèle hybride SARIMA-NARNN, l'étude montrent que le modèle hybride offre la meilleure performance prédictive (RMSE, MAE, MAPE les plus faibles), bien que tous les modèles permettent d'anticiper efficacement les fluctuations liées à la saisonnalité, aux jours de la semaine ou aux fêtes. Cette démarche favorise une meilleure planification des ressources hospitalières, en aidant les gestionnaires à anticiper les pics d'activité et à organiser l'accueil des patients en conséquence.

2.5.10 Utilité des réseaux neuronaux aux urgences et aux hôpitaux

Pour(Tsai *et al.*, 2016), l'utilisation des réseaux de neurones artificiels permet de prédire la durée de séjour hospitalier des patients dès l'admission, particulièrement en cardiologie. En tenant compte des

caractéristiques cliniques et administratives, il devient possible d’anticiper la charge en lits et d’améliorer la planification des ressources hospitalières. Cette approche offre ainsi un outil d’aide à la décision pour optimiser la gestion des admissions et réduire la congestion des services.

2.5.11 Utilité de l’analyse prescriptive au service des urgences et aux hôpitaux

Dans les services d’urgence, l’analyse prescriptive permet d’optimiser les décisions et le processus en temps réel. Elle peut prédire les périodes de fort achalandage aux services d’urgence, afin d’anticiper et recommander des ajustements de personnel ou d’autres ressources. Elle pourrait suggérer le nombre optimal des médecins, d’infirmières et de techniciens à avoir sur place à différents moments de la journée en fonction des tendances historiques et actuelles de l’afflux de patients (Jacquemet, 2014).

2.6 Synthèse critique

L’ensemble des approches examinées met en évidence le rôle indispensable de l’analytique de données pour améliorer la gestion des urgences. Chacune apporte une contribution spécifique tout en présentant certaines limites. L’analyse descriptive permet de comprendre les tendances passées et d’identifier les variables clés, tandis que l’analyse prédictive facilite l’anticipation des flux de patients et des besoins en ressources. Les méthodes d’apprentissage supervisé, notamment les algorithmes de régression, offrent des prédictions précises, mais leur fiabilité repose sur la disponibilité de données de qualité et sur leur caractère interprétable. Enfin, l’analyse prescriptive complète ces approches en traduisant les résultats scientifiques en recommandations opérationnelles concrètes, susceptibles de guider la prise de décision des gestionnaires.

2.7 Application des méthodes analytiques au contexte de l’Hôpital de la Cité-de-la-Santé de Laval

En combinant ces approches, notre projet vise à optimiser la planification des admissions, réduire les temps d’attente et fournir aux gestionnaires un outil décisionnel robuste, tout en prenant en compte les spécificités locales et les contraintes organisationnelles.

2.8 Conclusion

Dans ce chapitre, nous avons exploré les différentes approches proposées dans la littérature pour résoudre le problème du temps d’attente des patients sur civière. Le prochain chapitre aborde l’approche méthodologique que nous utilisons dans notre recherche.

CHAPITRE 3

DÉMARCHE MÉTHODOLOGIQUE DE RECHERCHE

Dans ce chapitre, nous présentons l'approche méthodologique adoptée pour notre recherche ainsi que les instruments de collecte de données. La section 3.1 aborde le but et la pertinence du projet. La section 3.2 présente la démarche méthodologique. La section 3.3 décrit la méthode de collecte des données. La section 3.4 présente les systèmes d'information organisationnels utilisés, ainsi que les variables et les mesures. La section 3.5 explicite l'utilisation de l'outil de collecte de données. La section 3.6 explique comment tester la robustesse et l'efficacité des outils. La section 3.7 aborde la confidentialité des données. La section 3.8 présente notre certificat d'éthique de recherche. La section 3.9 détaille les instruments de mesure. La section 3.10 explique l'analyse des données. Enfin, la section 3.11 offre une brève conclusion.

3.1 But et pertinence du projet

3.1.1 But du projet

Le but de notre projet vise à améliorer le processus d'admission des patients à l'urgence de l'hôpital de la Cité-de-la-Santé de Laval.

3.1.2 Pertinence pour le Projet

Le développement d'un tableau de bord descriptif, ainsi que la création de modèles prédictifs et prescriptifs, sont essentiels pour améliorer la gestion des admissions des patients à l'urgence. Ces outils analytiques aideront le directeur adjoint de la performance et la qualité, ainsi que le responsable de l'urgence, à mieux comprendre et gérer les flux de patients, contribuant ainsi à réduire le temps d'attente des patients en optimisant les processus décisionnels et opérationnels, et en facilitant une allocation plus efficace des ressources.

3.1.3 Critères de Succès/Évaluation

- **Utilité du Tableau de Bord** : évaluer par sa capacité à fournir des informations claires et utiles, ainsi que par la satisfaction des utilisateurs finaux (directeur adjoint de la performance, responsable de l'urgence).

- **Précision des modèles** : La précision des modèles prédictifs et prescriptifs sera mesurée par leur capacité à prédire avec exactitude les temps d'attente et les besoins en ressources avec une précision supérieure à 80 %.
- **Réduction du temps d'attente** : L'objectif est de démontrer une diminution mesurable, par exemple une réduction de 15 % des temps d'attente moyens, après la mise en œuvre des outils.
- **Adoption et Intégration** : évaluée par l'utilisation régulière des outils et leur intégration efficace dans les opérations quotidiennes.

3.2 Présentation de démarche méthodologique

3.2.1 Choix méthodologique

Dans le cadre de cette étude, en s'appuyant sur les travaux de Thompson et al. (2020) et de Lin *et al.* (2017), publiés dans *MIS Quarterly*, qui démontrent le rôle des technologies de l'information (TI) et de l'analyse des données, nous examinerons comment ces outils facilitent l'évolution des soins médicaux vers des approches moins intensives et plus préventives. Ces études démontrent que les TI et l'analyse de données permettent d'anticiper les besoins des patients, d'améliorer la qualité des soins et de réduire les coûts des traitements médicaux intensifs.

Notre étude se concentre sur l'analyse des données des patients. Nous commencerons par une analyse descriptive de données des patients, en examinant la durée moyenne de séjour (DMS) à travers la création d'un tableau de bord descriptif. Ensuite, nous réaliserons une analyse prédictive en développant des modèles qui permettent de prédire la DMS des patients sur civière à l'urgence. Enfin, nous procéderons à une analyse prescriptive en élaborant des modèles prescriptifs utilisant le modèle linéaire pour assister les gestionnaires dans leurs prises de décision.

Cette stratégie permet d'évaluer les phénomènes étudiés par la collecte de données issues de divers systèmes informatiques liés aux patients, tels que le système d'urgence, le système d'hospitalisation, le système d'imagerie médicale et le système de ressources humaines. Cette méthode permet de mesurer avec précision les variables relatives au temps passé par les patients sur civière à l'urgence. Elle permet aussi de détecter des tendances, des corrélations ou des différences significatives au sein de la cohorte étudiée. C'est pourquoi nous avons opté pour une méthodologie quantitative, inspirée des recherches de Wen *et al* (2024) et la mémoire de recherche de Renaud (2021).

La méthodologie quantitative facilite l'obtention de conclusions fondées sur des données quantifiables, ce qui permet de formuler des recommandations spécifiques pour améliorer l'efficacité des services d'urgence. Elle permet de quantifier les variables liées au temps passé sur les civières et d'identifier des tendances, des corrélations ou des différences significatives au sein de la population étudiée.

Pour interagir avec ces données, nous avons utilisé l'outil T-SQL (Transact-SQL) de Microsoft SQL Server. Dans le cadre de l'analyse descriptive des données, nous avons choisi l'outil Power BI qui facilite la création de diagrammes, de visualisations interactives, de rapports personnalisés et l'exploration statistique. Dans le cadre de l'analyse prédictive, le langage *Python* est utilisé pour développer des modèles prédictifs. Pour développer différents modèles prédictifs à l'aide des algorithmes d'apprentissage automatique supervisé. Ces algorithmes comprennent la régression linéaire, *KNN*, l'arbre de décision, les forêts aléatoires, et les réseaux neuronaux (Pak *et al.*, 2021). Dans le cadre de l'analyse prescriptive, l'application d'un modèle linéaire vise à améliorer la gestion de la DMS. Nous avons utilisé aussi le langage *Python* pour appliquer le modèle linéaire et trouver des solutions d'optimisation de la gestion de la DMS (Lopes *et al.*, 2023).

3.2.2 L'approche méthodologique

Notre recherche débutera par l'implémentation d'un tableau de bord descriptif du rôle opérationnel (Coutin et Vaucel, 2014). Il est alimenté par des données issues de l'entrepôt de données de l'Infocentre, lequel recueille des informations provenant de différents systèmes sources. Il fournit une analyse précise de la situation de l'urgence en fonction des variables influençant la DMS des patients sur civière à l'urgence. Cette étape permet de comprendre les dynamiques actuelles et les défis rencontrés dans la gestion de l'urgence.

Ensuite, nous développerons un modèle prédictif (Carter et Potts, 2014) pour prédire la DMS des patients sur civière en s'appuyant sur une série de variables liées à l'environnement de l'urgence. L'utilisation des techniques d'analyse prédictive permettra d'identifier les facteurs les plus influents sur la DMS des patients sur civière à l'urgence et de prévoir ses variations en fonction des changements anticipés dans ces variables.

Enfin, nous créerons un modèle prescriptif (Lopes *et al.*, 2023 ; Pettit *et al.*, 2024) pour orienter les gestionnaires et le personnel médical, y compris les médecins, vers les meilleures stratégies d'intervention pour optimiser la DMS. En s'appuyant sur les informations issues de l'analyse des données et du modèle

prédictif, l'analyse prescriptive proposera des actions concrètes visant à améliorer l'efficacité opérationnelle et le processus de prise en charge des patients à l'urgence.

Cette recherche se concentre sur les aspects opérationnels et organisationnels affectant la DMS à l'urgence, notamment les processus d'admission, la gestion de la disponibilité des lits, et les flux de patients. L'approche choisie promet une compréhension approfondie des mécanismes régissant la DMS et vise à fournir des solutions pratiques pour améliorer la performance des services d'urgence.

3.3 Collecte de données

3.3.1 Période d'étude et population

Notre étude couvre la période du 1er janvier 2021 au 31 décembre 2023 et compare trois périodes équivalentes. La durée est divisée en périodes saisonnières pour une analyse détaillée, comme les séries temporelles, qui visent à révéler les tendances des périodes observées. L'objectif est d'analyser les données de tous les patients admis aux urgences et placés sur civière à l'hôpital de la Cité-de-la-Santé de Laval.

3.3.2 Échantillon

Pour développer le tableau de bord descriptif, nous utilisons l'ensemble de l'échantillon des patients afin de comprendre la situation de la DMS à l'urgence. Dans la partie du développement du modèle prédictif, la méthode d'échantillonnage est probabiliste (tous les patients de la période mentionnée ont une chance connue d'être inclus, comme l'échantillonnage aléatoire simple). Pour le partitionnement, on aura deux ensembles : un ensemble d'entraînement pour bâtir le modèle et un ensemble de validation pour évaluer la performance sur de nouvelles données. Donc, 80 % des données seront utilisées comme les données d'entraînement et 20 % pour les données de validation.

Pour l'algorithme de série temporelle afin de comparer la saisonnalité entre les périodes. L'échantillon est divisé en deux ensembles : l'ensemble d'entraînement pour la période du 1er janvier 2021 au 31 décembre 2022 et l'ensemble de validation pour la période du 1er janvier 2023 au 31 décembre 2023.

3.4 Les systèmes d'information organisationnels

L'analyse des dossiers médicaux et des données opérationnelles révèle des informations précises sur la DMS des patients à l'urgence. Dans la section 4.4.1, nous présentons les différents systèmes d'information. Dans la section 4.4.2, nous décrivons les variables qui peuvent être utilisées.

3.4.1 Les différents systèmes d'information

Les informations proviennent des bases de données du système d'urgence, du système d'hospitalisation, du système d'imagerie, et du système de ressources humaines.

- **Urgence** : Le système *Medurg* de l'urgence contient toutes les informations sur les patients et leurs demandes, incluant les consultations spécialisées, les examens supplémentaires (comme imagerie) et les admissions à l'hôpital.
- **Hospitalisation** : Le système ADT, appelé *Clinibase_CI*, enregistre les admissions hospitalières, les états des lits (disponibles ou occupés), les congés prévus quotidiennement, les congés validés et les départs des patients de l'hôpital.
- **Imagerie** : Le système *Radimag* fournit l'état des requêtes d'examens au service d'imagerie en indiquant leur état de réalisation à savoir si elles sont non saisies, non réalisées, réalisées, à dicter et dictées.
- **Ressources humaines** : Le système *Espresso* permet de consulter l'horaire du personnel médical et paramédical disponible à l'urgence, tandis que le système *Pétal* fournit l'horaire des médecins.

3.4.2 Les données utilisées pour le tableau de bord (Variables et Mesures)

Pour analyser la DMS des patients sur civière, il est essentiel de sélectionner et de catégoriser les variables en différents sous-ensembles, en tenant compte de leur pertinence clinique et organisationnelle (Goldschmidt et Matthews, 2022). Cette démarche garantit que le tableau de bord fournit une vue complète et opérationnelle des facteurs influençant la DMS.

3.4.2.1 Critères de sélection des variables

- a. **Variables temporelles** : Année, période, jour, quart de séjour (minuit à 7 h, 7 h à 16 h, 16 h à minuit). Les variations temporelles influencent l'affluence et la disponibilité des ressources, permettant de détecter les périodes critiques et d'anticiper les pics d'occupation.

- b. Variables organisationnelles : Unité de soins, secteur, spécialité, type d'examens (imagerie). Ces variables identifient les départements ou services qui contribuent le plus aux délais, permettant de cibler les interventions organisationnelles.
- c. Variables liées au patient : Âge, sexe. L'âge peut influencer la complexité des soins et donc la durée du séjour. Le sexe peut révéler des différences dans les parcours de soins et la DMS.
- d. Raison de la consultation : Motif de visite à l'urgence. Elle permet de relier la DMS à la gravité ou à la nature des pathologies, afin d'adapter les ressources aux besoins spécifiques des patients.
- e. Priorité de triage : Niveaux d'urgence (P1 à P5) évalués par le personnel de triage. La priorité de triage influence directement la DMS et la séquence de prise en charge des patients.
- f. Variables opérationnelles :
 - Date et heure d'arrivée à l'urgence : Influence de l'affluence et de la disponibilité du personnel.
 - Durée d'attente pour un médecin spécialiste et pour les examens complémentaires.
 - Nombre de tests diagnostiques réalisés.
 - Nombre de lits disponibles pour l'hospitalisation.

Ces variables reflètent les contraintes logistiques et organisationnelles qui prolongent la DMS.

- Les variables contextuelles relatives aux ressources de l'urgence, telles que le nombre de civières ainsi que la disponibilité des médecins et des infirmiers, définissent la capacité du service à répondre à la demande et à assurer un flux efficient des patients..

g. Variables de sortie :

- Résultat du séjour : admission, transfert, départ médicalement décidé ou décès.
- Date et heure de départ de l'urgence.

Ces données permettent de calculer la DMS réelle et d'évaluer l'efficacité du processus de prise en charge.

3.4.2.2 Mesures dérivées

À partir de ces variables, le tableau de bord permettra de suivre :

- Nombre total de patients en attente sur civière.
- Durée totale et moyenne d'attente sur civière.
- Temps d'attente pour consultation spécialisée et examens complémentaires.

- Durée d'attente pour admission à l'hôpital ou opération.
- Ressources disponibles : médecins, infirmiers, examens d'imagerie, lits et congés planifiés.

3.4.3 Analyse critique

La sélection des variables combine des facteurs cliniques, organisationnels et contextuels, garantissant une approche holistique pour comprendre la DMS. Les variables choisies permettent d'identifier les goulots d'étranglement, d'anticiper les besoins en ressources et d'élaborer des recommandations opérationnelles concrètes pour réduire les temps d'attente.

3.4.4 Lien opérationnel

En combinant ces variables dans un tableau de bord interactif, l'hôpital peut obtenir une vue d'ensemble des facteurs influençant la DMS des patients sur civière, visualiser en temps réel les contraintes opérationnelles et anticiper les périodes de forte affluence, permettant ainsi d'identifier les domaines d'amélioration et d'optimiser la gestion des flux de patients et l'efficacité globale du service d'urgence.

3.5 Outil de collecte de données

Après la collecte des données, nous les avons nettoyées et préparées avec T-SQL. Par la suite, nous avons créé des procédures stockées pour importer les données dans les tables du datamart¹ *Urgence_DMS*. Ensuite, nous avons développé des vues spécifiques pour structurer les jeux de données provenant de différents systèmes (Annexe F) :

- **Liste des patients placés sur civière** : Vue qui contient la liste des patients sur civière à l'urgence.
- **Liste des demandes d'examens en imagerie** : Vue qui contient la liste des patients sur civière en attente d'examens au service de l'imagerie.
- **Liste des demandes d'admission (hospitalisation)** : Vue qui contient la liste des patients sur civière en attente d'un lit vacant pour une hospitalisation.
- **Liste des demandes de consultation spécialisée** : Vue qui contient la liste des patients sur civière en attente d'une consultation spécialisée.

¹ Un datamart est une sorte de base de données qui est orientée sujet et conçue pour répondre aux besoins spécifiques d'un groupe d'utilisateurs ou d'un département au sein d'une organisation.

- **Liste des demandes des examens en imagerie** : Vue qui contient la liste des patients sur civière en attentes d'examens au service de l'imagerie.
- **Liste des examens en Imagerie** : Vue qui contient la liste de tous les examens en imagerie.
- **Liste des lits à l'hôpital** : Vue qui contient la liste des patients hospitalisés et l'état des lits, les congés prévus, les congés signés et les départs.
- **Liste des demandes en chirurgie** : Vue qui contient la liste des patients sur civière en attente d'une chirurgie
- **Liste du personnel à l'urgence** : Vue qui contient la liste du personnel médical disponible à l'urgence selon leurs horaires.

Ces jeux de données sont également utilisés pour le développement d'algorithmes prédictifs. Dans le cadre de l'analyse prescriptive, l'application d'un modèle linéaire vise à optimiser la gestion de la DMS.

3.6 Test de robustesse de l'outil

Des tests de validation sont effectués pour confirmer la précision des données collectées. Ensuite, une validation a été réalisée avec les parties prenantes à l'hôpital pour vérifier l'exactitude des données produites à travers les différentes vues.

3.7 Confidentialité des données

Dans notre étude, nous avons garanti la confidentialité des données des patients. Les informations recueillies étaient anonymes et ne contenaient que le numéro de dossier, sans données personnelles. Elles sont stockées de manière sécurisée sur le serveur de l'hôpital de la Cité-de-la-Santé de Laval. Elles ne sont accessibles qu'au directeur de la recherche et à l'auteur du mémoire. Ces données seront conservées pendant cinq ans, puis supprimées. Des mesures de sécurité spécifiques sont également appliquées aux données dans l'entrepôt :

- Anonymisation : Toutes les données collectées sont anonymes dès le début du processus. Les identifiants personnels sont supprimés des jeux de données. Le nom et le prénom des personnels médicaux sont remplacés par les trois premières lettres du nom et la première lettre du prénom.
- Sécurité des données : Les données sont stockées dans des serveurs SQL sécurisés par le service de l'infrastructure du CISSS de Laval.
- Contrôle d'accès : L'accès aux données est limité aux membres de l'équipe de recherche.

3.8 Certificat d'éthique

Étant donné que notre projet de recherche implique la collecte de données auprès des patients à l'hôpital, nous avons complété la formation en éthique de la recherche basée sur l'énoncé de politiques des trois Conseils : « Éthique de la recherche avec des êtres humains » (EPTC 2: FER 2022) (Annexe G). Nous avons soumis une demande d'approbation à la DQEPE de l'hôpital de la cité-de-la-santé de Laval et avons obtenu un certificat d'éthique validant la conformité de notre procédure de collecte de données aux normes éthiques (Annexe H).

3.9 Instruments de mesure

L'analyse descriptive des données est effectuée à l'aide de l'outil Power BI avec l'intégration de python pour les visualisations avancées. Ils simplifient la création de rapports grâce à des interfaces interactives et facilitent l'exploration de données à partir de différentes vues. Lorsque le tableau de bord sera validé avec les parties prenantes, il sera publié dans un espace de travail sécurisé et partagé avec les gestionnaires et les utilisateurs concernés (Coutin et Vaucel, 2014). Cet outil aidera à améliorer l'analyse et la prise de décision basée sur les données de l'organisation.

Pour l'analyse prédictive, on utilise le langage R pour développer des modèles, notamment la régression linéaire, *KNN*, l'arbre de décision, les forêts aléatoires, et les réseaux neuronaux (Pak *et al.*, 2021).

Pour l'analyse prescriptive, le langage Python est choisi pour appliquer un modèle linéaire à fin d'optimisée la DSM (Lopes *et al.*, 2023). Ce modèle est basé sur trois éléments principaux :

- Les variables de décision : Identification des variables décisionnelles qui influencent la DMS.
- La fonction objective : Minimiser la DMS des patients sur civière.
- Les contraintes : prise en compte des limites opérationnelles, telles que les capacités d'accueil et les ressources humaines disponibles.

Après avoir établi ces bases, des solutions seront explorées pour trouver l'optimisation la plus efficace de la gestion de la DMS (J Alapont *et al.*, 2005).

3.10 Analyse de données

Après avoir recueilli et préparé les données, nous entamons le processus d'analyse. Dans la sous-section 4.9.1, nous présentons le tableau de bord descriptif. Dans la sous-section 4.9.2, nous présentons les modèles prédictifs. Dans la sous-section 4.9.3, nous présentons le modèle prescriptif.

3.10.1 Tableau de bord descriptif : Évaluation de l'état de l'urgence selon la DMS

Pour comprendre la situation de l'urgence concernant la DMS des patients sur civière, il existe actuellement un tableau de bord général « Tableau de bord de fluidité du parcours des usagers à l'hôpital ». Ce tableau de bord offre une vue d'ensemble de la fluidité des patients à l'hôpital entre les différentes unités de service. Par exemple, il affiche en temps réel le taux d'occupation des patients à l'urgence, la durée de séjours des patients à l'urgence, le nombre de lits disponibles et le nombre de lits vacants. Pour notre projet, nous avons décidé d'explorer en détail le délai de séjours des patients sur civière. Nous créerons un tableau de bord descriptif qui servira de tremplin vers une analyse plus approfondie, plutôt que d'être une finalité en soi. Cela encourage l'évaluation et la synthèse des informations recueillies pour en tirer des conclusions pertinentes. Ce tableau de bord, appelé « Tableau de bord de la DMS » est publié sur l'infonuagique de l'hôpital de la cité-de-la-santé de Laval dans un espace de travail partagé avec les gestionnaires et les différentes parties prenantes concernées. L'accès à cet espace de travail est limité au personnel dédié (gestionnaires et médecins). Ce tableau de bord vise à examiner les événements passés pour en extraire des informations, qui serviront pour définir les variables à utiliser pour le modèle de prédiction. Il sera important d'identifier les facteurs affectant la DMS des patients sur civière (Driesen *et al.*, 2018). La conception de ce tableau de bord repose sur les mesures et les variables mentionnées dans la sous-section

3.10.2 Variables et mesures.

En collaboration avec les gestionnaires et les médecins responsables des urgences, nous identifierons, à partir du tableau de bord descriptif, les variables les plus influentes qui affectent la DMS (Driesen *et al.*, 2018). Ensuite, nous modéliserons les différents modèles prédictifs. En fonction de la nature du problème et de la précision des résultats de chaque modèle, le modèle le plus approprié sera choisi. Ce modèle sera utilisé pour prédire la DMS future selon des plages horaires bien définies (Carter et Potts, 2014).

3.10.3 Développement des modèles prédictifs

Notre méthode de prédiction de la DMS repose sur des algorithmes d'apprentissage automatique supervisés. Ces algorithmes sont adaptés à des données dont les résultats sont connus, ce qui correspond à notre variable cible : la DMS des patients sur civière. Les variables prédictives sont issues du tableau de bord descriptif et comprennent des informations temporelles, organisationnelles, cliniques et opérationnelles.

3.10.3.1 Qualité des données utilisées

La précision et la fiabilité des modèles prédictifs dépendent fortement de la qualité des données. Avant l'implémentation, nous avons évalué les données selon plusieurs critères :

- Complétude : vérification que les principales variables (âge, sexe, temps d'attente, disponibilité des lits, résultats des examens) ne contiennent pas de valeurs manquantes. Les données manquantes ont été traitées par imputation ou suppression selon le contexte.
- Exactitude : validation des données historiques par croisement avec plusieurs sources (dossiers électroniques).
- Cohérence : détection des incohérences logiques, par exemple, des heures de départ antérieures aux heures d'arrivée ou des durées d'attente négatives.
- Uniformité : standardisation des formats de date, d'heure et des unités de mesure pour garantir la compatibilité entre les différentes sources.
- Temporalité : contrôle que les séries temporelles respectent les intervalles réguliers nécessaires à l'analyse des tendances.

L'attention portée à ces aspects permet de réduire les biais et erreurs de prédiction, assurant que les modèles générés reflètent correctement les processus réels du service d'urgence.

3.10.3.2 Étapes implémentation en Python

a. Prétraitement des données

- Nettoyage des données : suppression des valeurs manquantes ou aberrantes, gestion des doublons.
- Sélection des variables prédictives : identification des variables les plus pertinentes en fonction de leur corrélation avec la DMS.

- Transformation des données : normalisation ou standardisation des variables continues, encodage des variables catégorielles.
 - Division de l'ensemble de données : 80 % pour l'entraînement et 20 % pour la validation.
- b. Analyse exploratoire et corrélations
- Visualisation de la DMS par rapport aux variables prédictives à l'aide de graphiques de dispersion, histogrammes et matrices de corrélation.
 - Identification des tendances et relations significatives.
- c. Développement des modèles prédictifs
- Régression linéaire : estimation de la relation entre la DMS et les variables prédictives.
 - K-Nearest Neighbors (KNN) : prédiction basée sur les observations les plus proches dans l'espace des caractéristiques.
 - Arbres de décision et forêts aléatoires : modélisation des relations non linéaires et réduction du risque de surapprentissage en combinant plusieurs arbres.
 - Gradient Boosting : amélioration successive des prédictions en corrigeant les erreurs des modèles précédents.
 - Séries temporelles : analyse des variations temporelles de la DMS pour anticiper les périodes de forte affluence. L'ensemble d'entraînement contient les données de 2021-2022 et l'ensemble de validation celles de 2023.
 - Réseaux de neurones : capture des relations complexes entre variables pour des prédictions précises.

3.10.3.3 Objectifs et avantages

Ce modèle de prévision a pour but d'anticiper la demande en fonction des tendances historiques, des périodes de pointe et des conditions spécifiques (saisons, nombre de médecins disponibles, nombres d'infirmières). Cela permet d'ajuster la planification des ressources (personnel, matériel, lits) de manière proactive. Optimisant ainsi leur gestion en fonction des besoins anticipés.

3.10.4 Modèle prescriptif d'aide à la décision

En partant du modèle prédictif, nous avons élaborer un modèle prescriptif (Fenies, 2011) pour assister les gestionnaires dans leurs prises de décision. Ce modèle intégrera différentes variables et facteurs influençant la DMS des patients sur civière, afin de proposer des actions concrètes (El Oualidi et Saadi,

2013 ; Kadri *et al.*, 2014). Le développement de ce modèle prescriptif se fera en utilisant le langage Python et en appliquant un modèle linéaire (Lopes *et al.*, 2023). Il est basé sur :

- Les variables de décision : Identification des variables de décision qui influencent la DMS.
- La fonction objective : Établir l'objectif quantitatif, qui est de minimiser la DMS des patients sur civière à l'urgence.
- Les contraintes : prise en compte des limites opérationnelles, telles que les capacités d'accueil et les ressources humaines disponibles.

Il est essentiel d'explorer des solutions pour optimiser la gestion de la DMS (J Alapont *et al.*, 2005). En utilisant le langage Python, nous chercherons à minimiser la DMS des patients sur civière en ajustant les variables de décision tout en respectant des contraintes spécifiées. Cette approche, soutenue par des analyses prédictives, permettra de prendre des décisions éclairées.

3.11 Conclusion

Nous avons décrit notre méthodologie de recherche, qui adopte une approche quantitative intégrant l'analytique descriptive, prédictive et prescriptive. Nous avons présenté les outils de collecte de données, les systèmes d'information, ainsi que les variables et mesures employées. Les aspects relatifs à la confidentialité des données, à l'acquisition du certificat d'éthique et à notre stratégie d'analyse des données ont été couverts. Dans le prochain chapitre, nous procéderons à l'implantation et à l'analyse des résultats du tableau de bord descriptif.

CHAPITRE 4

IMPLÉMENTATION ET ANALYSE DES RÉSULTATS DU TABLEAU DE BORD DESCRIPTIF

Ce chapitre traite de l'implémentation et de l'analyse des résultats du tableau de bord. La section 4.1 présente le tableau de bord descriptif. La section 4.2 analyse la répartition de la DMS des patients à l'urgence, tandis que la section 4.3 explore la distribution de la DMS sur civière. La section 4.4 compare la durée moyenne et la médiane de séjour sur civière pour mettre en évidence d'éventuels écarts. La section 4.5 s'intéresse à la relation entre la DMS sur civière et différents délais d'attente. La section 4.6 analyse les délais d'attente pour une consultation spécialisée, suivie par la section 4.7, qui se concentre sur les délais d'attente pour l'hospitalisation. La section 4.8 étudie les délais d'attente pour les examens d'imagerie. La section 4.9 examine l'impact du nombre d'infirmiers par rapport à la DMS, tandis que la section 4.10 examine l'impact du nombre de médecins sur la DMS sur civière. Enfin, la section 4.11 traite des chevauchements de flux à l'urgence, et la section 4.12 synthétise les principaux constats observés sur la DMS des patients à l'urgence entre 2021 et 2023. Enfin, la section 4.13 présente une conclusion générale des résultats obtenus.

4.1 Présentation du tableau de bord descriptif pour la DMS des patients à l'urgence

Le tableau de bord descriptif présenté offre une vue d'ensemble des données relatives à la durée de séjour des patients à l'urgence de l'hôpital de la Cité-de-la-Santé de Laval. Il analyse les tendances sur une période de trois ans (2021-2023) et met en lumière les points forts ainsi que les axes d'amélioration dans la gestion des flux de patients à l'urgence. Pour le développement des jeux de données, nous avons utilisé SQL, suivi de Power BI pour la visualisation des données. Enfin, l'utilisation de Python a permis de créer des graphiques plus clairs et détaillés, facilitant l'analyse des corrélations et des interactions entre différents paramètres.

4.2 Répartition de la durée moyenne de séjour des patients à l'urgence

4.2.1 Sommaire global de la durée de séjour des patients à l'urgence


- **Analyse de la durée de séjour globale des patients à l'urgence :** Les données montrent une augmentation significative de la durée moyenne de séjour à l'urgence, passant de 9,5 heures en 2021 à 11 heures en 2023, soit une hausse de 15,7 %. Cette augmentation concerne à la fois les patients ambulatoires et ceux sur civière (Figure 4-1).

- **Analyse de la durée de séjour des patients ambulatoires à l'urgence** : Pour les patients ambulatoires, le temps de passage a augmenté de 5,3 heures en 2021 à 5,9 heures en 2023 (Figure 4-1).
- **Analyse de la durée de séjour des patients sur civière à l'urgence** : Les patients sur civière présentent une durée de séjour nettement plus élevée que les patients ambulatoires. En 2021, leur durée moyenne de séjour (DMS) sur civière était de 15,7 heures, tandis que leur durée totale de séjour à l'urgence atteignait 17,2 heures. En 2022, la DMS sur civière est passée à 17,1 heures et la durée totale à 18,8 heures. En 2023, ces valeurs ont respectivement atteint 17,9 heures pour la DMS sur civière et 19,7 heures pour la durée totale, marquant une augmentation de 14,01 % sur trois ans (Figure 4-1).

Ces données indiquent que les patients sur civière représentent une part importante de l'augmentation globale de la durée moyenne de séjour. Dans la plupart des années, la durée de séjour sur civière est inférieure de 1 à 2 heures à la durée totale à l'urgence, ce qui est cohérent puisque cette dernière inclut d'autres étapes du parcours de soins, notamment le délai entre l'arrivée à l'urgence et la fin de la première évaluation.

Comparaison entre patients ambulatoires et patients sur civière : Comme attendu, la DMS des patients ambulatoires reste systématiquement inférieure à celle des patients sur civière. Cette différence s'explique par la complexité plus importante des soins requis pour les patients sur civière, ce qui prolonge leur temps de prise en charge.


Figure 4.1 sommaire globale de la durée de séjour des patients à l'urgence



4.2.2 Répartition détaillée de la DMS sur civière en 2023

Les durées de séjour à l'urgence présentent des variations mensuelles significatives. La durée totale varie entre 18,8 heures et 21,9 heures, tandis que la DMS sur civière varie de 17,4 heures à 20,9 heures. Les mois hivernaux, notamment décembre, janvier et février, enregistrent les durées les plus longues, atteignant jusqu'à 20,9 heures, une hausse attribuable à une augmentation de l'affluence ou à des pics d'activité à l'urgence durant cette période. Une tendance à la hausse est également observée dès le mois d'août (18,1 heures) et se poursuit en septembre (18,2 heures) et octobre (18,3 heures), pour atteindre 19 heures en novembre. Cette progression peut être liée à la reprise des activités après les vacances estivales. À l'inverse, le mois de juillet se distingue par une DMS sur civière la plus courte, à 15,8 heures, probablement en raison d'une fréquentation réduite de l'urgence pendant la période estivale (Figure 4-2).


Figure 4.2 sommaire globale de la durée de séjour des patients à l'urgence



- Analyse détaillée du mois de décembre :** La DMS sur civière au mois de décembre (Figure 4-3) montre une variation significative, allant de 15,6 heures à 24,8 heures. Le jour 16 se distingue avec la durée la plus longue, atteignant 24,8 heures.
 - Pic de durée :** Entre les jours 12 et 16, une augmentation notable des durées est observée, avec une DMS totale atteignant 24,2 heures le jour 12 et un maximum de 27,1 heures le jour 16. À partir du jour 17, la DMS décline progressivement pour atteindre un minimum de 15,6 heures le jour 20. Une légère hausse est ensuite constatée autour des jours 25 et 26.
 - Analyse des pics :** L'augmentation de la DMS sur civière durant le mois de décembre peut être attribuée à des facteurs saisonniers, tels que la surpopulation des urgences liée à la période des fêtes ou à des conditions météorologiques défavorables, entraînant une hausse des consultations. Pour mieux gérer ces périodes critiques, il est recommandé de planifier les ressources en fonction

des jours à haut risque et d'optimiser les flux de patients. Afin de réduire les durées de séjour excessives.


Figure 4.3 Répartition de la DMS des patients sur civière - décembre 2023



- Analyse détaillée du mois de juillet :** En juillet, le mois où la DMS sur civière est la plus basse de l'année à 15,8 heures, des variations quotidiennes notables sont observées. Les durées vont de 12,2 heures (jour 1) à 21,6 heures (jour 22), avec des hausses significatives à certains moments. Par exemple, une augmentation est relevée le jour 5 (19 heures), le jours 13 (17,7 heures), et durant les jours 15 à 17, où les DMS varient entre 16 et 18 heures. Les jours 22 et 23 enregistrent les pics les plus élevés, atteignant respectivement 21,6 heures et 17,9 heures (Figure 4-4).

Les variations reflètent un engorgement progressif des services d'urgence, potentiellement lié à des facteurs saisonniers. Les périodes de vacances estivales pourraient prolonger les durées de séjour en raison de la mobilité accrue des patients, de la disponibilité réduite du personnel médical. Pour mieux anticiper et gérer ces variations, il est essentiel d'analyser les facteurs sous-jacents, tels que la disponibilité des ressources, et de renforcer la planification des effectifs médicaux pendant les périodes critiques. Ces ajustements contribueraient à maintenir une efficacité optimale des services d'urgence, même pendant les mois habituellement plus calmes.


Figure 4.4 Répartition de la DMS des patients sur civière - juillet 2023



4.2.3 Répartition détaillée de la DMS sur civière en 2022


Pour l'année 2022, à partir du mois d'août (16,8 heures), la DMS augmente progressivement, atteignant 18,8 heures en septembre et un pic de 19,2 heures en octobre. Elle reste élevée jusqu'en janvier (18,5 heures), marquant les durées les plus longues à l'urgence. À l'inverse, les mois de février (15,4 heures) et à juillet (16,04 heures) enregistrent les durées les plus courtes, reflétant une période d'activité réduite dans les services d'urgence (Figure 4-5).

Figure 4.5 Répartition de la DMS des patients sur civière en 2022




- **Analyse détaillée du mois d'octobre :** Le mois d'octobre montre des variations significatives dans les durées de séjour, particulièrement lors des fins de semaine. Les samedis 1er, 15 et 29 se démarquent avec des durées maximales de 22 heures, 28 heures et 21,2 heures, reflétant des dynamiques spécifiques en termes de fréquentation et de prise en charge (Figure 4-6).

Figure 4.6 Répartition de la DMS des patients sur civière - octobre 2022



- **Analyse détaillée du mois de février :** Les valeurs journalières du mois de février montrent des variations significatives. Des pics sont observés les 1er (18,7 heures), 2 (21,2 heures), 3 (22,3 heures), 17 (19,7 heures) et 26 (17,8 heures), correspondant à des journées où la durée moyenne de séjour à l'urgence est particulièrement élevée. À l'inverse, des durées plus basses, comprises entre 12,0 heures et 14,9 heures, sont enregistrées les 6, 10, 12, 13, 18, 22 et 28 (Figure 4-7).


Figure 4.7 Répartition de la DMS des patients sur civière - février 2022



4.2.4 Répartition détaillée de la DMS sur civière en 2021

On constate à partir du mois d'août (15,8 heures) une légère augmentation de la DMS. Cette tendance se poursuit en septembre (16,4 heures) et atteint un pic en décembre à 18,7 heures. Cependant, la DMS reste élevée jusqu'en janvier, avec 15,9 heures. Cependant, les mois de février (14,9 heures) jusqu'en juillet (14,07 heures) présentent les durées les plus courtes, ce qui pourrait indiquer une période moins chargée dans les services d'urgence durant ces mois (Figure 4-8).

Figure 4.8 Répartition de la DMS des patients sur civière en 2021



Pour la période étudiée (2021-2023), la variation de la DMS des patients sur civière selon le mois de l'année révèle une saisonnalité marquée. D'août à janvier, la DMS augmente progressivement, atteignant un pic en décembre, avant de redescendre. En revanche, pour le reste de l'année, la DMS reste relativement stable, avec un minimum observé en juillet, où la DMS est la plus courte.

4.2.5 Répartition de la DMS des patients sur civière selon le type d'orientation

Les patients rentrant chez eux présentent des durées de séjour nettement plus courtes que celles des patients hospitalisés, avec une DMS évoluant de 12 heures en 2021 à 12,5 heures en 2022, puis à 13,4 heures en 2023 (Figure 4-9). La situation est différente pour les patients hospitalisés. Dans ce cas, une

augmentation significative de la DMS est observée, passant de 19,4 heures en 2021 à 22,4 heures en 2023 (Figure 4-10). Ainsi, les patients en attente d'un lit pour hospitalisation passent significativement plus de temps à l'urgence que ceux qui retournent à leur domicile.

Figure 4.9 Répartition par type d'orientation « Retour à Domicile »






Figure 4.10 Répartition par type d'orientation « Admission Hospitalisation »

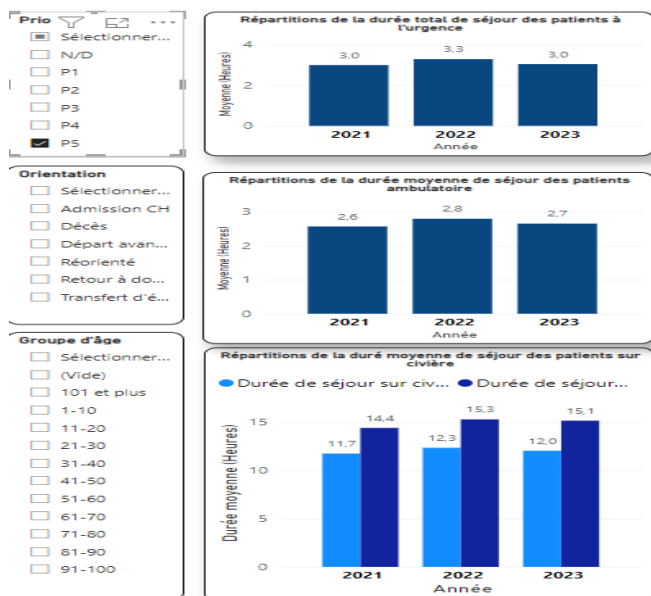


4.2.6 Répartition de la DMS des patients sur civière selon la priorité

La DMS des patients sur civière varie significativement en fonction des priorités. Pour la priorité P5, elle reste stable à 11,7 heures en 2021, 12,3 heures en 2022 et 12 heures en 2023. Pour ce qui est de la priorité P4, elle augmente nettement, passant de 17 heures en 2021 à 20,2 heures en 2023. Les priorités P1 et P2 suivent également une tendance à la hausse, avec une DMS passant de 11,2 heures à 13 heures pour P1, et de 14,4 heures à 16,6 heures pour P2 sur la même période. Enfin, la DMS pour la priorité P3 progresse de 16,6 heures en 2021 à 18,7 heures en 2023. Ces chiffres montrent une tendance générale à la hausse, surtout pour les priorités P2, P3 et P4 (Figure 4-11).

Figure 4.11 Répartition détaillée de la DMS sur civière selon les niveaux de priorité






Les patients en priorité P1 et P5 affichent une moyenne identique de temps passé sur civière. De même, les patients en priorité P2, P3 et P4 présentent des moyennes de durée de séjour très similaires. Cela soulève des questions sur l'efficacité du processus de gestion des priorités et appelle à une révision pour garantir que les priorités reflètent correctement l'urgence des cas.

4.2.7 Répartition de la DMS des patients sur civière par groupe d'âge

La DMS des patients sur civière pour les patients âgés de 60 ans et moins est de 13,7 heures en 2021, de 14,4 heures en 2022 et de 15,9 heures en 2023 (Figure 4-12). Pour les patients âgés de 60 ans et plus, la durée moyenne de séjour (DMS) sur civière est notablement plus élevée, atteignant respectivement 17,5 heures en 2021, 19,6 heures en 2022, et 19,7 heures en 2023 (voir Figure 4-13).


Figure 4.12 Répartition détaillée de la DMS sur civière selon les groupes d'âge de 1 à 60 ans



Les patients âgés de plus de 60 ans ont donc une durée moyenne de séjour sur civière nettement supérieure à celle des patients de 60 ans et moins, avec une augmentation progressive de 2021 à 2023

pour les deux groupes d'âge. Cette différence souligne l'importance d'identifier les facteurs qui prolongent le séjour des patients plus âgés afin d'améliorer la gestion et l'efficacité des services d'urgence.

Figure 4.13 Répartition détaillée de la DMS sur civière selon les groupes d'âge de 60 ans et plus




4.3 Distribution de la DMS sur civière

Dans cette sous-section, nous analysons en détail la distribution de la DMS sur civière selon divers critères, notamment la priorité de triage, l'intervalle de temps et l'orientation. Chaque série de graphiques comprend deux représentations : la première montre les données complètes sans nettoyage, tandis que la seconde applique un ajustement basé sur un IQR de 1,5 pour réduire l'influence des valeurs aberrantes.

4.3.1 Courbe loi normale


La distribution de la DMS sur civière (en bleu) et de la durée totale à l'urgence (en orange) est représentée sur une plage allant jusqu'à 500 heures (Figure 4-14). Une forte concentration est observée autour de 10 heures, avec une densité qui diminue rapidement au-delà, indiquant que la majorité des patients ont des séjours relativement courts. La DMS sur civière est de 16,95 heures, contre 18,63 heures pour la durée totale à l'urgence, ces moyennes étant influencées par des séjours plus longs. L'écart-type de 15,60 heures reflète une large dispersion, marquée par des valeurs aberrantes. Ces cas exceptionnels allongent les moyennes et augmentent la variabilité des résultats.

Figure 4.14 Courbe loi normale de la distribution de la DMS des patients sur civière



Après élimination des données aberrantes (Figure 4-15), la plage est limitée à 50 heures, ce qui met en évidence une concentration centrale des séjours entre 0 et 15 heures, avec une densité maximale entre 0 et 10 heures. La moyenne ajustée diminue à 14,28 heures pour les séjours sur civière et à 15,88 heures pour la durée totale à l'urgence, tandis que les écarts-types se réduisent respectivement à 9,67 et 9,95 heures. Ces ajustements reflètent une dispersion moindre et une meilleure représentation des tendances centrales, facilitant une analyse plus précise en réduisant l'influence des valeurs aberrantes.

Figure 4.15 Courbe loi normale distribution de la DMS sur civière par rapport à la DMS totale à l'urgence IQR=1.5




L'analyse des distributions révèle que la loi normale décrit bien la tendance centrale et la dispersion des durées de séjour, mais les valeurs aberrantes influencent la moyenne et l'écart-type. L'ajustement par l'IQR (Interquartile) réduit cet impact, offrant une représentation plus précise des durées courantes.

4.3.2 Courbe loi exponentielle


La distribution exponentielle modélise les processus à déclin constant, comme les temps d'attente avant un événement. Elle modélise les séjours courts, avec une concentration autour de 10 heures et une décroissance rapide (Figure 4-16). Cependant, des écarts apparaissent dans les premières heures, où les données réelles dépassent les prévisions. La distribution empirique (courbe verte) présente une forte asymétrie, avec une densité élevée au début suivie d'une décroissance progressive. L'ajustement exponentiel (courbe bleue pointillée) capture globalement cette tendance, bien que les premières heures soient légèrement surreprésentées. Le paramètre exponentiel, $\lambda = 0,06$, reflète une décroissance cohérente avec la traîne observée.

Figure 4.16 Courbe Loi exponentielle : Distribution de la DMS des patients sur civière



Après nettoyage des données aberrantes (Figure 4-17), la distribution empirique (courbe verte) montre une concentration accrue dans les premières heures et une traîne plus courte par rapport à la Figure 4-16. L'ajustement exponentiel (courbe bleue pointillée) s'aligne mieux avec la partie centrale de la distribution, avec un paramètre lambda ($\lambda = 0,07$) indiquant une décroissance plus rapide. L'application de l'IQR a réduit l'impact des valeurs aberrantes, rendant l'ajustement exponentiel plus précis pour les durées courtes.

Figure 4.17 Courbe Loi exponentielle : Distribution de la DMS des patients sur civière IQR=1.5



L'analyse des courbes montre que la loi exponentielle modélise bien la décroissance des durées de séjour, mais reste limitée pour les premières heures où la densité réelle est plus élevée. La réduction des valeurs aberrantes permet un ajustement précis centré sur les données courantes. Cependant, cette loi ne reflète pas les irrégularités ni les valeurs aberrantes.


4.3.3 Boîte à moustache

La distribution de la DMS sur civière à l'urgence, représentée par une boîte à moustaches (Figure 4-18), offre une analyse détaillée des données, y compris les valeurs aberrantes. La durée médiane, de 13,65 heures, indique que la moitié des patients passent moins que ce temps sur civière. Une légère asymétrie est observée, avec une boîte élargie au-dessus de la médiane, reflétant des séjours exceptionnellement longs. Ces valeurs aberrantes, atteignant jusqu'à 250 heures, sont souvent associées à des cas complexes nécessitant des soins prolongés.

Après le nettoyage des données aberrantes (Figure 4-18), la durée médiane de séjour sur civière est de 13,85 heures, indiquant que la moitié des patients passent moins de ce temps sur civière. L'IQR, qui capture les 50 % centraux des durées de séjour, reflète une dispersion notable autour de la médiane, montrant que les variations restent significatives malgré l'élimination des valeurs aberrantes. Une asymétrie positive persiste, avec une boîte légèrement élargie au-dessus de la médiane, signalant l'existence de quelques séjours relativement longs. Les valeurs aberrantes restent présentes, indiquant des cas particuliers qui nécessitent une analyse approfondie. Cela pourrait aider à identifier des facteurs spécifiques contribuant à ces séjours prolongés et à optimiser la gestion des patients pour réduire ces exceptions.

L'analyse des données montre une légère asymétrie positive des durées de séjour sur civière, une dispersion notable autour de la médiane (14,34 heures pour les données complètes, 13,85 heures pour les données nettoyées), et la présence de valeurs aberrantes nécessitant une analyse approfondie pour améliorer la gestion des cas complexes.

Figure 4.18 Boîte à moustaches de la DMS des patients sur civière à l'urgence



4.3.4 Distribution de la durée de séjour des patients à l'urgence par intervalle — Test ANOVA


Nous effectuons une analyse de la variance (test ANOVA) afin de comparer les moyennes des durées de séjour sur civière entre différents intervalles de temps (00H-14H, 14H-18H, 18H-00H). Ce test permet d'évaluer s'il existe des différences significatives entre ces moyennes.

L'analyse ANOVA révèle des différences significatives dans les durées de séjour sur civière selon les intervalles horaires (Figure 4-19). La période 0 h – 14 h montre une variabilité modérée avec des durées relativement stables malgré quelques valeurs aberrantes. L'intervalle 14 h – 18 h, le plus problématique, présente une surcharge des services, une forte concentration des données et des anomalies marquées.

Enfin, la tranche 18 h – 0 h affiche des séjours plus homogènes, une distribution équilibrée et une variabilité réduite, suggérant une meilleure gestion ou une affluence moindre. Le p-value inférieure à 0,001 confirme que ces différences sont statistiquement significatives. Le diagramme illustre des écarts marqués, avec l'intervalle 14 h – 18 h affichant les durées les plus longues et la plus grande variabilité. Ces résultats soulignent l'importance d'analyser cette période pour identifier les causes de saturation et optimiser les ressources.

Après le nettoyage des données aberrantes (Figure 4-19), la variabilité des durées de séjour est réduite, offrant une vue plus représentative des tendances typiques. L'intervalle de 14 h – 18 h apparaît comme une période critique, avec une médiane significativement plus élevée et une variabilité importante, probablement liées à des pics d'affluence ou des contraintes opérationnelles. En revanche, les intervalles 0 h – 14 h et 18 h – 0 h présentent des médianes plus faibles, reflétant des périodes plus calmes ou une meilleure prise en charge. Les écarts-types, bien qu'élevés (8,91 à 9,57), indiquent une dispersion notable des données. Les tests statistiques (p-values < 0,001) et l'ANOVA confirment la significativité des différences entre les intervalles horaires, mettant en évidence l'impact des plages horaires sur la gestion des flux de patients.


Figure 4.19 Distribution de la DMS des patients sur civière à l'urgence par intervalle



4.3.5 Distribution de la durée de séjour des patients à l'urgence par priorité — Test ANOVA


Le test ANOVA sur la durée de séjour sur civière par priorité révèle des différences significatives (p -value < 0,001) entre les groupes de priorités. La durée moyenne de séjour varie de 10,93 heures (P1) à 16,83 heures (P4), avec une dispersion plus importante pour les priorités élevées (P2 à P4). La médiane et l'écart-type confirment une hétérogénéité notable selon le degré d'urgence, indiquant que la priorité impacte significativement la durée de séjour.

Figure 4.20 Distribution de la DMS des patients sur civière par Priorité



L'analyse met en évidence l'impact de la priorité sur la gestion des flux de patients, avec une variabilité particulièrement marquée pour certaines catégories, notamment P4. Ces résultats soulignent la nécessité d'explorer d'autres facteurs spécifiques.

Figure 4.21 Distribution de la DMS des patients sur civière par Priorité IQR =1,5




4.3.6 Distribution de la durée de séjour des patients à l'urgence par orientation — Test ANOVA

L'analyse de variance de la DMS sur civière selon le type d'orientation (Figure 4-22) révèle des différences significatives entre les groupes :

- Admission CH : Une DMS moyenne de 19,28 heures, avec une médiane de 17,43 heures, reflète un temps significatif passé sur civière, marqué par une forte variabilité.
- Décès : Une moyenne de 9,74 heures et une médiane de 6,98 heures indiquent une prise en charge rapide due à la gravité de l'état des patients.
- Départ avant prise en charge : La DMS est la plus courte, avec une moyenne de 4,21 heures et une médiane de 1,78 heure, traduisant des départs rapides.
- Retour à domicile : Une DMS moyenne de 11,19 heures et une médiane de 7,57 heures reflètent une durée modérée sur civière, bien qu'une certaine variabilité soit présente.
- Référé : Une médiane de 9,4 heures indique que la majorité des patients passent moins de 10 heures, malgré des variations liées aux processus administratifs.
- Réorienté : Une médiane de 2,34 heures montre une réorientation rapide vers un autre service.
- Transfert d'établissement : Une DMS médiane de 15,15 heures reflète le temps requis pour organiser le transfert.

Les écarts-types révèlent une forte variabilité pour l'Admission CH (14,35) et le Transfert d'établissement (14,93), tandis que le Départ avant prise en charge et la Réorientation présentent des dispersions faibles. Le test ANOVA confirme des différences significatives entre les types d'orientation (p -values < 0,001), soulignant l'impact de l'orientation sur la DMS sur civière.

Figure 4.22 Distribution de la DMS des patients sur civière à l'urgence par Orientation




Après nettoyage des données, l'analyse de variance révèle les médianes suivantes :

- Admission CH : 16,68 heures, reflétant des durées prolongées dues aux procédures d'admission.
- Décès : 6,96 heures, indiquant une prise en charge rapide dans des situations critiques.
- Départ avant prise en charge : 1,78 heure, traduisant des départs rapides avant toute intervention.
- Retour à domicile : 9,7 heures, correspondant à des durées modérées.
- Référé : 9,4 heures, c'est le temps nécessaire pour organiser un transfert vers une autre spécialité.
- Réorienté : 2,3 heures, indiquant une redirection rapide vers un autre service.
- Transfert d'établissement : 14,47 heures, témoignant des délais prolongés liés aux démarches administratives et cliniques pour le transfert.

Ces médianes reflètent une répartition logique des durées : des temps courts pour les départs avant prise en charge et les réorientations, et des durées plus longues pour l'admission hospitalière et les transferts d'établissement, où des processus plus complexes interviennent (Figure 4-23).

La DMS des patients sur civière varie significativement selon le type d'orientation. Les patients en Admission CH et Transferts d'établissement présentent les durées les plus longues, en raison des processus administratifs impliqués, tandis que ceux qui partent avant la prise en charge ou sont réorientés ont les séjours les plus courts. Ces résultats peuvent aider à optimiser la gestion des flux de patients, notamment pour réduire les délais liés aux transferts et aux admissions.

Figure 4.23 Distribution de la DMS des patients sur civière à l'urgence par Orientation



4.4 Comparaison entre la durée moyenne et la durée médiane de séjour des patients sur civière à l'urgence


L'objectif est d'analyser l'écart entre la durée moyenne et la durée médiane de séjour sur civière des patients à l'urgence, en décomposant les données par année, mois, jour, et en les ventilant par intervalle de temps. Cette analyse vise également à identifier les services ou spécialités où cet écart est le plus prononcé, permettant ainsi de mieux comprendre les variations spécifiques et leurs causes potentielles.

4.4.1 Analyse détaillée pour l'année 2023

L'analyse de la durée moyenne par rapport à la durée médiane révèle un écart moyen de 4,7 heures, suggérant l'influence de valeurs aberrantes qui allongent la durée moyenne. À l'échelle mensuelle, des


écarts significatifs sont observés, notamment en février (4,8 heures), mars (4,8 heures), septembre (4,8 heures), octobre (5,4 heures) et décembre (5,1 heures). Ces différences indiquent des périodes où des séjours prolongés affectent les moyennes, reflétant potentiellement une charge de travail accrue ou des complexités spécifiques dans la prise en charge des patients. Ces résultats peuvent orienter la gestion des ressources et la planification pour réduire les délais durant les périodes critiques identifiées (Figure 4-24).

Figure 4.24 Comparaison entre la durée moyenne et la durée médiane de séjour à l'urgence 2023



Analyse détaillée pour le mois de décembre : Le mois de décembre présente une différence élevée de 5,1 heures entre la durée moyenne et la médiane. L'analyse montre des variations marquées, avec des écarts significatifs de 8 à 10 heures, les 5, 13, 16, 20 et 25 décembre. Ces écarts sont dus à des séjours exceptionnellement longs qui augmentent la moyenne, bien que la majorité des patients aient des durées plus courtes. Les intervalles de l'après-midi (14 h→18 h) et de la soirée (18 h→0 h) se distinguent par des durées de séjour particulièrement longues, avec des moyennes élevées et des écarts notables entre moyenne et médiane. Ces périodes critiques pourraient refléter une augmentation de la fréquentation ou la prise en charge de cas plus complexes nécessitant des séjours prolongés.

Figure 4.25 Comparaison entre la DMS et la durée médiane de séjour des patients — décembre 2023



- **Liste des valeurs aberrantes :** La table présentée en Figure 4-26 met en évidence des séjours exceptionnellement prolongés sur civière à l'urgence, dépassant parfois les 100 heures, principalement chez des patients présentant des troubles psychiatriques associés à des comportements bizarres ou idées suicidaires. Ces patients ont passé entre 166 heures et 244,77 heures sur civière, soulignant des difficultés majeures dans leur prise en charge et leur orientation vers les unités spécialisées en psychiatrie. Ces données mettent en lumière la nécessité d'accorder une attention particulière à ce type de patients, en renforçant les ressources et les protocoles spécifiques pour optimiser leur prise en charge et réduire ces délais prolongés.

Figure 4.26 Liste des durées plus longues (valeurs aberrantes)

Date de début d'épisode	Épisode	NoDossier	Priorité	Orientation	Durée de séjour sur civière	Durée total de séjour à l'urgence	Raison de la visite
2023-12-12 14:53:24			P2	Admission CH	244,77	245,27	Comportement bizarre
2023-12-08 16:53:07			P2	Admission CH	168,24	168,37	Inquiétude face à la sécurité du patient
2023-12-06 14:50:17			P2	Admission CH	155,50	155,74	Comportement violent / homicide
2023-12-07 20:42:37			P2	Admission CH	144,13	144,23	Comportement bizarre
2023-12-10 05:26:50			P2	Admission CH	130,82	130,94	Comportement bizarre
2023-12-08 14:25:10			P2	Admission CH	123,99	124,09	Référence pour consultation
2023-12-29 16:14:40			P2	Admission CH	120,30	120,45	Intoxication
2023-12-13 21:23:47			P2	Admission CH	112,83	112,90	Comportement bizarre
2023-12-14 05:17:11			P2	Retour à domicile	105,59	106,32	Comportement bizarre
2023-12-04 04:57:20			P2	Admission CH	103,93	104,20	Intoxication
2023-12-02 08:17:59			P2	Admission CH	102,48	102,65	Comportement bizarre
2023-12-13 20:59:30			P3	Admission CH	101,20	102,14	Faiblesse générale
2023-12-29 21:58:57			P3	Admission CH	100,05	113,25	Anxiété / Crise situationnelle
2023-12-31 18:09:16			P4	Admission CH	98,66	98,77	Intoxication
2023-12-01 20:55:35			P4	Admission CH	90,59	91,02	Dyspnée
2023-12-14 16:18:39			P4	Admission CH	90,49	97,19	Anxiété / Crise situationnelle
2023-12-11 22:25:13			P2	Admission CH	89,41	89,63	Confusion
2023-12-15 12:54:21			P2	Admission CH	86,42	86,70	Syncope / Pré-syncope
2023-12-02 05:33:12			P3	Admission CH	85,57	85,72	Faiblesse générale
2023-12-15 04:30:08			P2	Admission CH	81,72	81,90	Comportement bizarre
2023-12-02 14:01:30			P3	Retour à domicile	81,46	81,64	COVID-19 suspecté / Exposition à une maladie contagieuse
2023-12-16 13:18:29			P2	Admission CH	79,87	80,13	Idées suicidaires
2023-12-02 14:53:27			P3	Admission CH	77,24	77,43	Dyspnée
2023-12-16 14:28:03			P4	Admission CH	76,88	80,66	Blessure au membre inférieur

- **Recommandation :** Une piste d'amélioration consisterait à envisager la création d'une unité spécialisée en psychiatrie, directement rattachée au service des urgences. Cette unité permettrait de prendre en charge efficacement les patients présentant des troubles comportementaux ou nécessitant une surveillance psychiatrique accrue. En centralisant les ressources spécialisées et en développant des protocoles adaptés, une telle structure pourrait non seulement réduire les temps d'attente sur civière, mais aussi optimiser la gestion des cas complexes. Placée à proximité des urgences générales, elle faciliterait une transition rapide tout en désengorgeant les services conventionnels. Cette initiative pourrait ainsi contribuer à améliorer la qualité des soins tout en limitant les encombrements et en garantissant une prise en charge plus adaptée aux besoins spécifiques de ces patients.


4.5 Distribution de la DMS en fonction des différents délais d'attente

4.5.1 Distribution globale de la DMS en fonction de différents délais d'attente

- **Délai d'attente des examens d'imagerie** : La majorité des valeurs de délai moyen d'attente des examens d'imagerie se concentrent autour de 1,8 heure. Les valeurs de Q1, médiane, et Q3 sont proches les unes des autres, ce qui indique une faible variabilité. Cela signifie que le délai d'attente pour l'imagerie est relativement constant. La moyenne est très proche de la médiane (1,83), ce qui indique une distribution symétrique des délais d'imagerie, sans valeurs aberrantes marquées.
- **Délai d'attente de consultation spécialisée** : La médiane des délais d'attente est de 8,11 heures, très proche de la valeur clé de 8 heures (Q1) et de 8,21 heures (Q3), mettant en évidence un délai d'attente significatif autour de 8 heures, avec une faible dispersion et une distribution symétrique. Ce délai d'attente pourrait contribuer à prolonger le temps total passé sur civière, surtout dans les cas complexes nécessitant plusieurs étapes de prise en charge.
- **Délai d'admission hospitalière** : la médiane des délais d'attente est d'environ 11,25 heures, avec une plage interquartile étroite entre 9,83 heures et 12,06 heures. Bien que la distribution soit symétrique et montre une faible variabilité, une attente pouvant atteindre 12 heures a un impact notable sur la durée de séjour des patients sur civière à l'urgence. Cela contribue à l'encombrement du service de l'urgence et souligne un potentiel d'amélioration des processus d'admission hospitalière.
- **Durée de séjour sur civière** : La moyenne est aux alentours de 22,13 heures, avec une médiane de 22,22 heures. L'analyse des valeurs de Q1, Q3, de la médiane et de la moyenne permet une comparaison précise des délais, révélant que la durée de séjour sur civière est particulièrement élevée.

La durée de séjour sur civière semble être fortement influencée par l'attente pour un lit d'hospitalisation. Les efforts d'optimisation devraient donc se concentrer sur la gestion des flux hospitaliers et la disponibilité des lits afin de réduire cette durée de séjour. Par ailleurs, les délais d'attente pour les consultations spécialisées, avec une médiane de 8 heures, méritent également d'être revus pour améliorer l'efficacité globale. Bien que les délais d'attente pour l'imagerie soient bien gérés, leur impact sur la durée totale du séjour sur civière reste limité. En comparant chaque délai à la durée totale de séjour, on constate que ces délais s'additionnent et contribuent à prolonger le séjour global. Par exemple, un délai d'attente pour une consultation spécialisée, suivi d'un délai pour l'imagerie, peut allonger significativement la durée totale de séjour, même si chaque délai pris individuellement reste relativement court.

Figure 4.27 Distribution de la DMS en fonction des délais d'attente



4.5.2 Distribution de la DMS des patients en fonction des différents délais d'attente par plage horaire

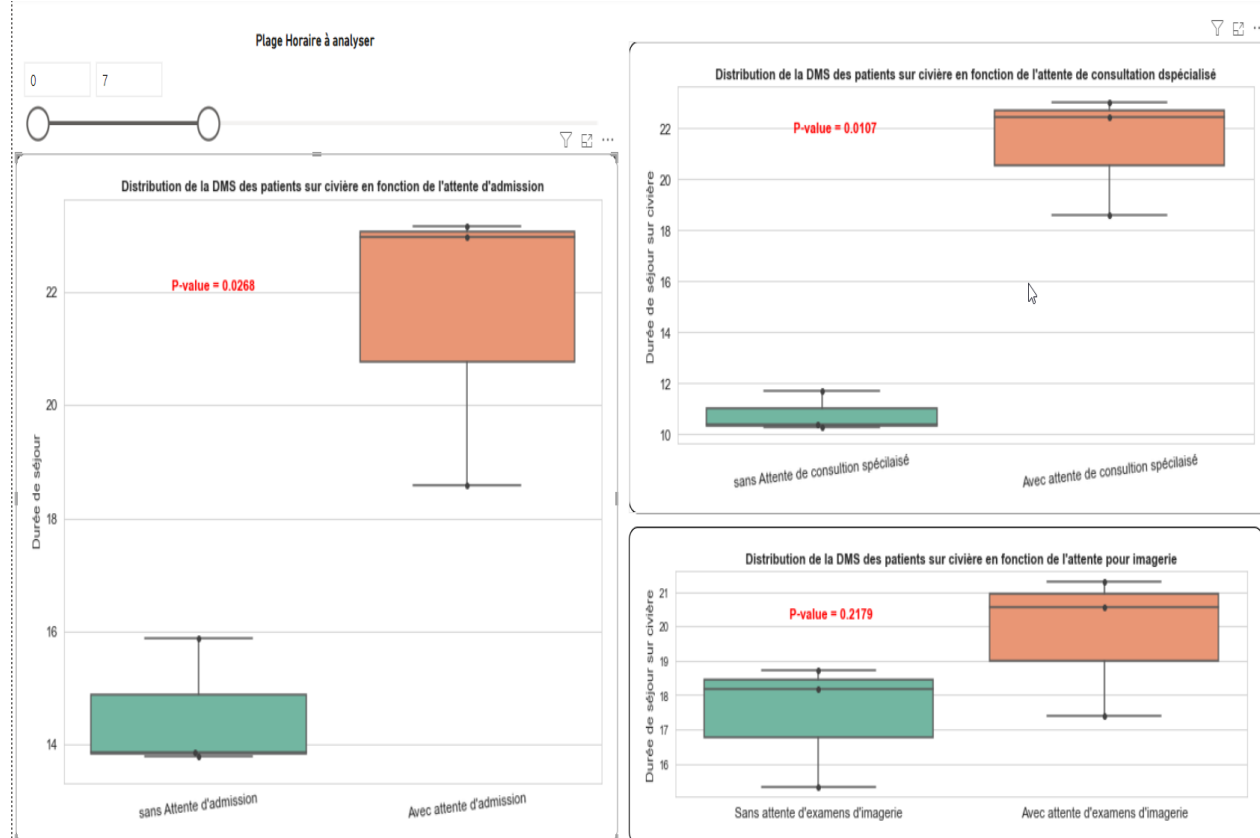
Pour analyser la DMS des patients sur civière selon leur attente, les données ont été réparties en deux groupes : avec et sans attente pour différents délais. Les plages horaires ont été divisées en trois segments : 00h-07h, 07h-16h, et 16h-00h.

4.5.2.1 Plage horaire : 0 h à 7 h

Nous avons analysé la DMS des patients sur civière pour la plage horaire de 0 h à 7 h selon trois types d'attente : admission hospitalière, consultation avec un médecin spécialiste et examen d'imagerie.

- **Attente d'admission hospitalière** : La DMS des patients avec attente d'admission est plus élevée que celle des patients sans attente d'admission. Le groupe « avec attente » montre une distribution étendue avec des valeurs plus élevées en moyenne. La P-Value est 0,026 8, qui est inférieure au seuil de 0,05, indiquant une différence statistiquement significative entre les deux groupes. Cela signifie que l'attente d'admission a un effet significatif sur l'augmentation de la durée de séjour sur civière entre 0 h et 7 h. L'attente pour un lit d'hospitalisation influence fortement la DMS des patients. Cette différence peut être liée à des délais administratifs ou à des contraintes de lits disponibles, qui prolongent la durée de séjour.
- **Attente de consultation spécialisée** : Les patients avec attente de consultation spécialisée ont une DMS plus élevée que ceux sans attente. La boîte à moustaches montre une distribution large et étendue pour les patients en attente, indiquant une plus grande variabilité dans la durée de séjour. De plus, la valeur de p est de 0,010 7, ce qui est inférieur au seuil de 0,05, indiquant ainsi une différence statistiquement significative. L'attente de consultation spécialisée a un impact significatif sur la DMS, augmentant la durée de séjour. Les consultations spécialisées constituent un facteur limitant pour réduire la DMS, probablement en raison de la disponibilité limitée des spécialistes la nuit. Cela pourrait indiquer un besoin de mieux coordonner ces consultations pour réduire l'impact sur la durée de séjour.
- **Attente pour un examen d'imagerie** : La DMS est légèrement plus élevée pour les patients avec attente d'examen d'imagerie, la différence entre les groupes est moins marquée par rapport aux deux autres types d'attente. Aussi, la P-Value de 0,217 9 qui est bien au-dessus de 0,05 indique qu'il n'y a pas de différence statistiquement significative entre les deux groupes. Cela suggère que l'attente pour un examen d'imagerie n'a pas d'impact majeur sur la DMS des patients entre 0 h et 7 h.

Figure 4.28 Distribution de la DMS par rapport aux délais d'attente (plage horaire : 00h-07h)



Parmi les trois types d'attente, l'attente d'admission et l'attente de consultation spécialisée montrent un impact significatif sur la DMS, avec des p-values inférieures à 0,05. Cela confirme que ces deux facteurs sont déterminants dans l'augmentation de la durée de séjour sur civière durant la nuit, et qu'une meilleure gestion de ces ressources pourrait potentiellement réduire la DMS.

4.5.2.2 Plage horaire : 7 h à 16 h

L'analyse de la DMS sur civière pour la période de 7 h à 16 h révèle des éléments significatifs pour les trois types d'attente étudiés :

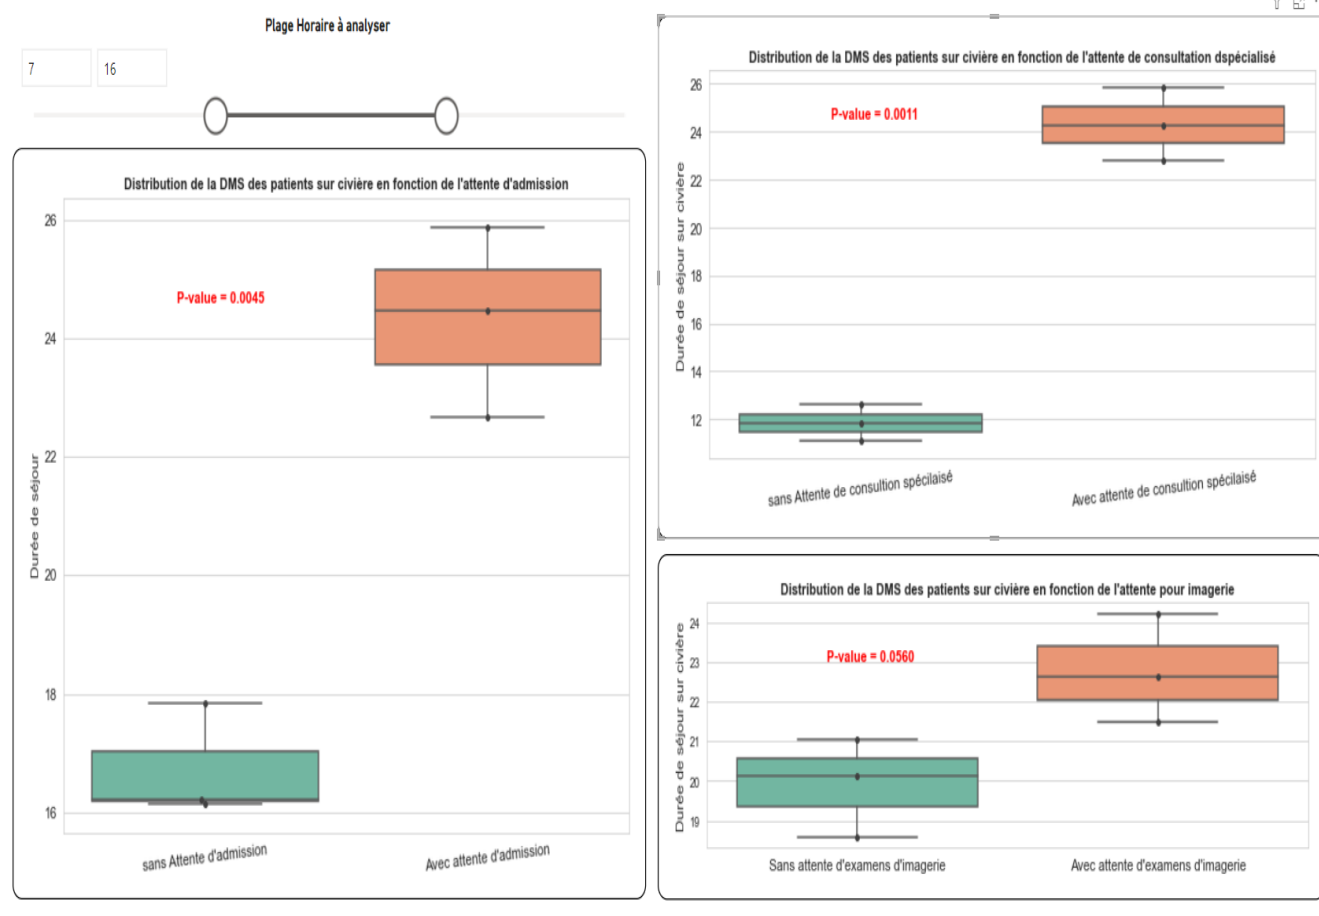
- Attente d'admission hospitalière : Les patients en attente d'admission présentent une DMS significativement plus élevée que ceux sans attente, avec une variation plus importante de la durée de séjour dans ce groupe. Le p-valeur de 0,004 5, inférieure au seuil de 0,05, confirme une différence statistiquement significative. Cela indique que l'attente pour un lit d'hospitalisation influence de manière notable l'augmentation de la durée moyenne de séjour (DMS) dans ce contexte. Ces résultats mettent en

évidence l'impact de l'attente d'admission sur la durée de séjour sur civière et soulignent l'importance d'améliorer les processus d'admission pour réduire la congestion.

- Attente de consultation spécialisée : Les patients en attente de consultation spécialisée présentent une DMS à la fois plus élevée et plus variable que ceux sans attente, reflétant une disparité notable dans les durées de séjour. La P-Value de 0,001 1, bien en dessous du seuil de 0,05, indique une différence statistiquement significative. Cela confirme que l'attente pour une consultation spécialisée influence significativement la DMS dans cette plage horaire. Cet impact marqué pourrait être attribué à une disponibilité limitée des spécialistes, soulignant la nécessité d'optimiser leur accès pour réduire les délais.
- Attente pour un examen d'imagerie : La DMS des patients en attente d'un examen d'imagerie est légèrement supérieure à celle des patients sans attente, bien que la différence soit moins marquée comparée aux deux autres types d'attente. La P-Value de 0,056 0, proche du seuil de 0,05, indique une tendance vers une différence statistiquement significative, mais reste légèrement au-dessus. Cela suggère que l'attente pour un examen d'imagerie pourrait avoir un impact sur la DMS, bien que cet effet soit modéré. L'optimisation des délais d'imagerie pourrait néanmoins contribuer à réduire la DMS, notamment dans des cas spécifiques.

Les analyses montrent que l'attente d'admission et de consultation spécialisée augmente significativement la DMS sur civière durant la journée, avec des p-values inférieures à 0,05 confirmant leur impact statistiquement significatif. En revanche, l'attente pour les examens d'imagerie présente une tendance à influencer la DMS, mais l'effet reste moins certain. Cette tendance mérite un suivi par des analyses complémentaires pour en évaluer pleinement l'importance.

Figure 4.29 Distribution de la DMS en fonction des délais d'attente (plage horaire : 07h-16h)



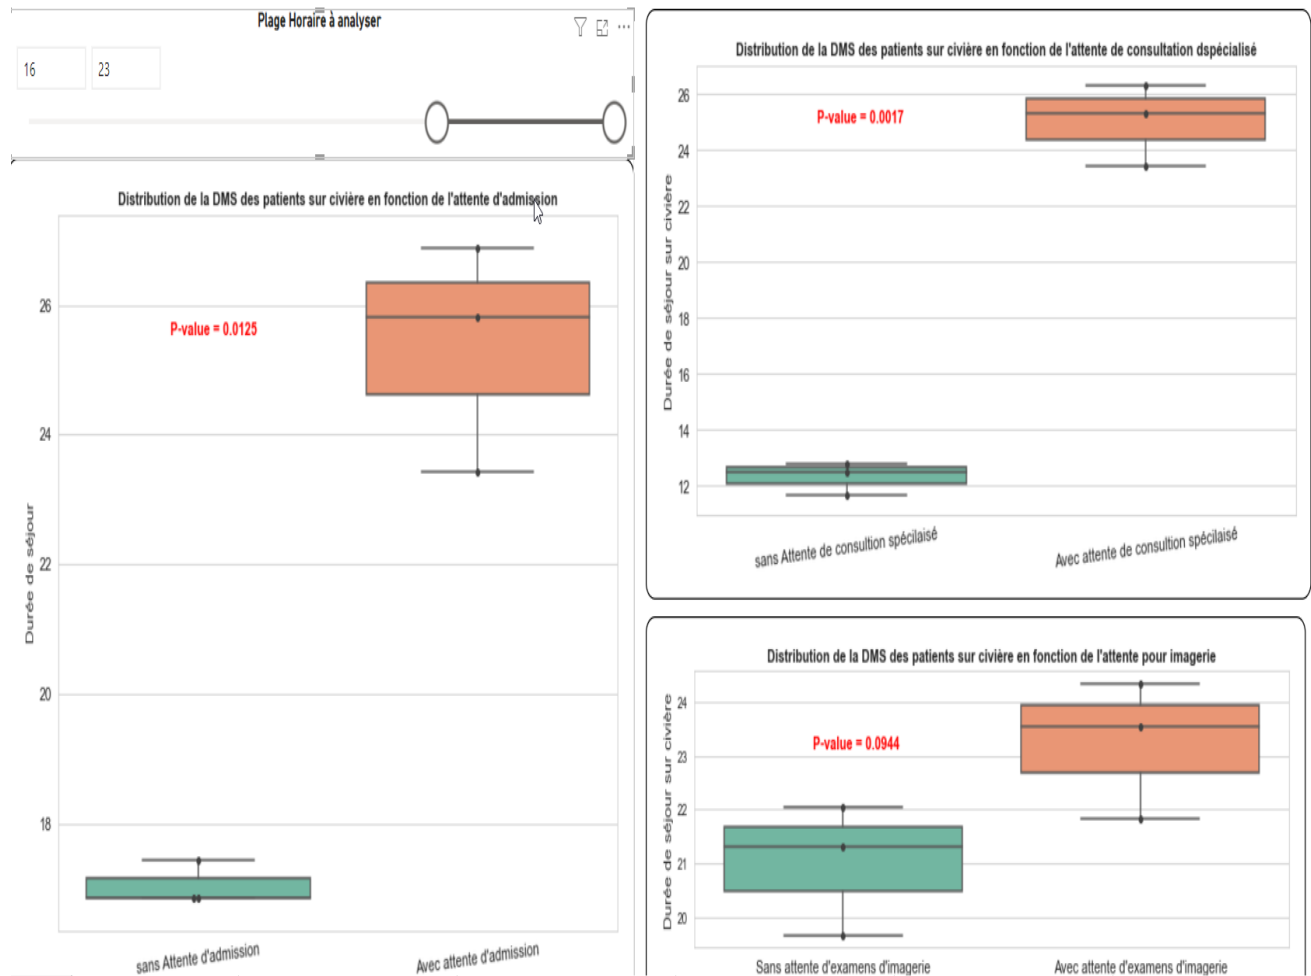
4.5.2.3 Plage horaire : 16 h à minuit

L'analyse de la DMS sur civière pour la période de 16 h à minuit en fonction des différents types d'attente :

- **Attente d'admission hospitalière** : La DMS est significativement plus élevée pour les patients en attente d'admission par rapport à ceux qui ne sont pas en attente. Cela indique que le processus d'admission impacte considérablement la durée de séjour sur civière. La P-Value de 0,012 5 est inférieure au seuil de 0,05, ce qui confirme que cette différence est statistiquement significative. La gestion des admissions pourrait être améliorée durant cette période pour réduire la DMS sur civière.
- **Attente de consultation spécialisée** : Les patients qui attendent une consultation spécialisée ont une DMS plus élevée et plus variable que ceux sans attente. La P-Value de 0,001 7 est bien inférieure à 0,05, ce qui indique une différence hautement significative. La disponibilité des consultations spécialisées semble être un facteur critique qui allonge la DMS.
- **Attente des examens d'imagerie** : La DMS est légèrement plus élevée pour les patients en attente des examens d'imagerie. La P-Value de 0,094 4 dépasse légèrement le seuil de 0,05, ce qui indique une

différence statistiquement non significative. L'impact de l'attente pour un examen d'imagerie sur la DMS semble moins important durant cette période par rapport aux autres types d'attente.

Figure 4.30 Distribution de la DMS en fonction des délais d'attente (plage horaire : 16 h->minuit)



Pour conclure, les attentes pour admission et consultations spécialisées sont les deux principaux facteurs influençant la DMS durant la fin d'après-midi et la soirée. Cela pourrait indiquer une pression accrue sur ces services pendant cette plage horaire. Bien que l'attente pour imagerie puisse avoir un impact, son effet est moins prononcé et pourrait nécessiter une analyse plus approfondie pour vérifier son influence.


4.6 Analyse du délai d'attente des consultations spécialisées

4.6.1 Sommaire global de l'attente des consultations spécialisées

Cette analyse fournit une vue d'ensemble des délais d'attente pour la consultation d'un médecin spécialiste à l'urgence sur les années 2021, 2022 et 2023, avec une attention particulière au mois de décembre. Les délais montrent une variation annuelle modérée, avec une moyenne de 6,9 heures en 2021, 6,7 heures en 2022, et 6,8 heures en 2023. Une tendance saisonnière est observée, avec des pics en septembre (7 heures) et décembre (7,1 heures), correspondant à des périodes de demande accrue. À l'inverse, les mois de mars et janvier affichent les délais les plus courts. Ces résultats soulignent l'importance d'un ajustement des ressources pendant les périodes de forte demande pour optimiser la gestion de la charge de travail et améliorer la prise en charge des patients.

Au mois de décembre, on constate que le délai moyen d'attente de consultation d'un médecin spécialiste la plus élevée est de 7,1 heures et la DMS sur civière de 37,4 heures (Figure 4-31). En général, le mois de décembre apparaît comme un mois critique, marqué par des délais d'attente et des séjours prolongés, probablement dus à une demande accrue de soins ou à une disponibilité réduite des spécialistes.

Figure 4.31 Délai d'attente des consultations spécialisées




4.6.2 Analyse détaillée du délai d'attente des consultations spécialisées — décembre 2023

En décembre, les délais moyens quotidiens d'attente de consultation varient entre 6,6 et 7,7 heures, avec des pics observés certains jours. Par exemple, le 1^{er} décembre (7,9 heures) et le 25 décembre (7,7 heures) enregistrent des délais plus élevés, probablement en raison d'une demande accrue ou d'une disponibilité

réduite pendant les fêtes. Les spécialités avec des délais élevés incluent la chirurgie vasculaire (14,3 heures), la psychiatrie (10,9 heures), l'endoscopie (10,2 heures), l'orthopédie (10,1 heures), l'hématologie (9,8 heures) et la pneumologie (9,5 heures). Ces spécialités affichent les temps d'attente les plus longs, soulignant un besoin d'ajustements dans les ressources pour répondre à la forte demande. À l'inverse, les spécialités avec des délais courts sont la chirurgie générale (5,4 heures) et la médecine interne (6,2 heures), témoignant d'une gestion plus efficace ou d'une demande moindre.

En décembre, les spécialités telles que la chirurgie vasculaire et la psychiatrie nécessitent une réallocation des ressources pour réduire les retards et améliorer la prise en charge des patients. Pour la chirurgie, il est essentiel de revoir l'encombrement des blocs opératoires et la disponibilité des salles d'opération. En revanche, pour la psychiatrie, la forte demande exige un renforcement des capacités et des ressources, car cette spécialité contribue de manière significative aux délais globaux.


Figure 4.32 Délai d'attente des consultations spécialisées — décembre 2023



4.6.3 Distribution du délai d'attente des consultations spécialisées (loi normale)

La courbe montre une distribution fortement asymétrique à gauche, indiquant que la majorité des patients bénéficient de délais d'attente relativement courts. Cependant, des cas extrêmes avec des délais significativement plus longs sont présents, probablement liés à des situations complexes ou à une disponibilité réduite des ressources. Ces valeurs aberrantes allongent la durée moyenne d'attente, bien que la majorité des consultations se situent dans des délais modérés (Figure 4-33).


Figure 4.33 Distribution du délai d'attente des consultations spécialisées (Loi normale)



4.6.3.1 Distribution des valeurs avec ajustement exponentiel

La distribution des délais d'attente ajustée selon une loi exponentielle avec un paramètre $\lambda = 0,13$. La courbe montre que les délais longs deviennent rapidement moins fréquents, mais leur présence continue d'impacter la distribution globale. L'ajustement exponentiel révèle une forte concentration des délais dans des valeurs basses, tout en confirmant que certains patients attendent de manière disproportionnée, influençant significativement le délai moyen (Figure 4-34). Globalement, le délai d'attente pour une consultation avec un médecin spécialiste reste relativement stable sur les trois années, malgré la présence de cas où l'attente est longue qui augmente la moyenne. La distribution exponentielle des délais d'attente met en évidence l'impact significatif de ces cas extrêmes.

Figure 4.34 Distribution du délai d'attente des consultations spécialisées (Loi exponentielle)



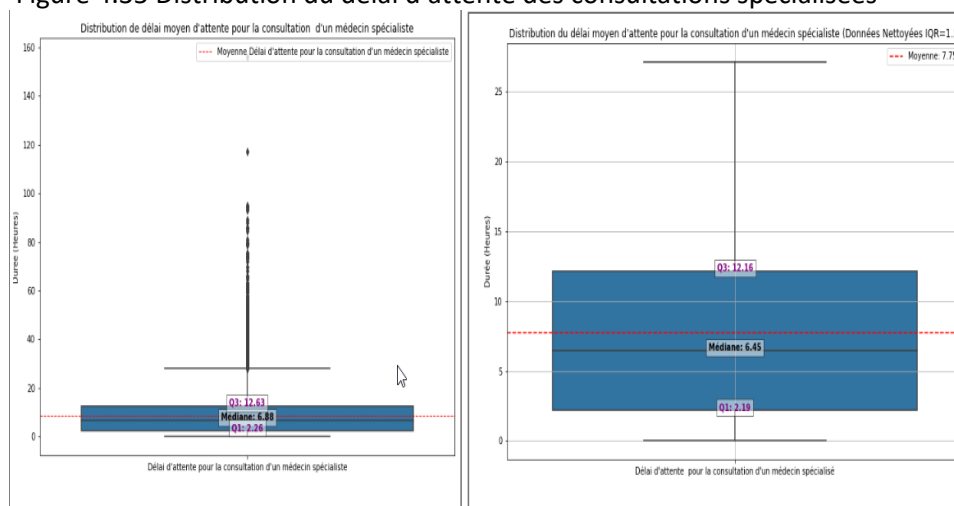
4.6.3.2 Boite à Moustache

La distribution des délais d'attente sur civière à l'urgence via la boîte à moustache (Figure 4-35) révèle une variabilité marquée, comme le montre la médiane de 6,88 heures, indiquant que la moitié des patients attendent moins de ce temps. Les valeurs des premier et troisième quartiles ($Q1 = 2,26$ heures, $Q3 = 12,61$ heures) mettent en évidence une concentration des délais d'attente dans une plage relativement limitée pour la majorité des patients. Cependant, des valeurs aberrantes significatives ont été observées, dépassant parfois les 20 heures et atteignant plus de 100 heures dans certains cas. Cela met en évidence des situations exceptionnelles où les patients subissent des délais prolongés. Ces données, incluant les valeurs aberrantes, traduisent une disparité dans les expériences des patients.

Après nettoyage des données aberrantes, la distribution des délais d'attente sur civière (Figure 4-35) apparaît plus compacte, reflétant une réduction significative de la variabilité tout en maintenant une médiane proche de celle de l'ensemble complet. La médiane est de 6,45 heures, indiquant une durée d'attente centrale légèrement inférieure. Les valeurs du premier et du troisième quartile ($Q1 = 2,19$ heures, $Q3 = 12,16$ heures) montrent que la majorité des délais d'attente restent concentrés dans une plage similaire. Ce nettoyage a permis d'atténuer l'impact des valeurs aberrantes tout en conservant une représentation fidèle des tendances principales.

La majorité des patients attendent entre 2 et 12 heures pour une consultation spécialisée. Cependant, certains patients subissent des délais d'attente beaucoup plus longs, ce qui allonge la durée moyenne et crée des valeurs aberrantes.


Figure 4.35 Distribution du délai d'attente des consultations spécialisées



4.6.4 Corrélation entre le délai d'attente des consultations spécialisées et la DMS sur civière


- Corrélation globale : La corrélation globale entre le délai d'attente de consultation spécialisé et la DMS sur civière (Figure 4-36) est de 0,34, avec un R^2 de 0,11. Cette corrélation modérée suggère qu'une augmentation du délai d'attente est associée à une légère augmentation de la durée de séjour sur civière. Cependant, la dispersion importante des points indique que d'autres facteurs influencent également la durée de séjour.

Figure 4.36 Corrélation entre le temps d'attente des consultations spécialisées et la DMS des patients sur civière




Après nettoyage des données avec un IQR = 2,5 (Figure 4-37), la corrélation diminue légèrement à 0,30, ce qui indique que les valeurs aberrantes influençaient l'analyse initiale. Cependant, une tendance positive persiste, confirmant une relation constante entre le délai d'attente et la durée de séjour sur civière.

Figure 4.37 Corrélation entre le temps d'attente des consultations spécialisées et la DMS sur civière donnée nettoyée IQR=2.5




- **Corrélation par année :** La corrélation par année montre que les trois années présentent des corrélations similaires (0,36), reflétant une tendance stable sur cette période. Bien que modérée chaque année, cette corrélation indique que la relation entre le délai d'attente et la durée de séjour sur civière reste relativement constante. (Figure 4-38)

Figure 4.38 Corrélation annuelle entre le temps d'attente des consultations spécialisées et la DMS sur civière



Après nettoyage des données, la corrélation entre le délai d'attente de consultation spécialisé et la DMS par année (Figure 4-39) nous montre que la suppression des valeurs aberrantes confirme une corrélation modérée, mais stable au fil des ans. Cela suggère l'existence d'une relation sous-jacente entre le délai d'attente pour un spécialiste et la durée de séjour sur civière.

Figure 4.39 Corrélation entre le temps d'attente des consultations spécialisées et la DMS sur civière par année donnée nettoyée IQR=2.5




En conclusion, la corrélation modérée (0,30 à 0,36) entre le délai d'attente pour consulter un spécialiste et la durée de séjour sur civière indique que des délais prolongés peuvent augmenter cette durée. La constance de cette corrélation chaque année montre une tendance stable dans la gestion des consultations spécialisées.

4.6.5 Corrélation entre le temps d'attente pour des consultations spécialisées par spécialité et la DMS sur civière

Nous analysons la corrélation entre le délai d'attente pour une consultation avec un médecin spécialiste et la DMS sur civière, répartie par spécialité. Les spécialités avec les plus fortes corrélations sont CHVA (Chirurgie Vasculaire) avec une corrélation de 0,77 ($R^2 = 0,59$) et CHGE (Chirurgie Générale) avec une corrélation de 0,52 ($R^2 = 0,27$). Ces résultats révèlent une relation significative, particulièrement pour CHVA, entre le délai d'attente pour une consultation et la durée de séjour sur civière, suggérant qu'un délai d'attente prolongé est fortement associé à une augmentation de la durée de séjour (Figure 4-40).


Figure 4.40 Corrélation entre le temps d'attente pour des consultations spécialisées par spécialité et la DMS sur civière



Après le nettoyage des données, les corrélations restent globalement stables. La CHVA (Chirurgie Vasculaire) maintient une corrélation élevée de 0,77 ($R^2 = 0,59$), tandis que les corrélations pour CHGE (Chirurgie Générale), ORTHO (Orthopédie) et NEURO (Neurologie) demeurent modérées. L'élimination des valeurs aberrantes a réduit l'effet des points extrêmes, resserrant la distribution pour les délais d'attente courts, sans modifier significativement les corrélations. Cela confirme la robustesse de la relation entre le délai d'attente et la durée de séjour, même après la suppression des données aberrantes (Figure 4-44).

La Chirurgie vasculaire (CHVA) présente une forte corrélation entre le délai d'attente pour consultation et la DMS sur civière, indiquant que des délais prolongés augmentent significativement la durée de séjour. D'autres spécialités, comme la Chirurgie générale (CHGE) et l'Orthopédie (ORTHO), affichent des corrélations modérées, nécessitant un suivi particulier. En revanche, des spécialités comme la Dermatologie (DERM), avec des corrélations faibles, montrent un impact marginal des délais d'attente sur la durée de séjour. Ces résultats permettent de prioriser les consultations ayant un effet significatif sur la DMS.

Figure 4.41 Corrélation entre le temps d'attente pour des consultations spécialisées par spécialité et la DMS sur civière (données nettoyées IQR=1.5)



4.6.6 Test ANOVA sur le délai d'attente des consultations spécialisées


Nous effectuons un test ANOVA sur le délai d'attente pour une consultation spécialisée à l'urgence, répartie par spécialité. Le tableau ANOVA (Figure 4-42) montre un p-value < 0,000 01, ce qui signifie que les différences entre les délais d'attente moyens par spécialité sont statistiquement significatives. L'indice F élevé (117,204 84) confirme que les délais d'attente varient de manière significative entre les spécialités.

Les boîtes à moustaches montrent une variabilité notable entre les spécialités :

- La chirurgie vasculaire (CHVA) semble avoir l'une des médianes les plus faibles et une dispersion limitée, ce qui indique des délais d'attente généralement courts et cohérents.
- La psychiatrie (PSY) et la pneumologie (PNEU) montrent des médianes plus élevées, accompagnées d'une dispersion importante, ce qui indique des délais d'attente plus longs et moins prévisibles.
- Enfin certaines spécialités, comme l'urologie (URO), affichent une variabilité plus modérée, mais incluent des valeurs aberrantes.

Des points situés au-delà des moustaches indiquent des valeurs aberrantes pour plusieurs spécialités. Ces cas pourraient influencer la moyenne globale et justifier un nettoyage (comme le filtre IQR). Les résultats de test ANOVA suggèrent que certaines spécialités nécessitent une attention particulière pour réduire les délais d'attente. La faible variabilité de CHVA pourrait indiquer une meilleure gestion, tandis que des spécialités comme PSY ou PNEU pourraient bénéficier d'interventions ciblées pour réduire les délais et leur variabilité.

Figure 4.42 Test ANOVA sur le délai d'attente pour des consultations spécialisées




Même après nettoyage des données aberrantes avec IQR = 1,5 (Figure 4-43), le test ANOVA continue de montrer un p-value < 0,000 01, indiquant que les différences entre les spécialités restent statistiquement significatives. La valeur F (87,94) est légèrement inférieure à celle des données non nettoyées, reflétant la réduction de l'influence des valeurs aberrantes sur la variabilité globale. Les spécialités d'urologie (URO) et chirurgie vasculaire (CHVA) continuent de montrer les délais d'attente les plus courts avec une faible dispersion. La psychiatrie (PSY) et la pneumologie (PNEU) maintiennent des délais d'attente plus longs, mais la réduction des valeurs aberrantes a limité leur dispersion. Certaines spécialités, comme l'orthopédie (ORTHO) et la gastroentérologie (GAST), montrent une médiane relativement stable, mais conservent une variabilité notable.

Les résultats ANOVA montrent qu'il existe des différences significatives dans les délais d'attente selon la spécialité. Les spécialités avec des délais plus longs, comme PSY et PNEU, pourraient bénéficier d'interventions pour réduire les délais. Le nettoyage a permis de se concentrer sur des délais plus représentatifs pour chaque spécialité, ce qui pourrait aider à prioriser les améliorations dans la gestion des consultations.

L'analyse de variance montre que les différences de délais d'attente par spécialité sont statistiquement significatives. Certaines spécialités, comme la chirurgie vasculaire, la gériatrie et l'hématologie, affichent des délais d'attente nettement plus élevés, suggérant une forte demande ou une disponibilité limitée des spécialistes. À l'inverse, des spécialités comme l'urologie et la chirurgie générale présentent des délais plus courts, reflétant une meilleure accessibilité. Des interventions ciblées sur des spécialités comme la psychiatrie (PSY) et la pneumologie (PNEU) pourraient aider à réduire les délais. Une réduction globale des délais d'attente pourrait légèrement améliorer la DMS sur civière.

Figure 4.43 Test ANOVA sur le délai d'attente des consultations spécialisées (IQR = 1,5)



4.7 Analyse du délai d'attente à l'hospitalisation


4.7.1 Sommaire global du délai d'attente pour l'hospitalisation

- **Tendances annuelles :** En 2023, le délai moyen d'attente d'hospitalisation s'élève à 10,5 heures, contre 9,8 heures en 2022 et 7,6 heures en 2021. Cette progression annuelle indique une

augmentation constante des délais, ce qui pourrait refléter une pression croissante sur les capacités d'hospitalisation.

- **Tendances mensuelles** : Le délai moyen d'attente d'hospitalisation augmente en fin d'année, avec des pics en décembre de 12,2 heures. Les mois de fin d'année (septembre, octobre, novembre, décembre) sont critiques, possiblement en raison de l'augmentation des admissions liées aux affections hivernales.
- **Tendances par intervalles** : Les intervalles indiquent des délais moyens comme suit : de 0 h à 14 h : 8,4 heures ; de 14 h à 18 h : 8,5 heures ; de 18 h à 0 h : 8,1 heures. L'intervalle de l'après-midi 14 h – 18 h présente les délais d'attente les plus élevés, ce qui peut correspondre à des périodes de forte affluence ou à des contraintes de ressources.
- **Tendance par spécialités** : Les délais d'attente par spécialité mettent en évidence des écarts importants : la psychiatrie (PSY) affiche le délai moyen le plus élevé avec 30,7 heures, suivie de la gériatrie (GER) à 11,5 heures et de la dermatologie (DERM) à 10,3 heures. Ces spécialités, en particulier la psychiatrie et la gériatrie, pourraient nécessiter une attention prioritaire en termes de ressources et d'organisation pour réduire ces délais.

Figure 4.44 Sommaire global du délai d'attente pour l'hospitalisation

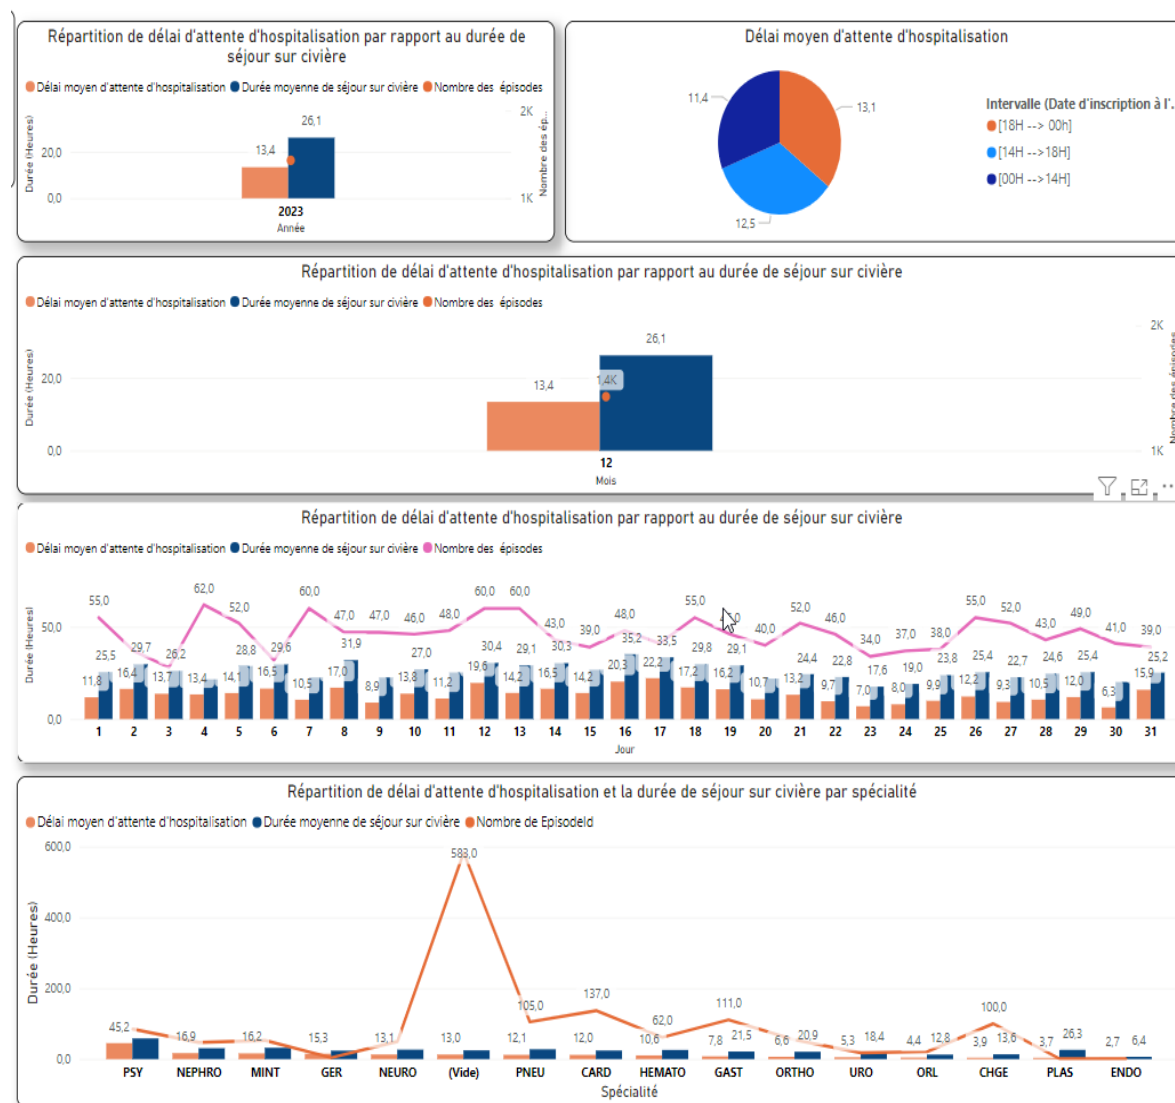


- **Analyse de décembre 2023**

- **Tendance journalière** : En décembre 2023, le délai moyen d'attente d'hospitalisation atteint 13,4 heures, marquant un pic par rapport aux autres mois de l'année. Ce mois se distingue par des délais d'attente particulièrement élevés, probablement dus à une hausse des admissions liées aux affections hivernales et à une disponibilité réduite des lits d'hospitalisation. Les 16 décembre (20,0 heures) et 17 décembre (22,0 heures) sont les journées avec les délais les plus élevés. Ces journées reflètent une surcharge critique du système hospitalier.
- **Tendance par spécialités** : La psychiatrie (PSY) affiche le délai moyen le plus élevé avec 45,2 heures, reflétant une demande de lits particulièrement importante ou des difficultés d'hospitalisation. La néphrologie (NÉPHRO) et la neurologie (NEURO) suivent avec des délais moyens respectifs de 16,2 heures et 13,8 heures, tandis que la pneumologie (PNEU) et le service de cardiologie (CARDIO) enregistrent des délais de 12,1 heures et 12 heures. Ces délais importants pourraient être liés à la complexité des cas traités ou à une pénurie de lits spécialisés, nécessitant des efforts ciblés pour optimiser l'accès aux soins dans ces domaines.

En décembre 2023, les délais d'attente pour l'hospitalisation augmentent significativement, avec des pics observés par jour et par intervalle horaire. La psychiatrie affiche les délais les plus élevés, nécessitant une gestion prioritaire pour améliorer la prise en charge des patients. Les délais d'attente varient selon l'année, l'intervalle horaire, le mois et la spécialité. Les périodes de fin d'année et l'intervalle de l'après-midi (14 h – 18 h) présentent des délais plus importants. La psychiatrie et la gériatrie, avec des délais particulièrement longs, demandent une attention particulière pour optimiser la gestion des patients et réduire les temps d'attente.

Figure 4.45 Tendance du délai d'attente à l'hospitalisation (exemple : décembre 2023)




4.7.2 Distribution du délai d'attente pour l'hospitalisation

4.7.2.1 Courbe Loi normale

Nous comparons la distribution du délai d'attente d'hospitalisation et de la DMS des patients sur civière en fonction de la loi normale. La courbe de la Figure 4-46 illustre les distributions de la DMS sur civière (bleu) et du délai moyen d'attente d'hospitalisation (orange). Les deux courbes sont asymétriques à gauche, avec un pic dans les premières heures suivies d'une décroissance rapide. La majorité des valeurs se situent sous 50 heures, bien que quelques cas extrêmes atteignent 200 heures. Ces distributions montrent que la plupart des délais et des séjours sont courts, avec quelques cas prolongés.

Après le nettoyage des données (Figure 4-46), le délai d'attente d'hospitalisation se concentre principalement entre 5 et 10 heures, avec une décroissance rapide. En revanche, la DMS sur civière est plus étalée, se situant majoritairement entre 10 et 20 heures. Ce nettoyage met en évidence des durées plus courtes en éliminant les cas extrêmes.

Figure 4.46 Distribution du délai d'attente pour l'hospitalisation (Loi normale)



4.7.2.2 Courbe loi exponentielle

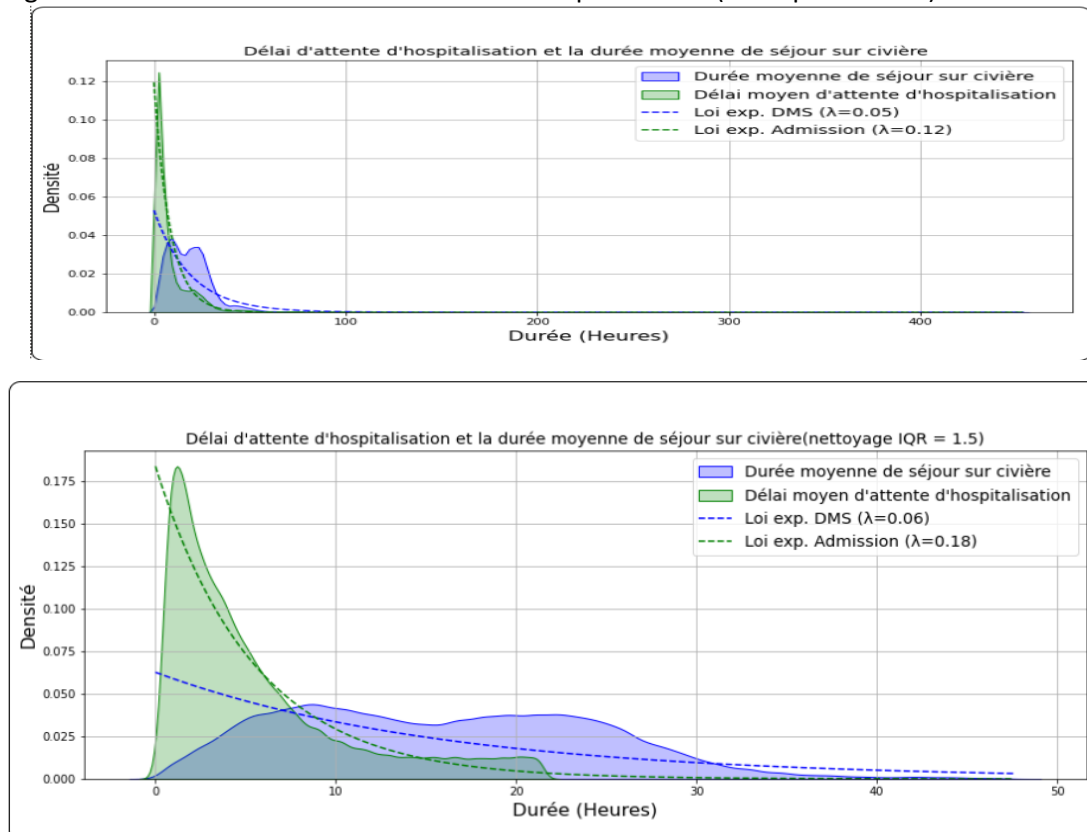
Nous analysons la distribution du délai d'attente pour l'hospitalisation ainsi que celle de la DMS sur civière en utilisant la loi exponentielle. Les distributions dans la Figure 4-47 montrent des pics marqués au cours

des premières heures, suivis d'une décroissance rapide. La loi exponentielle, avec $\lambda = 0,05$ pour la durée moyenne de séjour sur civière et $\lambda = 0,12$ pour le délai d'attente d'hospitalisation, est superposée afin d'ajuster les courbes. La majorité des patients présentent des délais et des séjours courts, bien que quelques cas extrêmes prolongent significativement la distribution.

Même après le nettoyage des données, qui met en évidence une concentration des durées autour de valeurs plus courtes et réduit l'influence des valeurs aberrantes, les distributions restent majoritairement concentrées dans les premières heures (Figure 4-47), avec des queues plus courtes. Les paramètres de la loi exponentielle ont été ajustés : $\lambda = 0,06$ pour la durée de séjour sur civière et $\lambda = 0,18$ pour le délai d'attente d'hospitalisation, reflétant une répartition plus représentative des cas courants.

Les distributions des durées, après exclusion des valeurs aberrantes, offrent une représentation plus fiable des délais d'attente et de séjour pour la majorité des patients. Les ajustements selon la loi exponentielle permettent de modéliser ces durées de manière réaliste, offrant une meilleure compréhension des tendances tout en minimisant l'influence des cas extrêmes.


Figure 4.47 Distribution du délai d'attente d'hospitalisation (Loi exponentielle)



4.7.2.3 Boite à moustache


Le délai d'attente d'hospitalisation (Figure 4-48) montre un Q1 à 2,07 heures, une médiane à 4,56 heures et une moyenne à 9,39 heures. Les valeurs aberrantes (> 400 heures) augmentent la moyenne, bien que la majorité des données se situent en dessous de 50 heures.

Figure 4.48 Distribution du délai d'attente pour l'hospitalisation



Après nettoyage, le délai d'attente d'hospitalisation (Figure 4-49) présente un Q1 à 1,86 heure, une médiane à 3,92 heures et une moyenne à 5,93 heures. Ce nettoyage réduit l'impact des valeurs aberrantes, rapprochant la moyenne de la médiane. Nous observons l'impact des valeurs aberrantes sur les distributions. Sans nettoyage, les délais d'attente d'hospitalisation affichent une moyenne élevée de 9,39 heures, influencée par des cas dépassant 400 heures, bien que la majorité des données se situent sous 50 heures. Après nettoyage (IQR = 1,5), la moyenne diminue significativement à 5,93 heures, se rapprochant de la médiane de 3,92 heures, ce qui offre une distribution plus représentative des cas courants.


Figure 4.49 Distribution du délai d'attente pour l'hospitalisation (données nettoyées, IQR = 1,5)



4.7.3 Corrélation entre le délai d'attente à l'hospitalisation et la DMS sur civière

Nous analysons la corrélation entre le délai d'attente d'hospitalisation et la DMS sur civière. La figure 4-50 montre une corrélation élevée ($r = 0,84$, $R^2 = 0,70$), indiquant une forte association. Les valeurs aberrantes allongent la ligne de tendance et amplifient la corrélation globale.

Figure 4.50 corrélation entre le délai d'attente à l'hospitalisation et la DMS sur civière




Après exclusion des valeurs aberrantes ($Z\text{-score} > 3$) (Figure 4-56), la corrélation diminue à 0,70 ($R^2 : 0,49$), mais reste modérée. Cela indique que la relation entre le délai d'attente et la durée de séjour est moins influencée par les valeurs aberrantes, offrant une perspective plus réaliste et représentative des cas courants.

Formule de : $Z = \frac{(X-\mu)}{\sigma}$ avec $Z\text{-score} \leq 3$

- X : Valeur de l'observation.
- μ : Moyenne de l'ensemble des données.
- σ : Écart-type de l'ensemble des données.

La corrélation initiale, élevée sans nettoyage, diminue après le filtrage des valeurs aberrantes, tout en restant positive. Cela démontre que le délai d'attente d'hospitalisation influence la durée de séjour sur civière, mais que les cas extrêmes amplifient artificiellement cette corrélation. Le nettoyage permet une vision plus précise pour la majorité des patients. La prochaine section approfondira cette corrélation en tenant compte du paramètre de la spécialité.


Figure 4.51 Corrélation entre le délai d'attente à l'hospitalisation et la DMS sur civière (Z-score ≤ 3)



4.7.4 Corrélation entre le délai d'attente à l'hospitalisation et la DMS sur civière selon la spécialité


Nous analysons la corrélation entre le délai d'attente d'hospitalisation et la DMS sur civière selon les spécialités. La figure 4-52 montre les corrélations les plus élevées pour : la psychiatrie (PSY) ($r=0,96$, $R^2=0,92$), l'urologie (URO) ($r=0,84$, $R^2=0,71$), et la cardiologie (CARD) ($r=0,74$, $R^2=0,55$). La corrélation est particulièrement forte en psychiatrie, où un délai d'attente élevé est étroitement lié à une durée prolongée sur civière.

Figure 4.52 Corrélation entre le délai d'attente à l'hospitalisation et la DMS sur civière par spécialité



Après nettoyage des valeurs aberrantes, Z-score ≤ 3 , 576 points sont éliminés (Figure 4-53) des 27 599 originaux laissant 27 023 points restants. Les corrélations par spécialité restent cohérentes, témoignant de la robustesse des relations : pour la psychiatrie (PSY) on a ($r=0,81$, $R^2=0,65$), pour la cardiologie (CARD) ($r=0,72$, $R^2=0,52$), et pour la gériatrie (GER) ($r=0,70$, $R^2=0,52$). Le nettoyage réduit légèrement les corrélations, mais confirme que, même sans valeurs aberrantes, le délai d'attente d'hospitalisation influence fortement la durée de séjour sur civière, particulièrement en psychiatrie, gériatrie et cardiologie.

Figure 4.53 Corrélation entre le délai d'attente à l'hospitalisation et la DMS sur civière par spécialité (Z-score ≤ 3)




Nous observons une forte corrélation entre le délai d'attente d'hospitalisation et la durée de séjour des patients sur civière pour des spécialités spécifiques, en particulier la psychiatrie et l'urologie. Le nettoyage des valeurs aberrantes n'affecte que marginalement la relation, confirmant que cette corrélation est représentative d'une tendance réelle dans la gestion des patients pour ces spécialités.

4.7.5 Analyse de la variance du délai d'attente à l'hospitalisation selon la spécialité des patients sur civière

Le test ANOVA examine le délai d'attente d'hospitalisation et la durée de séjour sur civière en fonction des spécialités pour les patients sur civière, avec et sans exclusion des valeurs aberrantes. Le test ANOVA présentée dans la figure 4-54 met en évidence des différences significatives dans la durée de séjour sur civière en fonction des spécialités (p -value $< 0,0001$). Sans exclusion des valeurs aberrantes, certaines spécialités, comme la psychiatrie (PSY) et l'hématologie (HÉMATO), affichent des durées nettement plus

élevées, avec des valeurs médianes et des écarts importants. Ces résultats soulignent l'influence marquée de la spécialité sur la durée de séjour, en particulier pour celles présentant une forte variabilité.


Figure 4.54 Test ANOVA du délai d'attente à l'hospitalisation selon la spécialité



La figure 4-55 présente les résultats du test ANOVA appliquée à la durée de séjour sur civière selon la spécialité, avec exclusion des valeurs aberrantes (IQR = 2,5). Cette approche réduit les écarts représentés dans les boîtes à moustaches tout en préservant les tendances globales. La psychiatrie (PSY) demeure la spécialité affichant les durées de séjour les plus élevées, suivie par la gériatrie (GER). Bien que le nettoyage atténue l'influence des cas extrêmes, ces spécialités continuent de présenter des durées de séjour significativement supérieures, confirmant leur impact disproportionné sur la variabilité globale.

Le test ANOVA confirme l'impact significatif de la spécialité sur la durée de séjour sur civière. Des spécialités comme la psychiatrie et l'hématologie affichent des séjours plus longs, même après l'exclusion des valeurs aberrantes. Ces résultats suggèrent que des interventions ciblées pourraient réduire ces durées.

Figure 4.55 Test ANOVA du délai d'attente à l'hospitalisation selon la spécialité



4.8 Analyse du délai d'attente pour les examens d'imagerie

4.8.1 Sommaire global du délai d'attente pour les examens d'imagerie

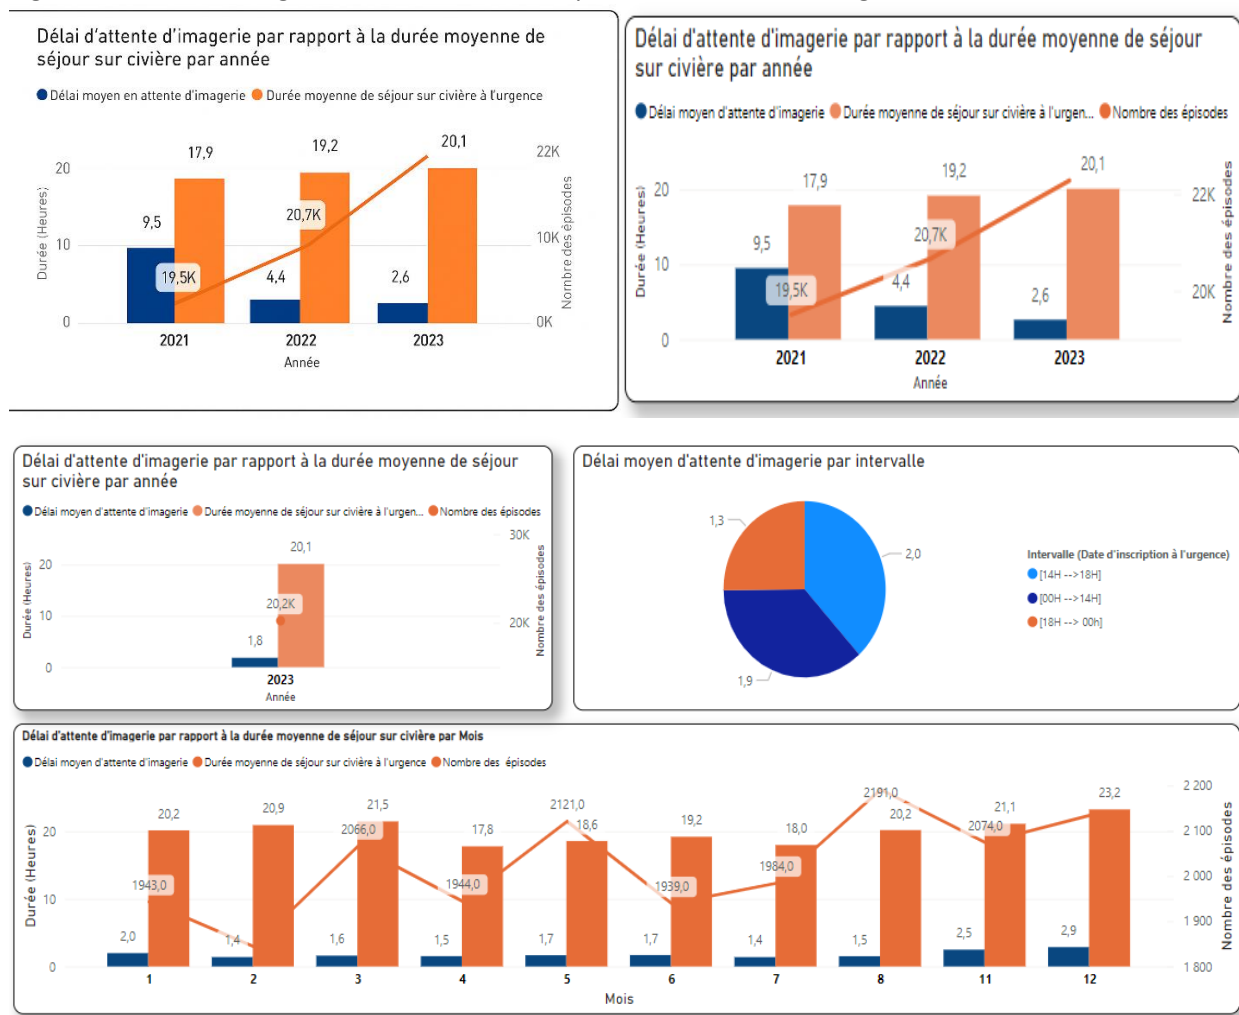
Ce tableau de bord fournit une vue d'ensemble de la demande d'examens d'imagerie à l'urgence, avec une analyse détaillée par année, mois, jour et type d'examen.

- **Tendance annuelle** : En 2023, le délai d'attente pour des examens d'imagerie atteint une moyenne de 2,6 heures, soit une diminution par rapport à 2021 (9,5 heures) et 2022 (4,4 heures).

- **Tendance mensuelle** : Le délai moyen d'attente par mois montre des pics en novembre (4,3 heures) et décembre (6,7 heures). Les mois d'automne sont plus chargés en termes de demandes d'imagerie, ce qui peut entraîner des délais d'attente prolongés.

Les variations observées dans le nombre d'épisodes montrent que certains jours enregistrent une demande accrue pour les examens d'imagerie, sans impact majeur sur les délais d'attente ou la durée moyenne de séjour sur civière. Cette stabilité reflète probablement une gestion efficace des ressources en imagerie, avec des ajustements adaptés aux fluctuations journalières de la demande.

Figure 4.56 Sommaire global du délai d'attente pour les examens d'imagerie




4.8.2 Distribution du délai d'attente pour les examens d'imagerie

4.8.2.1 Représentation des distributions selon la loi normale et la loi exponentielle

Nous analysons la distribution des délais dans la figure 4-57, où les graphiques révèlent une asymétrie prononcée à droite pour le délai d'attente d'imagerie et la DMS sur civière. La majorité des valeurs se situent à des niveaux bas, tandis que quelques cas affichent des délais prolongés. Après nettoyage des valeurs aberrantes (IQR = 1,5), les distributions conservent leur asymétrie, mais se recentrent davantage autour des valeurs moyennes, réduisant l'influence des valeurs aberrantes. La corrélation entre le délai d'attente et la durée moyenne de séjour (DMS) sur civière est faible ($r=0,08$), ce qui indique une absence de relation significative entre ces deux variables.

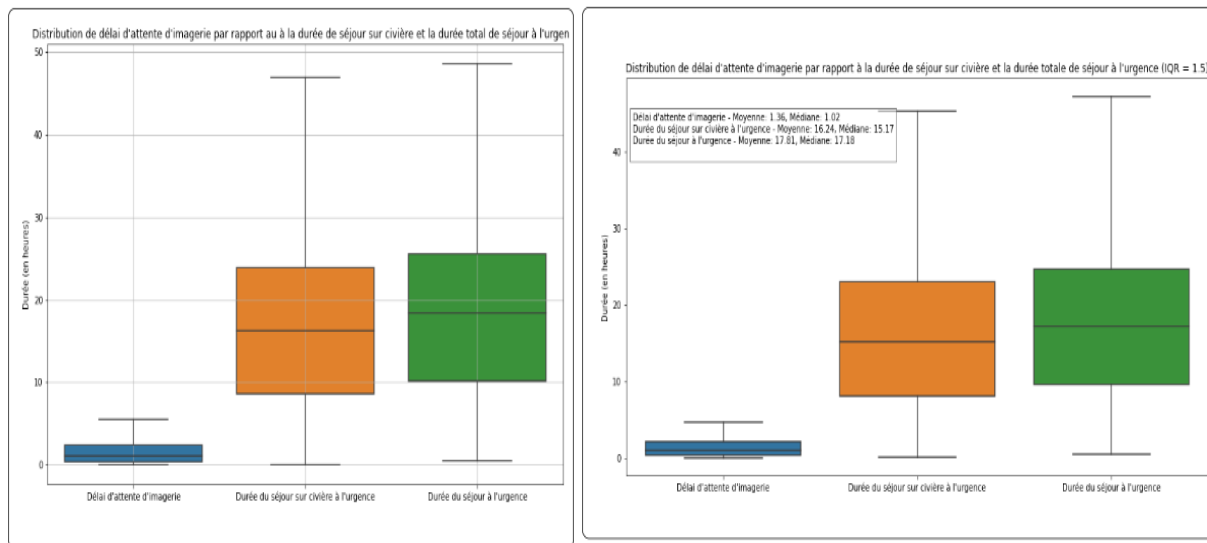
Figure 4.57 Distribution du délai d'attente pour les examens d'imagerie selon la loi exponentielle



4.8.2.2 Représentation en boîte à moustaches

Le délai d'attente des examens d'imagerie affiche une variabilité plus faible avec une médiane basse, tandis que les durées de séjour sur civière et à l'urgence montrent des médianes et des étendues plus importantes. Les médianes et les IQR indiquent que la durée totale de séjour à l'urgence est généralement plus longue que celle sur civière, ce qui est logique, car les patients peuvent être transférés vers d'autres services après leur séjour sur civière (Figure 4-58).

Figure 4.58 Distribution du délai d'attente des examens d'imagerie



La stabilité des délais d'attente pour les examens d'imagerie témoigne d'une gestion constante. La faible corrélation avec la DMS sur civière montre que ces deux mesures dépendent de facteurs distincts.


4.8.3 Analyse de la corrélation entre le délai d'attente des examens d'imagerie et la DMS sur civière

La corrélation entre le délai d'attente d'imagerie et la DMS sur civière est quasi inexistante, avec un coefficient de corrélation très faible (0,07). Cette relation minimale est confirmée par un coefficient de détermination ($R^2 = 0,01$), indiquant que seulement 1 % de la variance de la durée de séjour peut être expliqué par le délai d'attente d'imagerie, un effet négligeable. Une tendance légèrement croissante est notée, mais la majorité des données se situe sur des délais d'attente et des durées de séjour courtes, avec quelques valeurs aberrantes pour la DMS sur civière qui étendent la distribution (Figure 4-59).

Après nettoyage des données aberrantes (IQR = 1,5), seules les valeurs dans une plage restreinte ont été conservées. La corrélation reste très faible (0,06), confirmant qu'il n'y a pas de relation significative entre

le délai d'attente d'imagerie et la durée de séjour sur civière, même sans les valeurs aberrantes. La concentration des points est plus uniforme, mais la tendance demeure pratiquement plate, soulignant l'absence de lien fort entre ces deux variables.

Figure 4.59 Corrélation de délai d'attente des examens d'imagerie




4.8.4 Analyse de la corrélation selon le type d'examen d'imagerie

Les corrélations entre le délai d'attente d'imagerie et la DMS sur civière varient selon le type d'examen, comme le montrent les lignes de régression pour chaque groupe. La graphie/RX simple et l'échographie présentent des corrélations faibles, respectivement de 0,21 et 0,22, légèrement supérieures à celles des

autres examens. Pour l'IRM, la corrélation est quasi inexistante (0,05), tandis que la tomographie affiche également une corrélation faible (0,11). Bien que les régressions montrent des pentes légèrement positives, indiquant une tendance modeste à l'augmentation de la DMS avec le délai d'attente pour certains examens, cette relation reste très faible. La forte dispersion des points au sein de chaque groupe confirme l'absence d'une relation significative entre ces deux variables (Figure 4-60).


Figure 4.60 Corrélation selon le type d'examen d'imagerie



Après nettoyage des données aberrantes (IQR = 1,5). Les corrélations restent faibles, même après l'élimination des valeurs aberrantes, avec des résultats tels que : graphie/RX simple (corrélation de 0,12), échographie (corrélation de 0,08) et IRM (corrélation de 0,03). La réduction des valeurs aberrantes n'a pas

significativement modifié les corrélations, confirmant que les délais d'attente pour chaque type d'imagerie n'ont qu'un faible impact sur la durée de séjour sur civière (Figure 4-61).

Figure 4.61 Corrélation par type d'examen d'imagerie IQR 1.5



Les analyses par type d'examen montrent que le type d'imagerie a peu d'influence sur la corrélation entre le délai d'attente et la durée de séjour sur civière. Les corrélations restent faibles, confirmant que d'autres facteurs impactent davantage la durée de séjour des patients.


4.8.5 Analyse de la variance des demandes d'examens d'imagerie

Selon le graphique en violon (Figure 4-62), la distribution du séjour sur civière varie selon le type d'examen d'imagerie. Les groupes IRM et électrophysiologie présentent une dispersion plus importante, indiquant une variabilité élevée, tandis que l'échographie et la radiographie ont des distributions plus homogènes. Médecine nucléaire et hémodynamie affichent des médianes plus élevées, suggérant des séjours prolongés. Les valeurs de p-value ($< 0,001$) et de F (89,122 6) confirment une variabilité significative entre

les catégories d'examens. La variance et l'écart-type sont particulièrement élevés pour l'IRM (176,94) et la médecine nucléaire (137,04), renforçant leur lien avec des séjours prolongés.

Ces résultats indiquent que certains examens, notamment IRM, hémodynamie et médecine nucléaire, contribuent à l'allongement des séjours sur civière, possiblement en raison des délais d'attente pour la réalisation et l'interprétation des examens. L'optimisation de ces processus pourrait réduire la congestion aux urgences et améliorer la prise en charge des patients.

Figure 4.62 Corrélation selon type d'examen d'imagerie après nettoyage des données (IQR =1,5)




4.9 Analyse du nombre d'infirmières en relation avec la DMS des patients sur civière

4.9.1 Répartition du nombre d'infirmières selon la DMS des patients sur civière

Notre tableau de bord examine la relation entre le nombre d'infirmiers et la DMS des patients sur civière à l'urgence, en la répartissant par quart du jour (jour, soir, nuit). Nous constatons que la répartition du nombre d'infirmiers présente une majorité pendant la journée, suivie d'une baisse progressive le soir et la

nuit, avec une moyenne globale de 18-19 infirmiers par jour. Une relation inverse est observée dans certains cas, où un nombre plus élevé d'infirmiers (par exemple, le jour 18) est associé à une DMS plus courte. Cependant, la durée de séjour, variant entre 12,5 et 19,3 heures, indique que d'autres facteurs influencent également le temps passé sur civière (Figure 4-64). Les ressources humaines, notamment le nombre d'infirmiers, ont un effet modéré sur la DMS des patients sur civière. Une augmentation du nombre d'infirmiers semble légèrement réduire la durée de séjour, indiquant une corrélation partielle. Cependant, la variabilité quotidienne de la durée moyenne de séjour suggère qu'il est nécessaire d'examiner d'autres facteurs, tels que le volume de patients ou la gravité des cas, pour comprendre pleinement les fluctuations observées.

Figure 4.63 Analyse du nombre d'infirmières en fonction de la DMS




4.9.2 Analyse de la corrélation entre le nombre d'infirmières et la DMS des patients sur civière

Nous explorons la possibilité d'une corrélation entre le nombre d'infirmiers et la durée de séjour des patients sur civière, en les répartissant par quart de jour (jour, soir, nuit). Nous constatons qu'il y a une légère pente positive indiquant une corrélation faible (corrélation de 0,12) entre le nombre d'infirmières et la durée de séjour. Cela signifie que l'augmentation du nombre d'infirmières a un impact limité sur la


réduction ou l'augmentation de la durée de séjour des patients. La dispersion des points autour de la ligne de régression montre que la durée de séjour n'est pas fortement influencée par le nombre d'infirmières, suggérant que d'autres facteurs jouent un rôle plus important dans cette variation (Figure 4-65).

Figure 4.64 Corrélation entre le nombre d'infirmières et la DMS des patients sur civière



Nous avons utilisé le test ANOVA et nous constatons que les médianes de la durée de séjour restent relativement stables, quel que soit le nombre d'infirmières, corroborant la faible corrélation observée dans le graphique de gauche. La variation interquartile met en évidence une variabilité notable pour chaque intervalle de nombre d'infirmières, avec des valeurs aberrantes indiquant que, même avec un nombre similaire d'infirmières, la durée de séjour peut varier en fonction des caractéristiques des patients ou d'autres facteurs opérationnels (Figure 4-66). La corrélation de 0,12 entre le nombre d'infirmières et la durée de séjour sur civière est faible, indiquant que l'effectif infirmier a un impact limité sur cette durée. La variabilité des séjours, même avec des niveaux similaires d'infirmiers, suggère que d'autres facteurs, tels que la gravité des cas, l'afflux de patients ou les processus opérationnels, jouent un rôle plus significatif.

Figure 4.65 Distribution de la durée de séjour sur civière en fonction du nombre d'infirmiers




4.10 Analyse du nombre de médecins en relation avec la DMS

4.10.1 Répartition du nombre de médecins en fonction de la DMS

Nous avons examiné la relation entre le nombre de médecins et la DMS des patients sur civière, répartie par intervalle de prise en charge et par jour. La Figure 4-66 montre des variations quotidiennes des effectifs de médecins, avec des pics notables dans les jours 12, 22 et 25, probablement liés à des variations de la demande ou à des besoins spécifiques par spécialité. Cependant, la DMS, représentée par une ligne superposée, ne diminue pas systématiquement les jours où le nombre de médecins est plus élevé. Par exemple, le jour 21, malgré un effectif médical accru, il n'y a pas de réduction significative de la DMS. Ces observations indiquent que la DMS est influencée par des facteurs autres que les effectifs médicaux globaux. Pour approfondir cette analyse, il serait pertinent de disposer des horaires détaillés par fonction des médecins. Une distinction entre le nombre de médecins affectés aux patients ambulatoires et ceux responsables des patients sur civière permettrait de mieux évaluer leur impact respectif sur la DMS.


Figure 4.66 Nombre de médecins par intervalle par jour



4.11 Analyse des chevauchements des flux de patients à l'urgence

Ce tableau de bord examine le temps moyen de chevauchement, c'est-à-dire le temps durant lequel les ressources se chevauchent entre l'urgence et l'hospitalisation. Plus précisément, il s'agit du temps alloué à un patient déjà transféré vers un lit à l'hôpital, mais qui occupe encore un lit dans le système de l'urgence. Le temps de chevauchement a connu une augmentation significative en 2024 par rapport aux années précédentes, passant de : 17 minutes en 2021, 19 minutes en 2022, 20 minutes en 2023, pour atteindre 47 minutes en 2024. Cette évolution pourrait refléter une augmentation des ressources superposées ou une pression accrue sur ces dernières, nécessitant une gestion plus optimisée des flux entre l'urgence et l'hospitalisation.

Figure 4.67 Analyse des chevauchements des flux de patients à l'urgence



Recommandation : L'optimisation de ce processus permet de libérer des civières plus rapidement, offrant ainsi la possibilité d'accueillir d'autres patients en attente de soins.

4.12 Principaux constats observés sur la DMS des patients à l'urgence (2021-2023)

Pour synthétiser les principaux constats issus des analyses présentées dans les sections 5.1 à 5.12, le tableau ci-après regroupe les informations clés relatives aux différents types de délais. Pour chaque catégorie y sont indiqués la médiane, l'intervalle interquartile (Q1–Q3), la variabilité observée ainsi que l'impact sur la durée moyenne de séjour (DMS). Cette présentation permet de visualiser l'influence relative de chaque type de délai sur le séjour des patients à l'urgence, facilitant ainsi l'identification des facteurs majeurs contribuant à sa prolongation.

Tableau 4.1 principaux constats observés sur la DMS des patients à l'urgence (2021-2023)

Type de délai / facteur	Médiane (h)	Q1–Q3 (h)	Variabilité	Impact sur la DMS (durée moyenne de séjour)
Séjour sur civière (total)	22.22	Q1–Q3 serrés	Élevée	Étroitement lié à l'attente d'un lit d'hospitalisation.
Temps d'attente avant consultation (médecin)	2.1	1.8-2.5	Moyenne	Allonge modérément le séjour, mais reste prévisible.
Examen d'imagerie	1.83	~1.5–2.0	Faible	Peu d'impact, délais stables.
Consultation spécialisée	8.11	8.0 –8.2	Faible	Impact élevé sur la DMS ($\approx$ 8 h systématiques).
Admission hospitalière (attente lit)	11.25	9.8–12.1	Faible	Impact majeur, principale cause de prolongation du séjour.

4.13 Discussion choix des variables

Certaines variables mobilisées dans l'analyse descriptive, notamment les délais d'attente pour la consultation spécialisée, les examens d'imagerie ou l'admission hospitalière, contribuent directement à la durée moyenne de séjour (DMS). Leur sélection repose sur des critères méthodologiques rigoureux, et l'analyse descriptive a été conçue de manière à évaluer l'influence relative de chacun de ces délais sur la DMS. Alors que la DMS constitue une mesure globale du séjour du patient, chacune des variables retenues (délai de consultation, d'imagerie ou d'admission) reflète un aspect spécifique et objectivable du parcours hospitalier. Cette démarche permet ainsi d'identifier les facteurs les plus déterminants dans la prolongation du séjour, tout en respectant les postulats méthodologiques des analyses statistiques employées. Les résultats confirment l'existence de relations significatives entre la DMS et les trois variables principales étudiées, soit le délai d'attente pour les examens d'imagerie, pour la consultation spécialisée et pour l'obtention d'un lit, ce qui met en évidence les leviers prioritaires d'action afin de réduire les délais d'attente et d'optimiser la gestion des flux à l'urgence.

4.14 Conclusion

Les analyses montrent que la gestion de la DMS sur civière est influencée par plusieurs facteurs. Les principaux sont la saisonnalité (pics en fin d'année), les priorités de triage, les types d'orientation, et le délai d'attente pour hospitalisation, qui présente une corrélation élevée avec la DMS. Certaines spécialités, comme la psychiatrie et l'hématologie, impactent significativement la DMS, même après l'exclusion des valeurs aberrantes. Pour optimiser la DMS, plusieurs actions sont recommandées. Il est essentiel de réduire les délais d'attente pour l'hospitalisation, ainsi que ceux liés aux spécialités critiques. Un renforcement de la planification est nécessaire, en particulier pour anticiper les périodes de forte

demande. Par ailleurs, une exploration approfondie des causes des longs séjours sur civière permettrait d'identifier et de résoudre les problèmes spécifiques contribuant à ces durées prolongées.

Le prochain chapitre analysera les paramètres expliquant ces longs séjours et proposera un modèle prédictif pour mieux gérer les patients sur civière.

CHAPITRE 5

IMPLÉMENTATION DE MODÈLES PRÉDICTIFS

Ce chapitre est consacré au développement et à l'évaluation des modèles prédictifs visant à anticiper la durée de séjour des patients sur civière à l'urgence. La section 5.1 détaille la préparation des données et la création des variables prédictives pour l'entraînement des modèles. La section 5.2 évalue les performances des modèles de prédiction. La section 5.3 présente la modélisation des données. La section 5.4 met en avant les performances des modèles testés, tels que la régression linéaire, le KNN, la régression logistique, l'arbre de décision, le gradient boosting et la forêt aléatoire. La section 5.5 compare les performances des modèles prédictifs afin d'identifier l'approche la plus adaptée. La section 5.6 explore les résultats obtenus via un tableau de bord interactif et décrit le processus d'implémentation de la solution pour faciliter l'interprétation et l'application des prédictions. La section 5.7 présente l'architecture de la solution développée. Enfin, la section 5.8 résume les principaux résultats et propose des pistes d'amélioration pour affiner davantage la prédiction de la durée de séjour sur civière.

5.1 Préparation et création de variables de prédiction

Les variables prédictives utilisées dans ce modèle proviennent de cinq sources principales : les informations relatives aux patients, les données de triage à l'urgence, les signes vitaux, l'historique des visites à l'urgence et l'historique des hospitalisations.

5.1.1 Variables des patients

Les variables âge et sexe permettent d'identifier le profil des patients. Les patients âgés restent plus longtemps sur civière, et l'interaction âge-sexe est une variable prédictive potentielle.

Tableau 5.1 variables associées au patient

Variable	Description	Catégorisation
Sexe	Le sexe du patient	1 : masculin, 0 : féminin, 3 : autre
Âge	L'âge du patient	

5.1.2 Variables de triage à l'urgence

Les variables de triage jouent un rôle clé dans la compréhension de la situation d'urgence des patients. Elles incluent la priorité de triage, qui évalue la gravité de l'état du patient sur une échelle de 1 à 5, et le mode d'arrivée, que ce soit par ambulance, souvent associé à des cas critiques, ou par déplacement

autonome (ambulant), indiquant généralement une urgence moins sévère. Les diagnostics des patients, ainsi que les raisons de leur visite, influencent également la durée de séjour, certains diagnostics complexes ou critiques nécessitant des ressources accrues. La raison de visite, en particulier, est un paramètre déterminant pouvant influencer directement la décision de placement sur civière. Par exemple, des urgences médicales critiques ou des cas nécessitant des diagnostics immédiats, comme des douleurs thoraciques, un traumatisme crânien ou des complications postopératoires, requièrent souvent une prise en charge rapide et des soins intensifs. L'orientation des patients, comme une admission ou un transfert, a également un impact direct sur la gestion de leur séjour à l'urgence. Enfin, l'heure d'arrivée est un facteur déterminant, influençant à la fois le temps d'attente et la durée totale du séjour.

Tableau 5.2 variable de triage de patient à l'urgence

Variable	Description	Catégorisation
DateArrivée	Date d'arrivée à l'urgence	
HeureArrivée	Heure d'arrivée à l'urgence	
ModeArrive	Le mode d'arrivée du patient à l'urgence	Catégorisé en deux groupes : Le mode 1, 3, 4, 5, 6 et 7 sont regroupés sous « Ambulance » et le transport spécialisé et le mode 2 : « ambulant » voulant dire que le patient s'est rendu par ses propres moyens et qu'il peut se déplacer.
PrioritéTriage	Priorité de triage	Catégorisé de 1 à 5 en fonction du niveau d'urgence
RaisonVisite	Raison de la visite à l'urgence	Le regroupement de 169 codes de raison de visite, basé sur la description de chaque code, a permis de déterminer 12 groupes de raison de visite.
Diagnostic	Le code diagnostique du patient à l'urgence	Le regroupement de 25 codes de diagnostic en grandes catégories thématiques, basées sur la nature des diagnostics, a permis de déterminer 15 groupes de diagnostic.
Orientation	L'orientation à la sortie du patient. Par exemple : Admission CH	Le regroupement de 9 codes d'orientation en 6 groupes d'orientation distincts.

5.1.3 Les signes vitaux

Les signes vitaux sont essentiels pour évaluer l'état de santé des patients à l'urgence et influencent directement la durée de séjour sur civière. Ils incluent la fréquence respiratoire, la fréquence cardiaque, les tensions artérielles, la température corporelle, la saturation en oxygène et le niveau de glucose. Une fréquence respiratoire anormale nécessite souvent des interventions immédiates, telles que l'oxygénothérapie ou la ventilation, prolongeant ainsi le séjour sur civière. De même, une fréquence cardiaque anormale, comme des arythmies ou un choc cardiogénique, exige des traitements complexes qui augmentent la durée de prise en charge. La température corporelle, qu'il s'agisse de fièvre ou

d'hypothermie, peut indiquer une infection ou un choc nécessitant une stabilisation prolongée avant transfert. Les tensions artérielles, systolique et diastolique, jouent également un rôle crucial : une pression anormale peut signaler une crise cardiaque, un AVC ou une hémorragie, nécessitant des interventions prolongées. La saturation en oxygène, lorsqu'elle est faible (hypoxémie), requiert souvent une oxygénothérapie ou une ventilation assistée, retardant la libération de la civière. Enfin, le niveau de glucose, en cas d'hypoglycémie ou d'hyperglycémie, demande une surveillance attentive et des interventions spécifiques, augmentant le temps de séjour. Ensemble, ces paramètres fournissent des informations critiques pour orienter les soins et anticiper les besoins en ressources hospitalières.

Tableau 5.3 les signes vitaux

Variable	Description	Catégorisation
Respiratoire	Fréquence respiratoire	Catégorisé de très faible à très élevé
Pouls	Fréquence cardiaque	Catégorisé de très faible à très élevé
Température	Température corporelle	Catégorisé de très faible à très élevé
Tension_dya	Tension artérielle diastolique	Catégorisé de très faible à très élevé
Tension_sys	Tension artérielle systolique	Catégorisé de très faible à très élevé
Saturation	Saturation en oxygène	Catégorisé de très faible à très élevé
Glucomètre	Niveau de glucose	Catégorisé de très faible à très élevé

5.1.4 Variables de l'historique de l'urgence

Les données collectées à l'urgence permettent d'évaluer le type d'admissions ainsi que leur niveau d'urgence, tout en identifiant les facteurs qui influencent les délais et la durée de séjour des patients. Parmi ces données figure le nombre de patients inscrits à l'urgence, qui reflète l'afflux récent et la charge actuelle sur les ressources disponibles. Le délai moyen d'attente pour hospitalisation, mesurant le temps entre la décision d'hospitalisation et l'admission effective, met en évidence l'impact de la disponibilité des lits et de la saturation des spécialités sur l'efficacité des processus d'admission.

Le délai d'attente pour consulter un médecin spécialiste représente un autre facteur déterminant, directement influencé par la disponibilité et la réactivité des spécialités médicales. De même, le délai d'attente pour les examens d'imagerie, lié à la gestion des diagnostics, a une incidence directe sur la durée moyenne de séjour en cas de retards. Le taux d'occupation des civières, qui indique la proportion de civières utilisées par rapport au total disponible, et le nombre de patients sur civières fournissent des indications claires sur la pression exercée sur les ressources critiques de l'urgence. Enfin, des paramètres tels que le nombre de jours depuis la dernière visite à l'urgence ou encore le nombre total de visites effectuées au cours des 36 derniers mois offrent une meilleure compréhension des profils des patients

fréquents et de leurs besoins médicaux. Ces données sont cruciales pour optimiser les ressources hospitalières et réduire les délais d'attente tout en garantissant une prise en charge rapide et adaptée.

Tableau 5.4 variable de l'historique à l'urgence

Variable	Description
Nb_patients_inscrits_urgence_Dernier_4_Heures	Nombre total de patients inscrits à l'urgence au cours des 4 dernières heures
Nb_patients_inscrits_urgence_Dernier_8_Heures	Nombre total de patients inscrits à l'urgence au cours des 8 dernières heures
Nb_patients_inscrits_urgence_Dernier_12_Heures	Nombre total de patients inscrits à l'urgence au cours des 12 dernières heures
Delai_Attente_Admission	Le délai moyen d'attente pour une admission à l'hôpital est calculé à partir de l'heure d'arrivée du patient sur la civière, puis de l'enregistrement de la demande d'hospitalisation dans les systèmes MedUrge et ADT, jusqu'au transfert du patient vers un lit vacant.
Delai_Moyenne_Attente_Admission_Dernier_8_Hours	Délai moyen d'attente pour l'admission à l'hôpital des patients enregistrés au cours des 8 dernières heures.
Delai_Moyenne_Attente_Admission_Dernier_12_Hours	Délai moyen d'attente pour l'admission à l'hôpital des patients enregistrés au cours des 12 dernières heures.
Delai_Attente_Consul_Spec	Délai moyen d'attente pour une consultation avec un médecin spécialiste, calculé à partir de l'heure d'arrivée du patient sur la civière.
Moyenne_Delai_Attent_Consul_Spec_Dernier_8_Hours	Délai moyen d'attente pour une consultation avec un médecin spécialiste, calculé pour les patients enregistrés au cours des 8 dernières heures
Moyenne_Delai_Attent_Consul_Spec_Dernier_12_Hours	Délai moyen d'attente pour une consultation avec un médecin spécialiste, calculé pour les patients enregistrés au cours des 12 dernières heures
Delai_Attente_Imagerie	Délai d'attente de réalisation des examens d'imagerie.
Moyenne_Delai_Attente_Imag_Dernier_8_Hours	Délai moyen d'attente pour la réalisation d'un examen d'imagerie, calculé pour les patients enregistrés au cours des 8 dernières heures.
Moyenne_Delai_Attente_Imag_Dernier_12_Hours	Délai moyen d'attente pour la réalisation d'un examen d'imagerie, calculé pour les patients enregistrés au cours des 12 dernières heures.
Nbr_Jour_Depuis_Dernier_Visit	Nombre de jours écoulés depuis la dernière visite d'un patient à l'urgence.
Nbr_Visit_Dernier_36_Mois	Nombre total de visites d'un patient à l'urgence au cours des 36 derniers mois.
Nbr_Patients_Sur_Civiere	Nombre total de patients actuellement pris en charge sur des civières.
Taux_Occ_Civ	Taux d'occupation des civières, calculé en pourcentage, représentant la proportion de civières utilisées par rapport au total disponible à l'urgence.

5.1.5 Historique d'hospitalisation

L'historique d'hospitalisation joue un rôle prépondérant dans l'analyse des facteurs influençant la durée de séjour à l'urgence. Le nombre de lits disponibles dans un établissement de santé reflète la capacité d'accueil actuelle et influence directement la gestion des admissions et des patients. La date de sortie après la dernière hospitalisation permet de calculer le temps écoulé depuis l'hospitalisation précédente, fournissant des informations sur la fréquence et la continuité des soins.

Le nombre d'hospitalisations au cours des 36 derniers mois offre une perspective sur la consommation des ressources hospitalières et permet d'identifier les patients ayant des besoins fréquents ou complexes. Enfin, la durée moyenne d'hospitalisation par patient, calculée sur la même période, évalue l'intensité des soins nécessaires. Ces variables constituent des indicateurs clés pour comprendre les parcours de soins des patients et optimiser la planification hospitalière.

Tableau 5.5 variable de l'historique d'hospitalisation

Variable	Description
Nbr_Lit_Dispo	Nombre total de lits disponibles.
Nbr_Hospitalisation_Dernier_12_Mois	Nombre total d'hospitalisations d'un patient au cours des 12 derniers mois.
Moyenne_Dure_Hospit_Day_Dernier_12_Mois	Durée moyenne, en jours, des hospitalisations d'un patient au cours des 12 derniers mois.
Nbr_Hospitalisation_Dernier_36_Mois	Nombre total d'hospitalisations d'un patient au cours des 36 derniers mois.
Dure_Hospit_Day_Dernier_36_Mois	Durée moyenne, en jours, des hospitalisations d'un patient au cours des 36 derniers mois.
Dernier_Hospit_Depart_Date	Date de sortie de la dernière hospitalisation d'un patient.
LastHospitService	Le dernier service d'hospitalisation.

5.2 Évaluation des modèles pour la prédiction

5.2.1 Ajustement du modèle

Nous présentons le développement d'une série de modèles prédictifs pour déterminer la durée de séjour sur civière pour un patient, en utilisant des données recueillies de janvier 2021 à décembre 2023. Six différents modèles seront étudiés et une analyse comparative sera réalisée. Les modèles sont : la régression linéaire, la régression logistique, le modèle KNN, l'arbre de décision, le « *gradient boosting* » et la forêt aléatoire. La précision de ces modèles sera comparée afin de déterminer le plus performant. Le jeu de données total comprend 94 743 visites, dont 75 794 (80 %) sont dédiées à l'entraînement et 18 949 (20 %) réservées aux tests.

Les modèles ont été conçus pour traiter plusieurs variables catégorielles grâce à un encodage approprié, permettant ainsi leur interprétation optimale par les algorithmes. De plus, les données ont été normalisées afin d'uniformiser les échelles des variables, ce qui contribue à améliorer la performance des modèles.

Nous avons testé une variété d'hyper paramètres pour nos six modèles. Parmi les paramètres ajustés figurent le coefficient de régularisation et le type de régularisation pour la régression logistique, le nombre d'arbres et la profondeur maximale pour la forêt aléatoire, le taux d'apprentissage et le nombre d'itérations pour le « *gradient boosting* », ainsi que le nombre de voisins et la métrique utilisée pour le modèle KNN.

Nous avons utilisé la validation croisée « *K-fold* » pour évaluer la précision des modèles, ce qui nous a permis de mesurer non seulement leur capacité à prédire la durée de séjour, mais aussi leur aptitude à se généraliser sur un jeu de données indépendant. Les performances obtenues pour chaque configuration d'hyper paramètres ont été soigneusement enregistrées et analysées.

Après l'entraînement, le modèle a été sauvegardé, facilitant ainsi une réutilisation rapide et efficace pour des prédictions futures. Ce modèle est appliqué sur un jeu de données mis à jour quotidiennement, comprenant les informations des patients depuis le 1er janvier 2021 jusqu'à sept jours avant la date actuelle. Cela permet à ce modèle de s'améliorer progressivement au fil de l'intégration des nouvelles données.

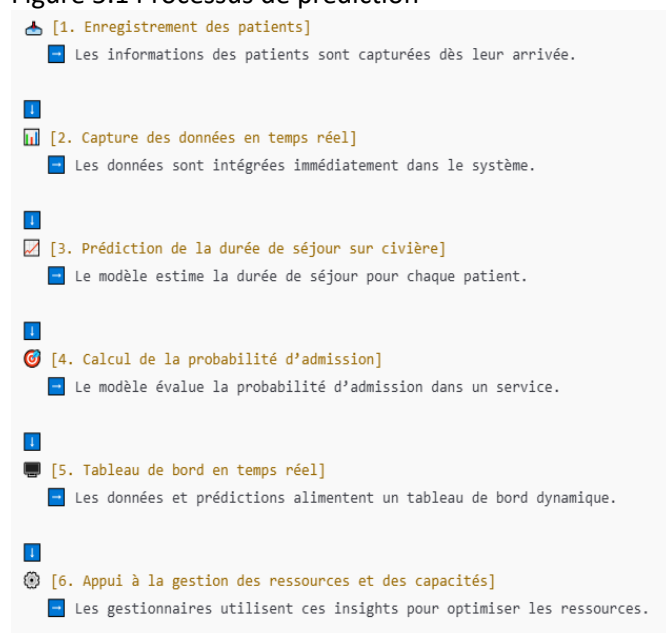
5.2.2 Évaluation globale

Après l'entraînement initial sur les données disponibles, le modèle, optimisé avec les meilleurs hyper paramètres identifiés, a été appliqué à un second ensemble de données pour la période de janvier 2024 à décembre 2024. Ces données concernent les patients sur civière à l'urgence et visent à évaluer la capacité du modèle à généraliser et à fournir des prédictions précises dans un contexte évolutif. L'objectif principal est de produire des estimations fiables de la durée de séjour requise. Les performances du modèle de prédiction, incluant l'estimation de la durée approximative de séjour à l'urgence, ont conduit à développer un second modèle visant à prédire la probabilité d'admission dans un service hospitalier spécifique. Ces prédictions offrent une estimation quantitative des besoins en services hospitaliers, améliorant ainsi la compréhension de leur répartition au sein de la population.

5.2.3 Évaluation en temps réel

Nous avons développé un processus dynamique pour améliorer l'évaluation des besoins en services hospitaliers à mesure que de nouvelles visites de patients sont enregistrées. Le modèle, déjà utilisé pour prédire la durée de séjour d'un patient, est désormais configuré pour actualiser ces prédictions en temps réel. À chaque nouvelle visite, le modèle calcule la durée de séjour sur civière et cumule ses prédictions pour les patients présents dans l'hôpital. Ce cumul en continu permet également d'estimer la probabilité d'admission dans un service hospitalier pour chaque patient. Ces données alimentent un tableau de bord actualisé en temps réel, offrant une vue complète de l'état actuel des patients. Cet outil est particulièrement utile pour les gestionnaires hospitaliers, en leur fournissant une représentation claire et en temps réel de la charge probable sur différents services, facilitant ainsi les décisions concernant l'allocation des ressources et la gestion des capacités (Figure 5.1).

Figure 5.1 Processus de prédiction



5.3 Modélisation

5.3.1 Préparation des données

La création des jeux de données est basée sur les variables prédictives décrites dans la section « 6,1 Préparation et création de variables de prédiction ». Ces données sont préparées à l'aide d'une procédure stockée nommée « *USPEntrainnementListPatientUrgenceDMS* » et sont ensuite enregistrées dans une

table appelée « *TbListPatientsUrgenceEntrainnement* ». Par la suite, nos modèles accèdent à cette table pour s’entraîner et effectuer leurs prédictions.

5.3.2 Gestion des valeurs manquantes

Pour garantir l’intégrité des données et améliorer leur qualité, un processus de gestion des valeurs manquantes a été mis en place.

- La colonne « LastHospitDepartDate », contenant des valeurs manquantes, est complétée par une date par défaut éloignée des dates existantes, en l’occurrence « 01-01-1988 ».
- La colonne LastHospitService, contenant des valeurs nulles, a été complétée par un code de service inexistant, fixé à -1.
- La colonne PrioriteTriage, contenant une valeur NAN égal à 1 indiquant que nous n’avons pas la priorité de triage, a conduit à la suppression de la ligne correspondante.
- Pour les colonnes des signes vitaux (Pouls, Température, Saturation, Glucomètre), les valeurs nulles ont été remplacées par des valeurs normales par défaut (Tableau 6-6). Pour ce qui est des lignes contenant des valeurs nulles pour Respiratoire, Tension_sys et Tension_dya, ces lignes ont été supprimées (Tableau 6-6). Ces étapes assurent une utilisation optimale des données pour les analyses prédictives et la modélisation, tout en réduisant les biais potentiels liés aux données manquantes.

Tableau 5.6 Gestion des valeurs manquantes pour les signes vitaux

Signes vitaux	Nombre des lignes NULL	Ratio= (Nombre des lignes nul) /Total, Nombre total : 94 743	Méthode Imputation des valeurs manquantes
Respiratoire	3229	3,4 %	Supprimer les lignes.
Pouls	3052	3,22 % :	Remplacer les valeurs nulles par une valeur normale égale à 72.
Tension_sys	6385	6.7 %	Supprimer les lignes.
Tension_dya	6419	6,77 %	Supprimer les lignes.
Température	21 717	22 %	Remplacer les valeurs nulles par une valeur normale égale à 37.
Saturation	3435	3,6 %	Remplacer les valeurs nulles par une valeur normale égale à 98.
Glucomètre	72 011	76 %.	Remplacer les valeurs nulles par une valeur normale égale à 5,5.

5.3.3 Encodage des variables catégorielles

Les valeurs catégorielles soient : mode d'arrivée, diagnostique, code raison Visite et orientation ont été regroupées à l'aide de dictionnaires de mappage et encodées.

- **Mode d'arrivée** : Les modes d'arrivée des patients sont regroupés en deux catégories principales. La catégorie Ambulance/Transport spécialisée comprend : l'ambulance (mode 1), la police (mode 3), l'armée (mode 4), l'hélicoptère (mode 5), le transport adapté (mode 6) et le fourgon (prison) (mode 7). Tandis que la catégorie Patient ambulant comprend uniquement le mode 2 désignant les patients arrivant ambulants (sur pieds).

Tableau 5.7 Regroupement mode d'arrivée

Id	Mode Arrivée	Regroupement	Nombre des lignes
1	Ambulance	Ambulance/Transport spécialisée	46 346
3	Police		
4	Armée		
5	Hélicoptère		
6	Transport adapté		
7	Fourgon (prison)		
2	Ambulant (sur pieds)	Ambulant (sur pieds)	48 396

- **Code d'orientation** : Les 9 codes d'orientation ont été regroupés en 6 groupes d'orientation pour simplifier l'analyse et améliorer la pertinence des catégories (Tableau 6-8).

Tableau 5.8 Regroupement par orientation

Id	Description	Groupe	Raison du regroupement	Nombre des lignes
1	En cours	En cours	Processus en cours	0
	Transfert d'établissement	Changements de structure	Transfert entre établissements ou unités	2197
19	Transfert d'unité			
15	Retour à domicile	Résolutions normales	Retour à domicile, réorienté, ou référé	46 541
16	Réorienté			
18	Référé			
17	Décès	Événements critiques	Décès	28
11	Visite annulée	Annulations	Visite annulée ou départ avant prise en charge	361
14	Départ avant prise en charge			
12	Admission CH	Admissions	Admission à l'hôpital	45 615

- **Code diagnostique :** Les 25 codes de diagnostic ont été regroupés en 15 grandes catégories thématiques, reflétant la nature des diagnostics pour une analyse plus structurée.

Tableau 5.9 Regroupement des diagnostics

Id	Description	Regroupement	Nombre des lignes
1	Maladies du système nerveux	Maladies du système nerveux	2004
2	Maladies de l'œil et de ses annexes	Maladies de l'œil	210
3	Maladie de l'oreille et de l'apophyse mastoïde	Maladie de l'oreille	841
4	Maladies de l'appareil respiratoire	Maladies de l'appareil respiratoire	7332
5	Maladies de l'appareil circulatoire	Maladies de l'appareil circulatoire	10 776
6	Maladies de l'appareil digestif	Maladies de l'appareil digestif	10 758
7	Maladies du système ostéo-articulaire, des muscles et du tissu conjonctif	Maladies du système ostéo-articulaire	3162
8	Maladies dermatologiques	Maladies dermatologiques	1407
9	Maladies endocriniennes	Maladies endocriniennes	2520
10	Maladies de l'appareil génito-urinaire	Maladies de l'appareil génito-urinaire	7195
11	Grossesse, accouchement et puerpéralité	Grossesse, accouchement et puerpéralité	518
12	Certaines affections dont l'origine se situe dans la période périnatale	Affections périnatales	79
13	Maladies hématologiques et immunitaires	Maladies hématologiques	1398
14	Tumeurs	Tumeurs	1638
15	Certaines maladies infectieuses et parasitaires	Maladies infectieuses	808
16	Troubles mentaux et du comportement	Troubles mentaux	9796
17	Troubles mentaux et du comportement liés à l'utilisation de substances psychoactives		
18	Troubles mentaux organiques, y compris les troubles somatiques		
19	Lésions traumatiques	Lésions traumatiques	6527
20	Intoxications et effets toxiques	Intoxications et effets toxiques	1246
22	Symptômes, signes et résultats anormaux d'examens cliniques et de laboratoire, non classés ailleurs	Symptômes, signes et résultats anormaux d'examens cliniques et de laboratoire, non classés ailleurs	2117
21	Certaines autres conséquences de causes externes	Certaines autres conséquences de causes externes	20 241
23	Malformations congénitales et anomalies chromosomiques	Malformations congénitales et anomalies chromosomiques	13
24	Code provisoire pour la recherche et les affections suspectées	Code provisoire pour la recherche et les affections suspectées	2114
25	Facteurs influant sur l'état de santé et motifs de recours aux services de santé	Facteurs influant sur l'état de santé et motifs de recours aux services de santé	2042

- **Code de raison de la visite** : Les 169 codes de raison de visite ont été regroupés en 12 catégories basées sur leurs descriptions :

Tableau 5.10 Regroupement des codes de raison de la visite

Codes de raison de la visite	Description	Groupe
0100, 0101, 0102, 0103, 0104, 0105, 0106, 0107, 0108, 0150, 0151, 0190	Problèmes cardiaques et circulatoires	Cardiovasculaire
1100, 1101, 1102, 1103, 1104, 1105, 1130, 1131, 1132, 1140, 1180	Troubles respiratoires	Respiratoire
0700, 0701, 0702, 0703, 0704, 0705, 0706, 0707, 0730, 0750, 0790	Troubles neurologiques, AVC et vertiges	Neurologique
0400, 0401, 0402, 0403, 0404, 0405, 0406, 0407, 0408, 0430, 0431, 0440, 0441, 0450, 0451, 0452, 0480, 0490	Symptômes digestifs et abdominaux	Gastro-intestinal
0500, 0501, 0502, 0503, 0504, 0505, 0506, 0550, 0551, 0590, 0800, 0801, 0802, 0803, 0804, 0805, 0840, 0850, 0890	Troubles urinaires, génitaux, grossesse	Urinaire/génital
0290, 0291, 0292, 0293, 0490, 0790, 1090, 1091, 1092, 1093, 1490, 1491, 1492, 1493, 1494, 1495	Blessures, traumatismes, accidents	Traumatique
1200, 1201, 1202, 1203, 1204, 1205, 1206, 1207, 1208, 1209, 1240, 1270, 1271, 1290, 1291, 1292, 1293, 1294	Pathologies cutanées, éruptions et plaies	Dermatologique
0600, 0601, 0602, 0603, 0604, 0605, 0606, 0607, 0630, 0680, 0681	Troubles psychiatriques et comportementaux	Psychiatrique/social
1500, 1501, 0480	Fièvre, infections, maladies contagieuses	Infectieux/Fièvre
0430, 0431, 0730, 1530, 1531	Problèmes spécifiques aux nourrissons et enfants	Pédiatrique
0103, 1508, 1510, 1530, 1570	Symptômes généraux ou non spécifiques	Symptômes généraux
0393, 0394, 1504, 1505, 1506, 1507, 1509, 1571, 1572	Diagnostic ou intervention diversifiée	Divers/autres

5.3.4 Processus de prédiction

Le processus de prédiction repose sur plusieurs étapes clés. Après le nettoyage des données, la gestion des variables avec des valeurs nulles et la catégorisation des variables catégorielles, les données sont divisées en deux ensembles : un ensemble d'entraînement (80 %) et un ensemble de validation (20 %). Les variables prédictives (X) et la cible (y) sont clairement définies. Un pipeline est ensuite mis en place pour normaliser les données et entraîner les modèles. Différents algorithmes, tels que la forêt Aléatoire, sont testés avec une recherche d'hyper paramètres optimisés via « *GridSearchCV* ». Le modèle sélectionné est évalué sur l'ensemble de validation à l'aide de métriques comme le MAE et le R² pour mesurer sa

performance. Une fois validé, le modèle final est sauvegardé avec les « *scalers* » et les colonnes utilisées, facilitant son déploiement pour des prédictions.

5.4 Performance des modèles spécifiques

5.4.1 Modèle de régression linéaire

Nous avons évalué le modèle de régression linéaire, conçu pour capturer les relations linéaires entre les variables, ainsi que deux de ses variantes principales. Le modèle Lasso, qui utilise la régularisation pour identifier les variables les plus pertinentes, et le modèle Ridge, qui améliore les performances grâce à l'ajustement d'hyper paramètres, ont également été testés pour optimiser la précision et la robustesse des prédictions.

Le modèle de régression linéaire a été évalué à l'aide de métriques telles que le MAE (4,46 heures), indiquant une erreur moyenne relativement faible par rapport à la DMS des patients sur civière (19 heures), et le R^2 (0,72), reflétant sa capacité à expliquer 72 % de la variance des données.

Le modèle de régression linéaire a démontré une précision acceptable, avec un RMSE de 6,45 et une corrélation de Pearson globale de 0,84, montrant une forte concordance entre les valeurs prédites et réelles. Cependant, seulement 11 % des prédictions de ce modèle se situent dans une plage d'erreur de ± 5 %, révélant des limitations pour les prédictions précises.

Tableau 5.11 Résultats de modèle régression linéaire

MAE	MSE	RMSE	R^2	Corrélation de Pearson	Taux de Précision (R L) : (Tolérance : ± 5 %)
4,46 h	41,58	6,45	0,72	0,84	11.0

- **Validation croisée** : Nous avons appliqué une validation croisée : les scores R^2 sur 5 plis varient entre 0,69 et 0,72, avec une moyenne de 0,71. Ces résultats indiquent que le modèle est relativement stable et généralisable.
- **Analyse des résidus** : Les résidus ne suivent pas une distribution normale, comme l'indique le test de *Shapiro-Wilk* (p -value < 0.0001), ce qui pourrait influencer certaines interprétations statistiques. Les erreurs résiduelles présentent une moyenne de 0,002, une médiane de -0,97 et un écart-type de 6,47 heures.

Le modèle Lasso, bien que présentant des performances globales similaires à celles de la régression linéaire, se démarque par sa capacité à identifier des variables clés grâce à la régularisation. Parmi les 78 colonnes analysées, 51 variables se sont révélées statistiquement significatives ($p < 0,05$), mettant en évidence leur importance dans la modélisation. Les coefficients des variables significatives reflètent leur impact relatif sur la durée de séjour. Les variables les plus corrélées avec la durée de séjour incluent le délai d'attente d'admission (corrélation = 0,73), le délai d'attente de consultation spécialisé (0,49) et le Service d'admission (0,25).

Tableau 5.12 les variables les plus fortement corrélées avec durée de séjour

Variables	Corrélation
DelaiAttenteAdmissionPatient	0,73
DelaiAttenteConsulSpec	0,49
AvgDelaiAttentConsulSpecLast8Hours	0,40
AvgDelaiAttenteAdmissionLast8Hours	0,38
ServiceAdmissionId	0,25

Le modèle Ridge, configuré avec une validation croisée à 5 plis (CV=5) et un hyper paramètre alpha variant entre 1 et 10, a démontré des performances supérieures à celles de la régression linéaire. Avec un MAE de 4,43, un RMSE de 6,46, et un R^2 de 0,73, il montre une meilleure capacité à expliquer la variance des données cibles tout en contrôlant le surajustement grâce à la régularisation intégrée.

Tableau 5.13 Résultats de modèle régression Ridge

MAE	MSE	RMSE	R^2	Corrélation de Pearson	Taux de Précision (RL) : Tolérance : $\pm 5\%$
4,43 h	41,58	6,46	0,73	0,84	12.00 %

Les résultats soulignent l'intérêt d'explorer des modèles avancés. Nous examinerons ensuite le modèle de régression logistique pour approfondir l'analyse et exploiter pleinement les informations clés.

5.4.2 Régression logistique

La régression logistique a été utilisée pour prédire la durée de séjour des patients en cinq classes : très court (0-12 heures), court (12-24 heures), moyen (24-48 heures), long (48-72 heures) et très long (plus de 72 heures). Le modèle a été configuré avec les paramètres suivants : max_iter=1000 pour assurer un nombre suffisant d'itérations pour la convergence, random_state=42 pour garantir la reproductibilité des résultats, multi_class='multinomial' pour résoudre un problème multiclass en une seule étape, et solveur='lbfgs', un « solveur » efficace pour les problèmes de petite à moyenne taille. Ce modèle offre une

classification catégorisée permettant d'analyser la gestion des patients en fonction de leur durée d'hospitalisation. Les résultats montrent une précision globale de 72 %, avec un F1-score pondéré de 0,70 (Figure 5.2). La matrice de confusion révèle de bonnes performances sur les catégories « Très Court » et « Longue », avec respectivement 3747 et 7626 prédictions correctes. Cependant, les classes intermédiaires, comme « Moyen » et « Court », présentent davantage de confusions, probablement dues à des caractéristiques explicatives se chevauchant (Figure 5-3).

Cette limitation des classes intermédiaires met en évidence l'intérêt d'explorer des modèles plus avancés. Dans la section suivante, nous examinerons le modèle K-Nearest Neighbors (KNN) pour affiner la classification et améliorer la précision, en particulier pour les classes intermédiaires.

Figure 5.2 Résultats de la régression logistique

```


--- Rapport de Classification ---
      precision    recall  f1-score   support

Très Court      0.65      0.61      0.63      6149
Court           0.00      0.00      0.00       196
Moyen           0.64      0.44      0.52      2788
Longue          0.77      0.91      0.83      8419
Très Long       0.97      0.42      0.59        76

accuracy              0.72      17628
macro avg           0.61      0.48      0.51      17628
weighted avg        0.70      0.72      0.70      17628

```

Figure 5.3 Matrice de confusion -Régression logistique



5.4.3 Modèle KNN

Le modèle K-Nearest Neighbors (KNN) a été appliqué pour prédire la durée de séjour des patients à l'urgence en fonction de leurs caractéristiques individuelles. Les hyper paramètres testés incluaient le nombre de voisins [3, 5, 7, 9, 11, 13, 15, 17, 20], les poids [« uniform », « distance »], et la métrique de distance [« euclidean », « manhattan »]. Grâce à GridSearchCV, les meilleurs hyper paramètres ont été déterminés : 13 voisins, une métrique euclidienne, et des poids basés sur la distance. Ces paramètres permettent aux voisins les plus proches d'exercer une influence significative sur les prédictions, optimisant ainsi la précision du modèle.

Les performances du modèle, évaluées à l'aide de métriques classiques, révèlent une capacité modérée à prédire les durées de séjour. Avec un coefficient de détermination (R^2) de 0,572 9, le modèle explique environ 57 % de la variance des données. La MAE de 5,54 heures indique une erreur moyenne notable, et le RMSE de 7,99 heures met en lumière des écarts importants, particulièrement pour les cas extrêmes de durées très courtes ou très longues. Cependant, la corrélation de Pearson, évaluée à 0,772 3, démontre une relation relativement forte entre les prédictions et les valeurs réelles, soulignant la capacité du modèle à capturer des tendances globales.

Malgré sa simplicité et sa capacité à modéliser des relations non linéaires, le modèle KNN a montré des limitations significatives. Il explique une partie importante de la variance, avec un R^2 modéré (0,52), et présente des erreurs élevées pour les cas atypiques, ce qui limite son utilisation dans notre contexte qui nécessite une grande précision. Ces résultats nous ont conduits à explorer, dans la section suivante, un modèle plus sophistiqué : l'arbre de décision (Figure 5.4).

Figure 5.4 Résultats du modèle KNN

```
--- Meilleurs Paramètres ---  
{'metric': 'euclidean', 'n_neighbors': 13, 'weights': 'distance'}  
  
--- Meilleur Score R² ---  
R² : 0.5249  
MAE (Mean Absolute Error) : 5.542614879334732  
RMSE (Root Mean Squared Error) : 7.991894805142959  
R² (Coefficient de détermination) : 0.5729571322646332  
Corrélation (Pearson) : 0.7722550603753553
```

5.4.4 Modèle Arbre de décision

L'arbre de décision a été configuré et optimisé à l'aide de « GridSearchCV », en explorant plusieurs hyper paramètres : la profondeur maximale [5, 10, 15, 20, 25, None], le nombre minimal d'échantillons requis

pour diviser un nœud [2, 4, 10, 20], le nombre minimal d'échantillons par feuille [1, 5, 10, 15, 20], et le nombre de caractéristiques à considérer pour chaque division [None, « sqrt », « log 2 »].

Une validation croisée en 5 plis a permis d'identifier les meilleurs paramètres : une profondeur maximale de 10, un minimum de 2 échantillons pour diviser un nœud, et 20 échantillons par feuille. Sur l'ensemble de validation, les performances obtenues démontrent une meilleure capacité de prédiction par rapport au modèle précédent : une moyenne erreur absolue (MAE) de 4,10 heures, une erreur quadratique moyenne (RMSE) de 6,26 heures, et un coefficient de détermination (R^2) de 0,74. De plus, la corrélation de Pearson entre les prédictions et les valeurs réelles atteintes 0,85, mettant en évidence une forte correspondance entre les valeurs prédites et observées.

En conclusion, l'arbre de décision offre une performance solide dans la prédiction de la durée de séjour. Cependant, pour affiner davantage les prédictions, nous explorerons l'approche du *gradient Boosting Regressor* dans la section suivante (Figure 5.5).

Figure 5.5 Résultats de l'arbre de décision

```
Nombre total de colonnes dans le DataFrame après encodage : 116
Fitting 5 folds for each of 48 candidates, totalling 240 fits

--- Meilleurs Hyperparamètres ---
{'max_depth': 10, 'max_features': None, 'min_samples_leaf': 20, 'min_samples_split': 2}

--- Meilleur Score  $R^2$  (validation croisée) ---
 $R^2$  : 0.7153

--- Résultats sur l'Ensemble de Validation ---
MAE : 4.10, MSE : 39.24, RMSE : 6.26,  $R^2$  : 0.74
```

5.4.5 Modèle de gradient de Boosting Regressor

Le modèle de Gradient de Boosting Regressor a été configuré avec les hyper paramètres suivants : un nombre d'estimateurs entre 100 200 et 300, un taux d'apprentissage variant entre 0,01 et 0,2, une profondeur maximale des arbres testée sur 3, 5 et 10, un nombre minimal d'échantillons pour diviser un nœud de 2, 5, et 10, et un nombre minimal d'échantillons par feuille de 1,3 et 5. De plus, différentes fractions d'échantillons par arbre ont été explorées : 0,8, 0,9 et 1,0.

L'optimisation de ces hyper paramètres a été réalisée à l'aide de *RandomizedSearchCV*, configuré avec une validation croisée à 5 plis (CV=5) et R^2 comme métrique d'évaluation. Après optimisation, les meilleurs

paramètres sélectionnés comprenaient un nombre d'estimateurs à 200 et une profondeur maximale des arbres de 5. Ces paramètres ont permis d'obtenir des performances solides sur l'ensemble de tests, avec une erreur absolue moyenne (MAE) de 3,80 heures et une racine carrée de l'erreur quadratique moyenne (RMSE) de 5,78 heures. Le coefficient de détermination (R^2), évalué à 0,78, montre que le modèle explique 78 % de la variance des durées de séjour, ce qui est particulièrement prometteur pour ce type d'application. Ces résultats démontrent une forte capacité du modèle à prédire avec précision les durées de séjour, tout en maintenant un bon équilibre entre la complexité et la généralisation. Cependant, afin d'améliorer davantage les performances, nous explorerons la forêt Aléatoire dans la section suivante (Figure 5.6).

Figure 5.6 Résultats du modèle de gradient de Boosting Regressor

```
--- Meilleurs Hyperparamètres ---  
{'n_estimators': 200, 'max_depth': 5}  
  
--- Résultats sur l'Ensemble de Test ---  
MAE : 3.80, MSE : 33.38, RMSE : 5.78,  $R^2$  : 0.78
```

5.4.6 Modèle de forêt aléatoire (RF)

Le modèle de forêt aléatoire a été optimisé à l'aide d'un « param_grid », explorant plusieurs combinaisons d'hyper paramètres :

- Nombre d'arbres dans la forêt (50, 100, 200, 300, 400) : correspond au nombre d'arbres dans la forêt. Un plus grand nombre d'arbres améliore généralement la performance, mais au prix d'un temps de calcul plus long.
- Profondeur maximale de l'arbre (5, 10, 20, 30, 40, 50) : désigne la profondeur maximale des arbres, c'est-à-dire le nombre maximal de divisions qu'un arbre peut contenir. Limiter la profondeur aide à prévenir le surajustement.
- Nombre minimum d'échantillons (2, 4) : indique le nombre minimum d'échantillons nécessaires pour diviser un nœud. Des valeurs plus élevées entraînent des arbres moins complexes, favorisant la généralisation.
- Nombre minimum d'échantillons dans une feuille terminale (1, 2) : correspond au nombre minimum d'échantillons requis dans une feuille terminale. Cela garantit que chaque branche finale de l'arbre contient au moins ce nombre d'échantillons.

La meilleure configuration, avec 200 estimateurs et une profondeur maximale des arbres fixée à 20, a permis d'obtenir des performances notables sur l'ensemble de validation. Les résultats incluent une erreur absolue moyenne (MAE) de 3,78 heures et un coefficient de détermination (R^2) de 0,77, montrant que le modèle explique 77 % de la variance des durées de séjour. Ces performances confirment la robustesse du modèle pour ce type de prédiction (Figure 5.6).

Figure 5.7 Résultats du modèle de forêt aléatoire

```
===== Modèle Forêt Aleatoire =====
Connexion réussie au serveur SQL Server !
c:\Users\kane9300\Anaconda3\envs\Nejib\travdms\serverProd\ForetAleatoire:51: UserWarning: pandas only supports SQL
tring URI or sqlite3 DBAPI2 connection. Other DBAPI2 objects are not tested. Please consider using SQLAlchemy.
df = pd.read_sql(query, conn)
Données chargées avec succès ! 94743 lignes chargées.
MAE: 3.78
R2 Score: 0.77
```

L'analyse des caractéristiques importantes révèle que le délai d'attente pour l'admission des patients est le facteur le plus influent (52,35 %), suivi du délai d'attente pour une consultation spécialisée (20,89 %) et du délai d'attente pour les imageries (2,39 %). Ces résultats montrent que les variables liées aux délais jouent un rôle crucial dans la prédiction des durées de séjour. Par ailleurs, d'autres facteurs tels que l'heure d'arrivée et l'âge effectif ont une contribution moindre, mais significative. Les performances du modèle de forêt aléatoire et les caractéristiques importantes mettent en évidence des domaines clés pour optimiser le délai d'attente pour les admissions et les consultations spécialisées.

5.5 Comparaison des performances des modèles

Dans le cadre de cette analyse prédictive, nous avons comparé six modèles pour identifier celui offrant les meilleures performances tout en garantissant une interopérabilité optimale. Le modèle de régression linéaire, souvent utilisé comme point de départ, a obtenu un R^2 de 0,72 et une MAE de 4,46 heures, révélant ses limites à capturer les relations complexes des données. De plus, bien que la régression logistique soit performante pour des tâches de classification, elle n'a pas été retenue, car elle n'est pas adaptée à ce problème de régression. Le K-Nearest Neighbors (KNN) a montré une amélioration par rapport à la régression linéaire, avec un R^2 de 0,52 et une MAE de 5,54 heures. Cependant, son incapacité à gérer efficacement les relations non linéaires et à traiter les cas atypiques limite son application. L'arbre de décision, quant à lui, a marqué une avancée significative avec un R^2 de 0,74 et une MAE de 4,10 heures, démontrant une capacité accrue à modéliser des structures complexes.

Le Gradient Boosting Regressor a affiché des performances impressionnantes, avec un R^2 de 0,78 et une MAE de 3,80 heures, grâce à sa capacité à capturer des relations complexes et à gérer efficacement des données variées. Toutefois, le modèle de la forêt aléatoire a obtenu un R^2 de 0,77 et une MAE légèrement inférieure de 3,78 heures, offrant ainsi une combinaison optimale entre précision et robustesse. Grâce à son mécanisme d'agrégation, elle garantit une meilleure généralisation et met en évidence les variables clés influençant les prédictions, telles que le délai d'attente pour l'admission (52,35 %) et les consultations spécialisées (20,89 %). Ces caractéristiques renforcent la pertinence du modèle dans ce contexte. En conclusion, bien que le Gradient Boosting présente un R^2 légèrement supérieur (0,78), la forêt aléatoire se distingue par sa capacité à équilibrer performance, simplicité d'interprétation et robustesse.

5.5.1 Choix retenus et justification

Après comparaison de la performance de six modèles et afin de sélectionner celui offrant les meilleurs résultats. Parmi ces modèles, le modèle de forêt aléatoire et le modèle de gradient de Boosting Regressor se distinguent par leurs performances élevées. La forêt aléatoire obtient une MAE de 3,78 heures, un RMSE de 5,78 heures, et un R^2 de 0,77, tandis que le Gradient Boosting présente des résultats très similaires avec une MAE de 3,80 heures, un RMSE de 5,78 heures, et un R^2 de 0,78. Bien que les deux modèles offrent des prédictions précises et une bonne généralisation, la forêt aléatoire est légèrement avantagée par une erreur absolue moyenne plus faible, la rendant particulièrement robuste pour ce type de données. Cependant, le Gradient Boosting excelle dans la capture des relations complexes et non linéaires, ce qui pourrait être un atout pour des analyses plus approfondies. En conclusion, les deux modèles sont adaptés, mais la forêt aléatoire est retenue comme le meilleur modèle pour ce cas précis, grâce à sa combinaison de précision et de robustesse.

Dans le contexte de notre analyse, nous avons choisi la forêt aléatoire, car il offre un équilibre satisfaisant entre performance et interprétabilité : il permet de visualiser l'effet de chaque facteur sur la variable cible, ce qui est essentiel pour fournir des recommandations compréhensibles aux décideurs et assurer la transparence de la démarche prédictive.

5.6 Tableau de bord prédictif

5.6.1 Création de modèles

Après avoir sélectionné le modèle de forêt aléatoire, un fichier de modèle prédictif a été généré sous le nom « FAPatientUrgence_model.pkl ». Ce format de fichier encapsule toutes les configurations du modèle,

ainsi que les poids appris par les algorithmes, permettant un déploiement et une réutilisation simplifiés. Grâce à ce format, les prédictions peuvent être effectuées sans nécessiter de réentraînement ou de reconfiguration du modèle. Ce modèle est conçu pour estimer efficacement la durée de séjour des patients sur civière, apportant une aide précieuse à la gestion des flux de patients. De plus, un deuxième modèle a été développé pour prédire la probabilité d'admission dans un service hospitalier spécifique, offrant ainsi une vision plus complète et précise des besoins hospitaliers. Ces outils contribuent à une prise de décision rapide et éclairée, tout en optimisant la gestion des ressources hospitalières.

5.6.2 Collecte de données

Une procédure stockée SQL nommée « [Urgence_DMS]. [USPGetListPatientUrgencestoPredictDMS] » est exécutée toutes les 15 minutes pour capturer un instantané des données actuelles de l'urgence. Cet instantané stocke les données dans une table appelée « TbListPatientsTopredict » comprenant des variables similaires à celles utilisées lors de l'entraînement des modèles prédictifs, garantissant ainsi une cohérence entre les données d'entraînement et celles utilisées pour les prédictions en temps réel. Cette approche permet de fournir des estimations fiables et actualisées de la durée de séjour des patients, en s'adaptant dynamiquement à l'évolution des conditions à l'urgence.

5.6.3 Exécution et prédiction

Un script Python, nommé « PredictionDMSPatientsUrgence », est exécuté automatiquement par SQL Server pour interroger la table « TbListPatientsToPredict », qui contient les données des urgences. Ce script utilise le modèle prédictif sauvegardé dans le fichier « BestModelPatientUrgence_model.pkl » pour estimer la durée de séjour des patients. Les résultats, incluant le numéro de dossier du patient, la durée de séjour prédite, et l'heure de la prédiction, sont ensuite enregistrés dans une table SQL appelée « PredictionsPatientsDMS ».


Un deuxième script Python appelé « Prediction_ServiceAdmission_PatientUrgence » est également exécuté automatiquement par SQL Server pour appliquer le modèle « FAPatientUrgence_SA_model.pkl » à la même table « TbListPatientsToPredict ». Ce processus génère des probabilités d'hospitalisation pour chaque service, qui sont enregistrées dans la table SQL « TbPredictionResults_Patient_S_Admission ». Cette table contient l'identifiant unique du patient (DossierId) : l'Identifiant du service hospitalier prédit (ServiceAdmission), la probabilité d'admission dans le service (Admission_Probability) et la date de la prédiction effectuée (PredictionDate).

Ce système de prédiction en temps réel, centralisé dans des tables dédiées, joue un rôle clé dans la gestion proactive des flux de patients. En fournissant immédiatement des informations stratégiques, il facilite la prise de décision pour l'allocation optimale des ressources médicales et améliore la fluidité des processus opérationnels dans l'environnement hospitalier.

5.6.4 Visualisation des données

Les données prédictives sont intégrées dans un rapport Power BI, déployé sur l'infrastructure de l'hôpital de la cité-de-la-santé de Laval. Ce tableau de bord, intitulé « Tableau de bord prédictif des patients à l'urgence », est mis à jour automatiquement toutes les 15 minutes pour garantir une visualisation en temps réel. Il affiche la durée de séjour prédite des patients sur civière, la probabilité d'admission d'un patient dans un service hospitalier, ainsi que des projections sur le nombre de patients susceptibles d'être admis. Ce tableau offre une vue complète et claire de l'état des urgences, permettant au personnel hospitalier de surveiller la charge de travail, d'identifier rapidement les situations critiques, et d'optimiser la gestion des ressources pour une prise de décision éclairée (Figure 5.7).

Figure 5.8 Tableau de bord prédictive



5.7 Architecture de la solution

L'architecture de la solution du modèle prédictif de la durée de séjour des patients, structuré autour d'un entrepôt de données et d'un serveur d'application. Les données proviennent de plusieurs sources (urgence, hospitalisation et imagerie) et sont intégrées via un processus ETL dans une base SQL centralisée (InfocentreDB). L'Infocentre est organisé en plusieurs niveaux : réception, normalisation et présentation des données. Une section dédiée à la science des données contient les jeux de données d'entraînement

et de prédiction. Le serveur d'application, basé sur Python, exécute les scripts d'entraînement et de prédiction, permettant d'estimer la durée de séjour, la probabilité d'admission. Les résultats sont ensuite intégrés dans une application infonuagique du l'hôpital de la cité-de-la-santé de Laval, alimentant des tableaux de bord descriptifs et prédictifs pour optimiser la gestion des urgences (Annexe I).

5.8 Conclusion

Ce chapitre a présenté les étapes de conception, d'évaluation et de comparaison de divers modèles prédictifs pour estimer la durée de séjour des patients sur civière à l'urgence. Des approches variées ont été explorées, incluant la régression linéaire et logistique, le KNN, ainsi que des modèles basés sur les arbres tels que l'arbre de décision, le gradient boosting et la forêt aléatoire. L'objectif était de sélectionner la solution la plus performante et adaptée aux besoins prédictifs.

Parmi ces modèles, la forêt aléatoire s'est imposée comme la solution optimale, grâce à son équilibre entre robustesse, performance et simplicité d'interprétation. Avec un R^2 de 0,77 et une MAE de 3,78 heures, elle s'est révélée presque aussi performante que le gradient boosting ($R^2 = 0,78$) tout en offrant une meilleure stabilité et une plus grande clarté dans l'identification des variables clés.

Le délai d'attente pour l'admission et les consultations spécialisées, ont été mis en lumière comme des facteurs prédominants influençant la durée de séjour.

En conclusion, cette analyse confirme la pertinence de la forêt aléatoire comme outil prédictif pour optimiser la gestion des flux de patients et des ressources dans un environnement hospitalier. Elle constitue une base solide pour des décisions éclairées et une meilleure allocation des ressources médicales. Le prochain chapitre est entièrement consacré à l'analyse critique des résultats.

CHAPITRE 6

ANALYSE CRITIQUE DE RÉSULTATS

Ce chapitre a pour objectif d'interpréter les résultats obtenus à travers une analyse approfondie et structurée. La section 6.1 examine la distribution des erreurs de prédiction. La section 6.2 analyse les corrélations entre les variables, tandis que la section 6.3 identifie celles qui exercent la plus grande influence sur les modèles prédictifs. La section 6.4 présente les résultats relatifs à la probabilité d'admission en service, et la section 6.5 évalue la performance globale du modèle. La section 6.6 discute des limites de l'analyse prédictive, suivie par la section 6.7, qui explore ses implications pratiques. Enfin, la section 6.8 propose une conclusion synthétique des principaux enseignements tirés de cette analyse.

6.1 Analyse de la distribution des erreurs de prédiction

Nous constatons que la moyenne des valeurs réelles est de 15,29 heures, qui reflètent la durée moyenne observée des séjours des patients sur une période de trois ans (2021-2022-2023). En comparaison, la moyenne des valeurs prédites de 15,32 heures met en évidence une concordance presque parfaite entre les prédictions du modèle et les données réelles. L'erreur moyenne de prédiction, calculée comme la différence absolue moyenne entre les valeurs réelles et prédites, est de 0,03 heure, soit seulement 1,96 % de la moyenne réelle. Avec une MAE (moyenne absolue des erreurs) de 3,78 heures et un R^2 (coefficient de détermination) de 0,77, le modèle démontre à la fois une précision élevée et une capacité à expliquer 77 % de la variance des données, confirmant ainsi sa fiabilité et sa pertinence pour cette tâche prédictive.

6.1.1 Analyse des erreurs brutes


Dans notre modèle de forêt aléatoire, ajusté lors des étapes précédentes, 61 175 enregistrements ont été utilisés pour l'entraînement et 15 294 pour les tests, permettant d'évaluer sa capacité de généralisation. Le graphique de la distribution des erreurs (Figure 6.1) sous forme d'histogramme illustre les écarts entre les prédictions et les observations réelles, offrant une évaluation de la précision du modèle et des éventuelles tendances de sous ajustement ou de surajustement.

Les erreurs brutes, calculées comme *Erreur brute* = $Y_{réelle} - Y_{prédite}$, présentent les caractéristiques suivantes :

- Distribution centrée : Les erreurs sont majoritairement entre 0 et 5, suggérant l'absence de biais systématique significatif et un équilibre global entre les prédictions et les valeurs réelles.
- Dispersion des erreurs : La majorité des erreurs se situent entre -10 et 10, indiquant une bonne performance globale. Quelques valeurs aberrantes (au-delà de ± 20) révèlent des difficultés spécifiques.
- Asymétrie et queues : Une queue droite légèrement plus longue indique une sous-estimation ponctuelle de certaines valeurs.

Cette distribution étroite et centrée confirme la précision générale du modèle, bien que l'analyse des erreurs extrêmes puisse permettre des ajustements pour renforcer sa fiabilité entre les valeurs réelles ($Y_{réelle}$) et les valeurs prédites ($Y_{prédite}$) par le modèle de forêt aléatoire.

Figure 6.1 Distribution des erreurs brutes



6.1.2 Analyse des erreurs absolues


La distribution des erreurs absolues, définies comme les valeurs absolues des différences entre les prédictions et les valeurs réelles : ($|Erreur| = |Y_{réelle} - Y_{prédite}|$) révèle les points suivants :

- Concentration des erreurs faibles : La majorité des erreurs absolues se situe entre 0 et 5 heures, avec un pic autour de 0, indiquant une précision globale élevée du modèle.
- Distribution asymétrique : Une queue droite plus longue (>20) révèle des erreurs importantes, bien que rares, illustrant des cas où le modèle est moins performant.
- Longue queue droite : Certaines erreurs atteignent jusqu'à 100, signalant des valeurs aberrantes ou des cas particuliers de forte divergence entre les prédictions et les valeurs réelles.
- Performance globale : Le modèle est performant pour la majorité des cas, avec une prédominance d'erreurs faibles.
- Cas à investiguer : Les erreurs supérieures à 20 nécessitent une analyse approfondie, pouvant révéler :

- Des données aberrantes ou imprécises.
- Une complexité insuffisante du modèle ou des variables explicatives manquantes.

Malgré ces rares exceptions, le modèle de forêt aléatoire capture efficacement les relations dans les données (Figure 6-2). L'analyse des cas atypiques pourrait encore améliorer ses performances.

Figure 6.2 Distribution des erreurs absolues




6.1.3 Impact de la profondeur maximale des arbres de décision sur l'erreur absolue moyenne (MAE)

Nous avons analysé l'influence de la profondeur maximale des arbres de décision sur l'erreur absolue moyenne (MAE) dans une forêt aléatoire (Figure 6-3), en fonction de différents nombres d'estimateurs :

- **Tendance générale :** La MAE diminue avec l'augmentation de la profondeur maximale, reflétant une meilleure capture des relations complexes. Au-delà d'une profondeur de 15 à 20, la MAE se stabilise, indiquant une saturation des gains de précision et un risque accru de surajustement pour des arbres plus profonds.
- **Impact du nombre d'estimateurs :** Les courbes MAE pour différents nombres d'estimateurs indiquent des tendances similaires. L'augmentation du nombre d'estimateurs améliore surtout la stabilité des prédictions en réduisant leur variabilité, sans affecter significativement la MAE.
- **L'analyse souligne que de limiter la profondeur maximale à 15-20 optimise la précision sans surajustement, tandis qu'un nombre suffisant d'estimateurs renforce la robustesse du modèle. Ces paramètres équilibrent performance et efficacité computationnelle.**


Figure 6.3 Impact de la profondeur maximale des arbres de décision sur l'erreur absolue moyenne



6.1.4 Analyse des erreurs résiduelles

L'erreur résiduelle, définie par $\text{Erreur résiduelle} = Y \text{ réelle} - Y \text{ prédite}$ à une moyenne de -0,02, indiquant une légère sous-estimation des valeurs réelles par le modèle. Cette faible moyenne traduit un bon calibrage global. Toutefois, l'erreur absolue moyenne révèle des écarts notables, signalant des prédictions moins précises dans certains cas. La corrélation entre les valeurs prédites et réelles reste solide. Sur le graphique, la ligne rouge, représentant une prédiction parfaite ($Y \text{ réelle} = Y \text{ prédite}$), montre que les points proches indiquent des prédictions précises, tandis que ceux éloignés reflètent des écarts importants.

Figure 6.4 Valeurs prédite par rapport aux valeurs réelles



Le modèle de forêt Aléatoire performe bien pour les valeurs réelles de 0 à 100 heures (Figure 6-4), avec des prédictions précises concentrées autour de la ligne rouge. Au-delà de 100 heures, les prédictions se

dispersent, indiquant une baisse de précision pour les cas extrêmes. Cela met en évidence une bonne performance globale, avec des marges d'amélioration pour ces valeurs aberrantes.

6.2 Analyse des corrélations entre les variables

Les variables les plus corrélées avec la durée de séjour mettent en évidence l'importance des délais et des caractéristiques des patients. Les corrélations les plus élevées incluent le délai d'attente d'admission (0,73) et le délai d'attente de consultation spécialisée (0,49), soulignant que des attentes prolongées influencent directement la durée totale des séjours. Les moyennes des délais d'attente pour les consultations spécialisées des dernières 8 et 12 heures montrent également un impact modéré (0,40 et 0,38), reflétant l'effet cumulatif des retards. Des facteurs moins corrélés, mais significatifs incluent le service d'admission (ServiceAdmissionId) (0,26), l'âge (0,19) et des variables historiques comme les moyennes des durées d'hospitalisation passées sur 5 ans et 36 mois (0,14 et 0,12). Enfin, l'activité récente et les retards d'admission sur les dernières heures montrent des corrélations faibles (0,12 et 0,37), mais restent intéressants pour comprendre l'influence des processus hospitaliers. Les variables les plus influentes, liées au temps d'attente, suggèrent que l'optimisation des processus avant et pendant l'admission pourrait significativement réduire la durée totale des séjours. Les corrélations plus faibles révèlent des facteurs secondaires qui, bien que moins directs, peuvent jouer un rôle dans des contextes spécifiques ou combinés.

Tableau 6.1 Les dix principales corrélations avec la durée de séjour

Variables	Corrélation
DelaiAttenteAdmissionPatient	0,728 714
DelaiAttenteConsulSpec	0.489646
AvgDelaiAttentConsulSpecLast8Hours	0,398 453
AvgDelaiAttentConsulSpecLast12Hours	0.380800
AvgDelaiAttenteAdmissionLast8Hours	0,379 343
AvgDelaiAttenteAdmissionLast12Hours	0,370 212
ServiceAdmissionId	0,256 845
AgeEffectif	0,191 590
MoyenneDureHospitDayLast5ans	0,140 078
MoyenneDureHospitDayLast36Mois	0,125 434
NbrPatientDerniere8Heures	0,124 691
NbrHospitalisationLast5ans	0,117 216
NbrPatientDerniere12Heures	0.109872
NbrHospitalisationLast36Month	0,108 983

6.3 Identification des variables importantes

L'analyse des variables importantes dans le modèle de forêt Aléatoire révèle les facteurs influençant le plus la prédiction de la durée de séjour des patients sur civière à l'urgence (Figure 6.5):

- **Variables principales :**
 - Délai d'attente d'admission (52,35 %) : Facteur clé, son optimisation pourrait réduire significativement les temps de séjour.
 - Délai d'attente de consultation d'un spécialiste (20,89 %) : Contributeur majeur, des consultations plus rapides amélioreraient l'efficacité globale.
 - Délai d'attente des examens d'imagerie (2,23 %) : Impact moindre, mais notable, nécessitant une gestion prioritaire des examens.
 - Heure d'arrivée (2,23 %) : Influence modeste, liée aux variations de disponibilité des ressources.
- **Variables à impact modéré :**
 - Âge (1,66 %) : Facteur indirect influençant d'autres variables.
 - Délais moyens d'attente spécialisés (dernières 8 et 12 heures) : Indicateurs des tendances récentes influençant la durée du séjour.
- **Variables secondaires :**
 - NbrPatientDerniere12Heures : Impact faible, reflétant la charge de travail.
 - Pouls : Paramètre clinique simple, mais significatif.

Les délais d'attente dominent l'explication de la durée de séjour, tandis que les variables cliniques et démographiques jouent un rôle secondaire. Une optimisation ciblée des processus clés pourrait améliorer significativement l'efficacité du parcours patient (Figure 6.6).

Figure 6.5 Poids des caractéristiques dans la prédiction


```
Meilleurs paramètres :
{'max_depth': 20, 'n_estimators': 200}

Résultats sur l'ensemble de validation :
MAE : 3.78
R² : 0.77

Importance des caractéristiques :
```

	Feature	Importance
11	DelaiAttenteAdmissionPatient	0.523539
16	DelaiAttenteConsulSpec	0.208992
19	DelaiAttenteImag	0.023907
7	HeureArrivee	0.023829
18	AvgDelaiAttentConsulSpecLast12Hours	0.014190
1	AgeEffectif	0.013744
17	AvgDelaiAttentConsulSpecLast8Hours	0.012117
10	NbrPatientDerniere12Heures	0.009693
0	DossierId	0.009394
39	Pouls	0.008001

Figure 6.6 top 10 Variables les Plus importantes



6.4 Analyse des résultats pour la probabilité d'admission en service


Nous avons évalué la performance du modèle dans la prédiction des services d'admission des patients. Cette analyse repose sur l'utilisation de la matrice de confusion, permettant d'examiner la précision, le rappel et les éventuelles erreurs de classification. Les résultats offrent une perspective sur la capacité du modèle à prédire efficacement les services d'admission.

6.4.1 Analyse des résultats de la matrice de confusion

L'analyse de la matrice de confusion (Figure 6-7), appliquée à la prédiction des services d'admission, illustre la capacité du modèle à classer correctement les patients dans les différentes catégories. Ces catégories correspondent aux services hospitaliers codés numériquement dans la base de données (par exemple : 2, 4, 18, 80, etc.), chaque code représentant un service spécifique d'admission. Les valeurs élevées observées sur la diagonale principale (884, 671, 664 et 402 pour les services 2, 4, 18 et 80 respectivement) traduisent la justesse des prédictions effectuées par le modèle et confirment sa performance pour plusieurs services majeurs. En revanche, certaines confusions apparaissent en dehors de la diagonale, notamment pour les services 5, 6, 7, 8 et 9, ce qui indique des chevauchements dans les caractéristiques explicatives ou une représentation insuffisante de certaines classes. Ces erreurs récurrentes suggèrent la nécessité d'une investigation plus approfondie, qui pourrait s'appuyer sur l'ajout de variables discriminantes ou sur un rééquilibrage des données afin d'améliorer la différenciation entre services voisins. Ainsi, bien que le modèle de forêt aléatoire démontre une robustesse notable et une

bonne capacité de généralisation, des marges d'amélioration subsistent pour affiner la précision des prédictions, en particulier dans les services où la confusion est plus fréquente.

Figure 6.7 Matrice de confusion pour l'évaluation de la probabilité d'admission



6.4.2 Évaluation de la précision des résultats

Les résultats de performance du modèle (Figure 6-7) pour chaque service d'admission mettent en évidence une précision globale élevée (0,97), indiquant que la majorité des prédictions sont correctes. Cependant, la macro moyenne (0,82) est inférieure en raison de la pondération égale des classes, ce qui reflète des performances moins élevées pour certaines classes peu représentées. Les services 4, 26, 86 et 90 affichent une précision parfaite (1,00), probablement grâce à un nombre élevé d'exemples, tandis que les classes 7, 8 et 9 montrent des précisions modérées (0,76 à 0,85) en raison d'un faible support. Le F1-score moyen pondéré est également élevé (0,96), traduisant un bon équilibre entre précision et rappel. Les classes avec un support élevé, comme la classe 0 (9008 instances), influencent fortement les moyennes, tandis que celles avec un support faible, comme 17 ou 32, obtiennent des scores plus faibles. Ces résultats

montrent que le modèle excelle pour les classes majoritaires, mais rencontre des limites pour les classes rares. Pour améliorer les performances, des techniques comme le rééquilibrage des classes (suréchantillonnage ou sous-échantillonnage) et l’affinage du modèle pourraient être explorées.


Figure 6.8 Résultats de précision de la probabilité d’admission en service

	precision	recall	f1-score	support
0	1.00	1.00	1.00	9008
2	0.97	1.00	0.98	884
4	1.00	0.85	0.92	13
5	0.98	0.93	0.95	721
6	0.90	0.82	0.86	380
7	0.84	0.74	0.79	401
8	0.85	0.64	0.73	285
9	0.76	0.89	0.82	231
11	0.91	0.91	0.91	597
18	0.88	0.88	0.88	17
20	0.91	0.59	0.71	17
24	0.88	0.96	0.92	695
26	1.00	0.14	0.25	14
32	0.00	0.00	0.00	2
34	0.89	0.94	0.91	258
36	0.92	0.77	0.84	154
38	0.87	0.93	0.90	168
50	0.00	0.00	0.00	4
60	0.99	0.85	0.91	126
62	0.00	0.00	0.00	3
80	0.95	0.98	0.97	64
83	1.00	0.20	0.33	25
85	0.95	1.00	0.97	3079
86	1.00	0.20	0.33	15
89	1.00	0.56	0.72	34
90	0.99	1.00	0.99	433
accuracy			0.97	17628
macro avg	0.82	0.68	0.72	17628
weighted avg	0.97	0.97	0.96	17628

6.4.3 Analyse de la probabilité moyenne d’admission par service

L’analyse de la probabilité moyenne d’admission (Figure 6-8) montre que les services 2, 4 et 18 se distinguent avec des probabilités moyennes significatives, bien que modestes, suggérant leur rôle central dans le processus d’admission. La majorité des autres services affichent des probabilités proches de 0 à 0,1, reflétant une implication plus spécifique et moins fréquente. La concentration des probabilités sur les services 2, 4 et 18 révèle une distribution asymétrique et déséquilibrée des admissions. Ces services, en tant qu’acteurs clés, méritent une analyse approfondie pour comprendre leur prédominance et explorer des optimisations visant à mieux répartir les charges et améliorer la gestion des ressources hospitalières.

Figure 6.9 Probabilité moyenne d'admission par service



6.5 Performance du modèle

Les résultats montrent que le modèle de forêt aléatoire capture efficacement les tendances globales, mais éprouve des difficultés à gérer les cas extrêmes. Ces derniers sont souvent influencés par des facteurs non inclus dans les données, tels que les horaires des cadres médicaux et non médicaux (médecins, infirmiers), les délais administratifs, ainsi que des éléments externes comme les conditions météorologiques. La distribution asymétrique des erreurs absolues met en évidence la nécessité d'un traitement spécifique pour les séjours atypiques.

6.6 Limite de l'analyse prédictive

Malgré les performances globalement satisfaisantes du modèle de forêt aléatoire, plusieurs limitations doivent être soulignées. Premièrement, le modèle présente des difficultés à prédire avec précision les cas extrêmes, où les durées de séjour s'écartent fortement de la moyenne, en raison de facteurs non inclus dans les données, tels que les variations des horaires du personnel, les retards administratifs ou des événements externes imprévus. Deuxièmement, certaines variables cliniques et contextuelles susceptibles d'influencer la durée de séjour, comme la gravité exacte des cas, la disponibilité spécifique des ressources spécialisées ou les interactions entre services, n'ont pas été intégrées, ce qui peut réduire la capacité explicative du modèle pour certaines situations. Troisièmement, le déséquilibre des classes pour la prédiction des services d'admission limite la précision pour les services peu représentés, malgré l'excellente performance pour les classes majoritaires. Enfin, l'analyse repose sur des données historiques

sur trois ans, ce qui implique que toute modification structurelle, organisationnelle ou saisonnière dans les flux hospitaliers pourrait affecter la pertinence des prédictions futures. Ces limitations suggèrent que le modèle doit être utilisé comme un outil d'aide à la décision plutôt que comme un instrument de prédiction absolue, et qu'une actualisation régulière des données et un enrichissement des variables explicatives sont nécessaires pour améliorer sa robustesse et sa fiabilité.

6.7 Implications pratiques de l'analyse prédictive

L'analyse prédictive des délais et de la durée de séjour en urgence présente des implications pratiques majeures pour la gestion hospitalière. En identifiant précocement les patients à risque de séjour prolongé sur civière, il devient possible d'anticiper les besoins en lits, de mobiliser plus rapidement les ressources humaines et d'optimiser la planification des admissions. De plus, la prédiction des goulets d'étranglement – tels que l'attente pour une consultation spécialisée ou l'obtention d'un lit d'hospitalisation – offre aux gestionnaires une base décisionnelle solide pour ajuster les processus en temps réel. Ces outils prédictifs permettent aussi de soutenir la priorisation clinique, en orientant les patients vers des parcours de soins plus adaptés et en réduisant la congestion dans les zones critiques. Enfin, leur intégration dans les systèmes d'information hospitaliers peut contribuer à améliorer la qualité des soins, à renforcer la satisfaction des patients et à optimiser l'utilisation des ressources, ce qui constitue un levier stratégique dans un contexte de pressions croissantes sur les urgences.

6.8 Conclusion

Le modèle de forêt aléatoire se révèle performant dans l'ensemble, bien que perfectible pour les cas extrêmes. L'analyse ANOVA met en évidence l'impact significatif de certaines spécialités, notamment la psychiatrie, sur la prolongation des séjours sur civière. Les principaux goulots d'étranglement identifiés concernent les délais d'attente (admission, consultation, imagerie), tandis que des facteurs secondaires, tels que l'âge et l'heure d'arrivée, exercent une influence marginale. Ces résultats ouvrent des perspectives d'optimisation des flux hospitaliers et des processus de gestion. Le prochain chapitre conclut ce travail de recherche en synthétisant les principales contributions et implications.

CONCLUSION

Ce chapitre conclut notre projet de recherche, dont l'objectif était de développer un modèle performant pour prédire la durée de séjour des patients sur civière lors de leur passage à l'urgence. Après son élaboration, ce projet a été reconnu comme une initiative innovante par Santé Québec, témoignant de son apport significatif à la gestion hospitalière. Cette reconnaissance valide non seulement la pertinence de notre démarche, mais aussi son potentiel d'application à l'échelle provinciale. Cette conclusion met en perspective les différentes contributions de notre travail. D'abord, la section 8.1 présente les contributions et impacts de notre recherche, en mettant en avant les avancées qu'elle apporte à la gestion des flux hospitaliers. La section 8.2 résume les résultats obtenus avec la forêt aléatoire, en soulignant ses performances en termes de précision et de robustesse. La section 8.3 explore les perspectives et recommandations pour de futures recherches, en proposant des améliorations possibles du modèle. La section 8.4 expose les limites de notre étude, notamment les contraintes liées aux données et aux infrastructures techniques. La section 8.5 examine les pistes de travaux futurs, afin d'élargir l'application du modèle et d'en renforcer l'efficacité. Enfin, la section 8.6 propose une conclusion synthétique, mettant en lumière les implications pratiques et les bénéfices potentiels de cette approche pour la gestion des urgences hospitalières.

Contributions et impacts de notre recherche

Apport du tableau de bord descriptif : Ce tableau de bord fournit aux gestionnaires une vision claire et structurée des flux de patients à l'urgence, en mettant en évidence les tendances, les périodes d'affluence et les facteurs influençant la durée de séjour. Il facilite la prise de décision en temps réel en permettant d'anticiper les surcharges, d'optimiser la répartition des ressources et d'adapter les effectifs en fonction des besoins. De plus, il favorise une meilleure coordination entre les différentes équipes hospitalières, réduisant ainsi les délais d'attente et améliorant la qualité de prise en charge des patients.

Contribution du contrôle des chevauchements à l'amélioration de la gestion de l'urgence : Ce mécanisme permet aux gestionnaires et aux utilisateurs du système hospitalier de détecter et de corriger les incohérences dans les données du système « *Medurge* » à l'urgence. Il garantit qu'un épisode est correctement clôturé dès qu'un patient quitte l'urgence, évitant ainsi les erreurs administratives pouvant conduire à une occupation simultanée de deux lits, l'un à l'urgence et l'autre en hospitalisation. En

assurant une mise à jour rigoureuse des statuts des patients, ce contrôle renforce la fiabilité des données, améliore la fluidité des admissions et optimise l'utilisation des ressources hospitalières. De plus, il réduit les risques de saturation artificielle des lits, facilitant ainsi la planification des admissions et une meilleure répartition des effectifs médicaux.

Apport du modèle prédictif sur la gestion des séjours des patients sur civière : Ce modèle améliore la gestion hospitalière en anticipant avec précision la durée de séjour des patients sur civière. En offrant une prévision plus fiable des flux de patients, il permet aux gestionnaires d'adapter de manière proactive les ressources humaines et matérielles, d'optimiser la gestion des lits et d'anticiper les périodes de forte affluence. Il contribue également à une meilleure planification des admissions, réduisant ainsi les délais d'attente en améliorant la qualité de la prise en charge. En identifiant les patients à risque de séjours prolongés, il aide à prioriser les interventions médicales et à assurer la fluidité du parcours de soins, minimisant ainsi la surcharge des urgences et renforçant l'efficacité globale du système hospitalier.

Approche innovante pour améliorer la gestion des flux à l'urgence : L'acceptation de ce projet en tant que projet d'innovation par l'Agence Santé Québec valide sa pertinence et son impact potentiel. Sachant que Santé Québec est l'agence principale responsable du système de santé au Québec, cette reconnaissance souligne l'importance de notre démarche et son apport concret à l'amélioration des soins. Le projet se distingue par l'intégration d'analyses prédictives avancées, inédites au l'hôpital de la cité-de-la-santé de Laval et à l'échelle provinciale, permettant d'anticiper la durée de séjour des patients sur civière et d'améliorer la fluidité des parcours de soins en urgence.

Cette reconnaissance confirme la valeur de notre approche pour optimiser la gestion des séjours en urgence. Elle permet aux gestionnaires une planification plus efficace des ressources hospitalières, une réduction des délais d'attente pour les consultations spécialisées, l'admission et les examens d'imagerie, ainsi qu'une amélioration de l'assignation des lits pour l'hospitalisation.

Concrètement, cela se traduit par une diminution du temps passé sur civière, une meilleure répartition des équipes médicales en fonction des flux de patients et une réduction des engorgements aux urgences. Les modèles prédictifs permettent également d'anticiper les besoins en personnel et en équipements, d'ajuster en temps réel l'affectation des ressources, et d'optimiser l'occupation des unités d'hospitalisation en fonction des prévisions de départ et d'admission.

En facilitant l'identification des patients à risque de séjour prolongé, ce projet contribue aussi à prioriser les interventions et à adapter les protocoles de prise en charge pour éviter des complications inutiles. L'intégration de ces modèles dans la gestion hospitalière permet aussi d'améliorer la satisfaction des patients et du personnel en réduisant les périodes d'attente et en assurant une prise en charge plus fluide et plus efficace.

Ce modèle sera utilisé comme projet pilote à l'échelle du l'hôpital de la cité-de-la-santé de Laval, puis déployé à l'échelle provinciale pour améliorer l'efficacité des services d'urgence et optimiser la gestion hospitalière dans l'ensemble du réseau de santé au Québec. Il propose une approche basée sur les données, pouvant être appliquée à d'autres secteurs de la santé, notamment la planification des chirurgies, la gestion des lits en soins intensifs et la prévision des flux de patients en période de forte affluence.

Synthèse des résultats obtenus : Le modèle de forêt aléatoire a démontré une efficacité notable en fournissant une erreur absolue moyenne (MAE) de 3,78 heures et une erreur quadratique moyenne (RMSE) de 5,87 heures, ce qui atteste de sa capacité à réduire les écarts importants dans les prédictions. De plus, avec un seuil de ± 3 heures pour considérer une prédiction comme correcte, il a atteint un taux de réussite de 78,86 %, surpassant les autres modèles testés.

Le modèle a également affiché un coefficient de corrélation de 0,78, indiquant une forte correspondance entre les valeurs prédites et observées. Ces résultats placent la forêt aléatoire comme une approche privilégiée pour les analyses nécessitant précision, robustesse et adaptabilité. Des améliorations restent envisageables via un ajustement plus poussé des hyperparamètres ou l'intégration de nouvelles dimensions de donnée.

Perspectives et recommandations

Perspectives de recherche : Afin de guider la mise en œuvre des actions proposées, les recommandations ont été classées en fonction de leur priorité (impact et urgence) et de leur faisabilité (ressources, contraintes techniques et organisationnelles).

Impact direct et la mise en œuvre possible avec des ressources organisationnelles et techniques disponibles à court terme :

- Optimisation des processus d'admission et de consultation spécialisée entre 7 h et 16 h.
- Réévaluation des besoins en ressources dédiées aux consultations spécialisées (7 h à 16 h)

Actions à fort impact, mais nécessitant du développement technique ou une infrastructure plus robuste :

- Développement d'un modèle prédictif multiorientations : capable d'anticiper non seulement la durée de séjour sur civière, mais aussi : admission hospitalière, réorientation, départ sans prise en charge, décès.
- Améliore la planification des soins et la gestion des flux.
- Requiers une collecte et une préparation de données plus complète.

Actions pertinentes, mais nécessitant un investissement technologique important avant d'être réalisables pleinement.

- Exploration de modèles plus avancés (réseaux de neurones) combinés à une infrastructure de calcul plus puissante.
- Développement d'un modèle d'optimisation des décisions d'admission et de l'accès à une consultation spécialisée

Recommandations stratégiques : La coexistence de plusieurs systèmes d'information hospitaliers, tels que *MedUrg*, *RadImag*, *Clinibase-CI* et *Opera*, génère des délais, des incohérences et une charge administrative accrue, limitant l'efficacité des soins. L'intégration d'un ERP hospitalier unifiant sur ces plateformes permettrait une saisie unique des données, une réduction des erreurs, une meilleure visibilité sur les parcours des patients et une coordination optimisée des services. Cette approche renforcerait la prise de décision et améliorerait la fluidité des soins, contribuant ainsi à réduire la durée des séjours aux urgences.

Contraintes et limites de l'étude : La présente recherche, bien qu'elle ait permis d'obtenir des résultats pertinents et prometteurs, comporte plusieurs limites qu'il convient de souligner afin d'en situer la portée et de proposer des pistes d'amélioration pour de futurs travaux.

Données manquantes : L'absence de certaines variables prédictives clés, telles que les horaires en temps réel des médecins et des infirmières, a limité la précision des prédictions. Ce déficit d'information a restreint la capacité du modèle à capter des variations liées à la disponibilité des ressources humaines, ce qui est pourtant un facteur déterminant dans la durée de séjour. Par conséquent, certaines fluctuations observées pourraient être attribuées à ces variables absentes, réduisant la robustesse des estimations, notamment dans des situations cliniques ou organisationnelles complexes.

Données imparfaites : La pandémie de COVID-19 a profondément perturbé le fonctionnement hospitalier, modifiant les flux de patients, les priorités médicales et les protocoles de soins. Ces bouleversements ont introduit des anomalies dans les données, telles que des délais atypiques ou des changements de priorisation, susceptibles d'influencer négativement la précision des modèles prédictifs. Bien que des traitements préalables aient été appliqués, certaines distorsions contextuelles subsistent, limitant la comparabilité avec des périodes plus stables.

Contraintes techniques : L'utilisation de modèles avancés, comme les réseaux de neurones, exige des infrastructures de calcul performantes, incluant des serveurs à haute capacité et des ressources spécialisées pour l'optimisation des hyperparamètres. L'absence de telles ressources a conduit à privilégier des algorithmes plus accessibles, tels que la forêt aléatoire, performants sur un large éventail de cas, mais moins adaptés à des scénarios atypiques ou fortement non linéaires. Cette contrainte technique a donc limité l'exploration de solutions potentiellement plus précises.

Contexte unique : Les données utilisées proviennent d'un seul établissement hospitalier. Ce choix, bien que pertinent pour assurer la cohérence des données et la maîtrise des paramètres contextuels, réduit la capacité à généraliser les résultats à d'autres milieux. Les différences d'organisation, de ressources, de protocoles cliniques et de profils de patients entre établissements pourraient modifier substantiellement les performances des modèles. Une extension à un échantillon multiétablissements permettrait de renforcer la robustesse et la transférabilité des conclusions.

Gestion des cas extrêmes : Les modèles testés rencontrent des difficultés à prédire avec précision les séjours exceptionnellement longs ou courts, souvent influencés par des facteurs rares (ex. complications inattendues, conditions socioéconomiques particulières, retards logistiques imprévus). Cette limite met

en évidence l'intérêt de recourir à des approches plus sophistiquées, telles que des réseaux de neurones profonds ou des méthodes hybrides combinant apprentissage statistique et règles expertes.

Limites dans le développement du modèle : Le temps requis pour collecter, nettoyer et préparer les données, ainsi que pour intégrer des variables supplémentaires, a constitué un frein important au développement. Cette contrainte a empêché la conception d'un modèle prescriptif, pourtant porteur d'un fort potentiel pour optimiser la gestion hospitalière. De plus, l'ampleur et la complexité des données à traiter ont considérablement ralenti le processus. Une approche itérative aurait permis de livrer des versions préliminaires exploitables rapidement, puis de les améliorer progressivement, garantissant ainsi des résultats tangibles à court terme tout en poursuivant l'optimisation.

En résumé, ces limitations soulignent l'importance d'un accès élargi aux données, d'une collaboration interétablissements, d'un renforcement des capacités techniques et d'une planification agile du développement des modèles. Leur prise en compte dans les travaux futurs serait essentielle pour améliorer la précision, la robustesse et la portée des outils prédictifs destinés à la gestion hospitalière.

Futurs travaux de recherche

Accès à des données élargies pour améliorer les variables prédictives : Il serait essentiel d'envisager un accès aux données horaires en temps réel des médecins et des infirmières pour mieux intégrer l'impact de l'organisation des ressources humaines sur les flux de patients. De plus, l'intégration des analyses de laboratoire en tant que nouvelles variables prédictives pourrait permettre d'exploiter des milliards de données cliniques, offrant ainsi une vision plus fine de l'état de santé des patients et une amélioration significative des prédictions sur leur orientation.

Prédiction des temps d'attente selon la consultation spécialisée et service demandé : Un autre axe d'amélioration consiste à prédire avec précision les temps d'attente pour chaque consultation spécialisée, en tenant compte des spécificités des services sollicités. Cela permettrait d'optimiser la gestion des consultations spécialisées, réduisant ainsi les délais d'attente des patients.

Prédiction des différentes orientations des patients : Enfin, un axe prioritaire serait de prédire les différentes orientations des patients lors des épisodes d'urgence, notamment : la réorientation vers un

autre service, le transfert vers un autre établissement. Ces prédictions permettraient d'anticiper les besoins logistiques et cliniques, et d'améliorer globalement la gestion des urgences.

Prédiction du volume de patients attendus à l'urgence : La prédiction à l'avance du nombre de patients qui seront inscrits à l'urgence pour des périodes trimestrielles offrirait aux gestionnaires un outil précieux pour mieux planifier les ressources et anticiper les besoins. En se basant sur des paramètres tels que la répartition géographique, les données démographiques, le taux de croissance de la population et le pourcentage de personnes âgées dans la région de Laval, cette approche permettrait de modéliser avec précision les flux de patients attendus aux urgences. Ces prévisions pourraient également intégrer des facteurs saisonniers, des tendances épidémiologiques et des conditions climatiques, comme l'impact d'une tempête de neige ou de verglas, fournissant ainsi un cadre d'analyse global et proactif pour la gestion hospitalière.

Toutes les optimisations proposées constituent des fondations solides pour évoluer vers une approche plus opérationnelle à travers l'utilisation d'un modèle prescriptif. Contrairement aux modèles descriptifs et prédictifs, le modèle prescriptif vise à fournir des recommandations optimales et des actions concrètes pour améliorer la gestion des flux de patients et des ressources.

Optimisation des processus à l'aide d'un modèle prescriptif : En intégrant les données élargies (horaires des professionnels de santé, analyses de laboratoire), le modèle prescriptif pourrait identifier les meilleures actions à prendre pour :

- Réduire les délais critiques (admissions, consultations spécialisées).
- Garantir une meilleure allocation des ressources.
- Permettre une prise en charge proactive des patients, notamment pour les cas de réorientation, départs sans prise en charge, ou transferts.

Conclusion générale : Cette recherche met en évidence l'impact des délais d'attente à l'urgence, sur la durée de séjour sur civière, notamment ceux liés à l'admission et à la consultation spécialisée. Nos analyses révèlent que la période critique se situe entre 7 h et 16 h, où une meilleure gestion des ressources pourrait réduire ces délais et améliorer la prise en charge des patients.

Le tableau de bord descriptif développé offre un suivi en temps réel, permettant aux gestionnaires d'identifier les surcharges, d'évaluer l'efficacité des décisions et d'ajuster les effectifs en conséquence.

Nos résultats ont des implications directes pour la gestion hospitalière. L'intégration d'un modèle prédictif permet d'anticiper la durée de séjour des patients et d'adapter les ressources en conséquence, optimisant ainsi la gestion des lits, le processus d'admission et la fluidité des services d'urgence.

Certaines limites doivent être prises en compte, notamment l'absence de variables clés, comme la disponibilité en temps réel des effectifs médicaux, et la fragmentation des systèmes d'information hospitaliers. Une intégration unifiée des données améliorerait la précision des modèles prédictifs et l'efficacité de la gestion des urgences.


Enfin, cette recherche ouvre des perspectives d'amélioration. L'exploration de modèles avancés, tels que les réseaux de neurones, et l'élargissement du périmètre des prédictions (ex. anticipation des réorientations ou admissions hospitalières) offrirait des gains supplémentaires en précision et en efficacité. De plus, la mise en place d'un modèle prescriptif pourrait aller encore plus loin en proposant des recommandations optimales pour la gestion des flux de patients et des ressources.

En conclusion, nos travaux apportent des solutions concrètes pour réduire la congestion à l'urgence, améliorer la gestion des ressources hospitalières et optimiser la prise en charge des patients. L'adoption d'outils analytiques avancés et l'amélioration de l'intégration des données hospitalières permettront aux décideurs d'optimiser les processus et de garantir un meilleur accès aux soins pour tous.

ANNEXE A


Liste des captures d'écran des trajectoires des patients

PA-6 — Trajectoire d'un patient et le temps d'attente possible




Source : (Appleby *et al.*, 2005, p. 21)

PA-7 — Schéma des différentes étapes du projet de recherche

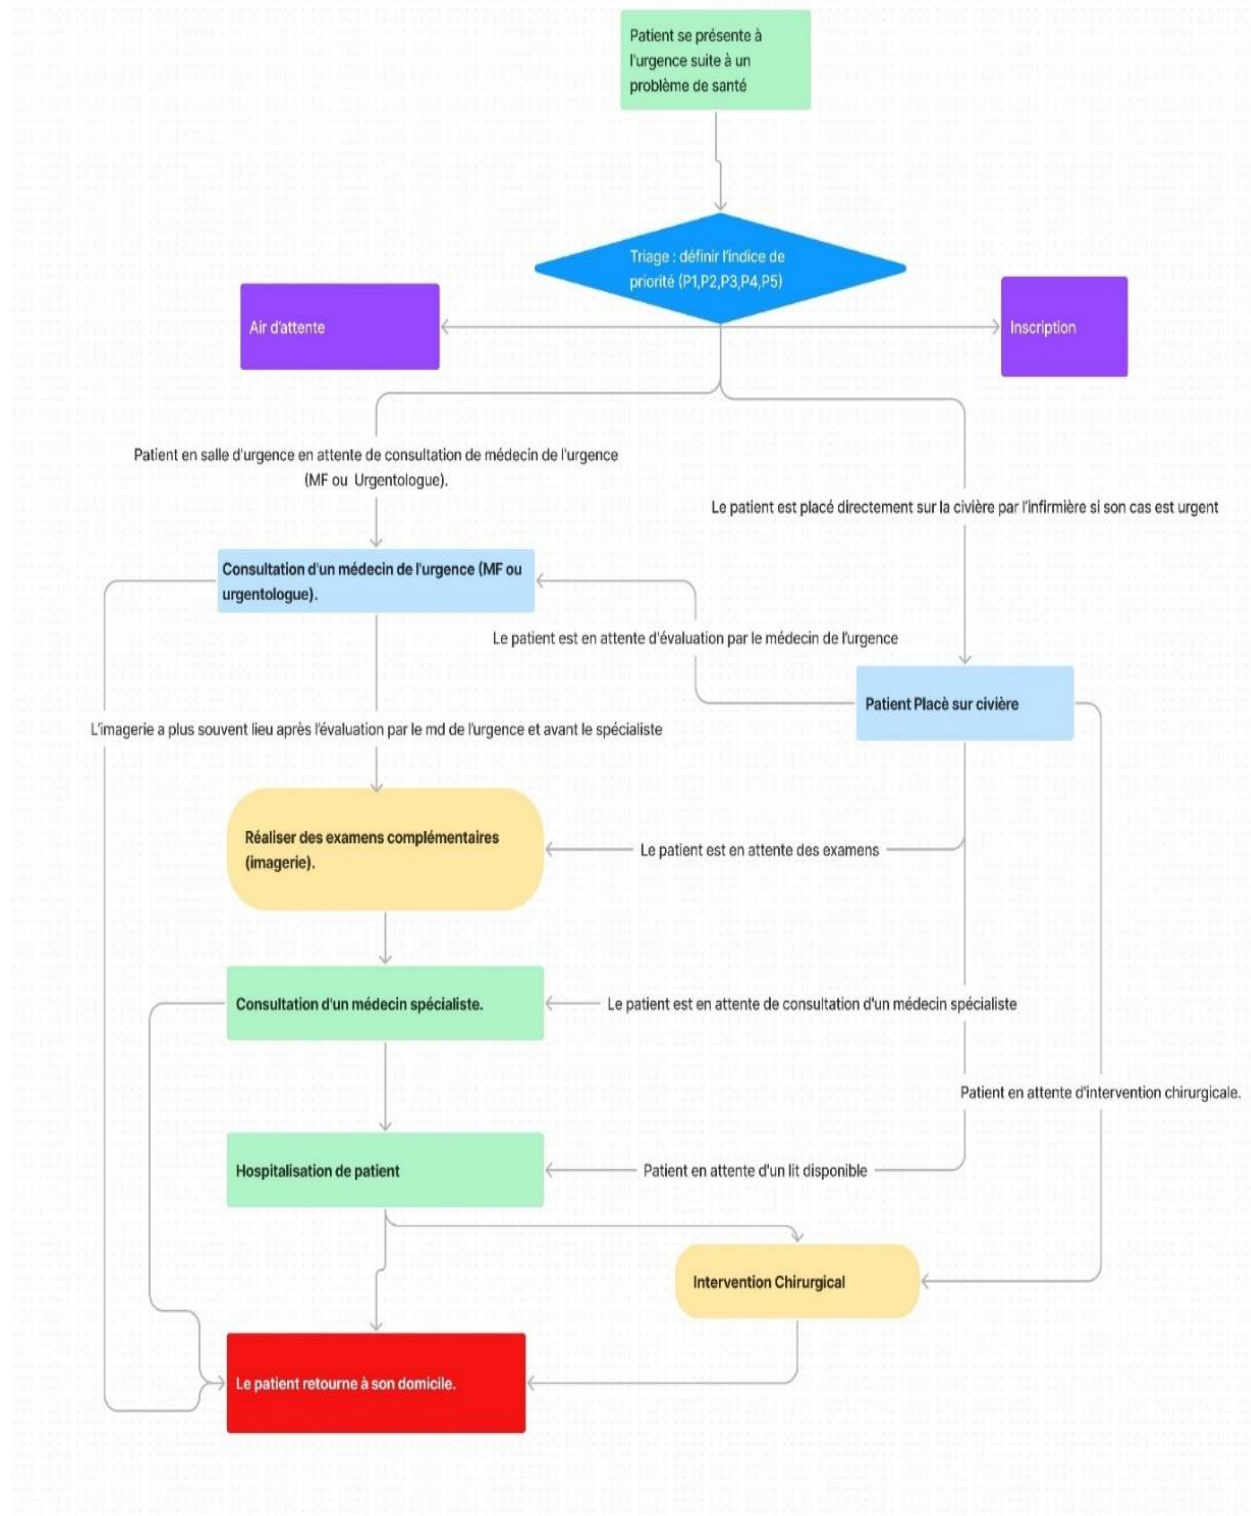


PA-8 — Schéma illustrant le temps d'attente des patients pour recevoir des soins, avec des exemples des États-Unis, de l'Australie et du Royaume-Uni



Source : (McIntyre et Clara K, 2019)


PA-9 — Trajectoire d'un patient à l'urgence de l'hôpital Cité-de-la-Santé et son temps d'attente




ANNEXE B

Liste des captures d'écran du tableau de bord de la DQPE — Service de l'Infocentre, l'hôpital de la cité-de-la-santé de Laval


TB - 4 — Tableau de bord de la fluidité : situation de l'urgence (l'hôpital de la cité-de-la santé de Laval)



TB-5 — Tableau de bord de la fluidité du parcours des usagers — Section consultation spécialisée (l'hôpital de la cité-de-la-santé de Laval)




TB-6 — Tableau de bord de la fluidité du parcours des usagers : section en attente d'hospitalisation (l'hôpital de la cité-de-la-santé de Laval)



ANNEXE C

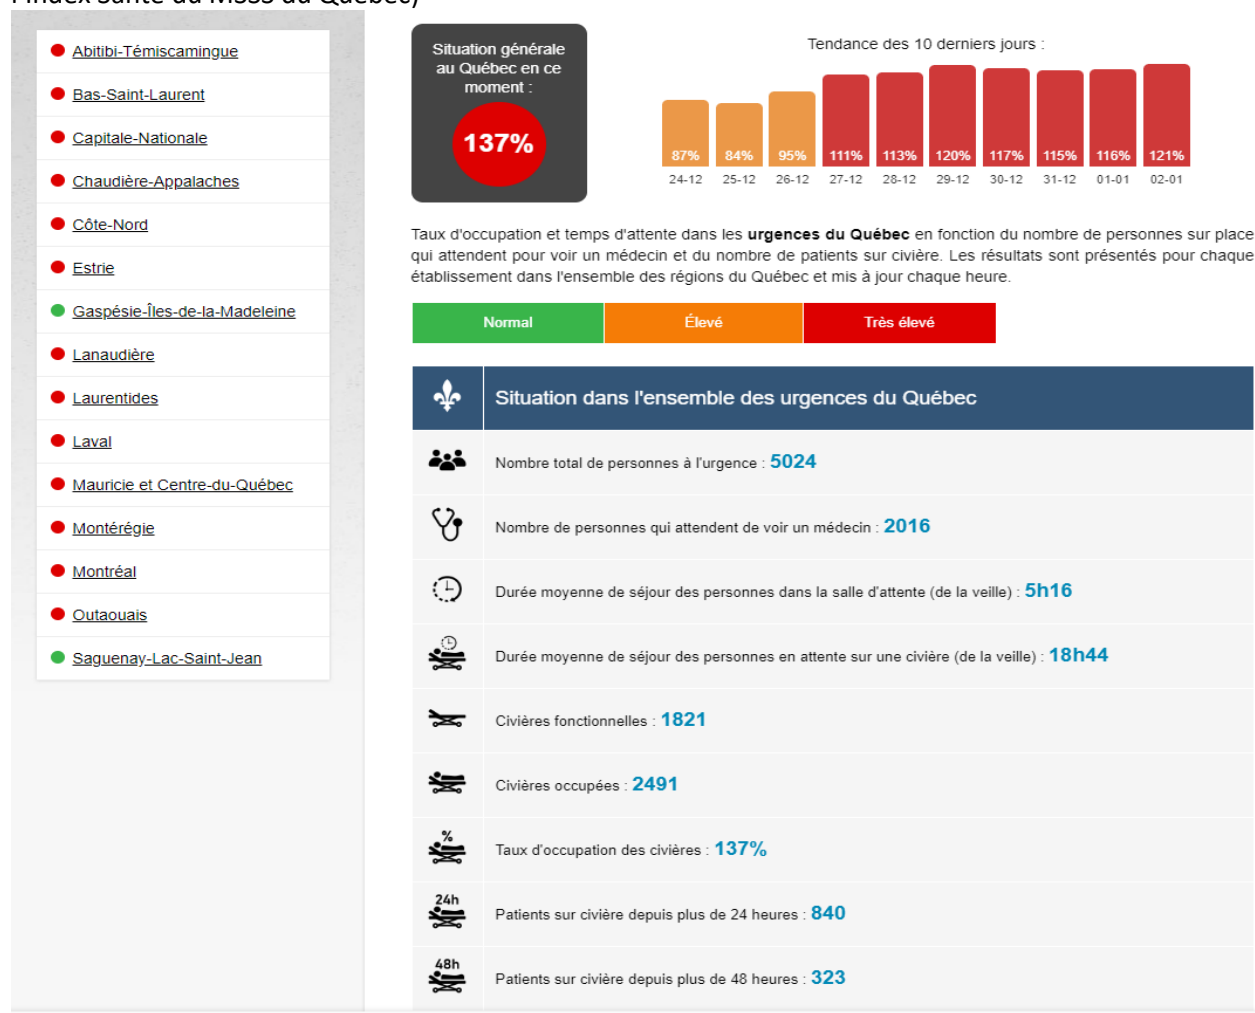
Liste des captures d'écran des tableaux de bord de l'Index Santé du MSSS du Québec

SA-2 — Urgences du Québec : variation de différentes mesures




Source : (Déry, 2019))


SA-3 — Situation dans l'ensemble des urgences du Québec au 2 janvier 2023 (données produites par l'Index Santé du MSSS du Québec)




SA-4 — Situation dans l'ensemble des urgences du Québec au 12 mars 2024 (données produites par l'Index Santé du MSSS du Québec)



SA-5 — Situation à l'urgence d'hôpital de la cité-de-la-santé de Laval au 3 janvier 2023 (données produites par l'Index Santé du Québec)




SA-6 — Évolution de la durée de séjour en salle d'urgence au Québec



Source : (Faubert, 2023a)

SA-7 — Taux d'occupation et temps d'attente dans l'urgence de l'hôpital de la cité-de-la-santé de Laval (données produites par l'Index Santé du Québec)



ANNEXE D

Liste des captures d'écran des tableaux de l'Institut canadien d'information sur la santé

CA-2 — Évolution de la durée de séjour en salle d'urgence à l'échelle du Québec

Tableau 1 Nombre de visites et durée du séjour au service d'urgence selon les niveaux de l'Échelle canadienne de triage et de gravité (ETG) et pour les cas admis, provinces et territoires participants, SNISA, avril 2022 à mars 2023


Province ou territoire*	Nombre de visites au service d'urgence				Médiane (50 % ont passé moins d'heures)			90 ^e percentile (90 % ont passé moins d'heures)		
	Total	Niveaux ETG I à III (sortie) [†]	Niveaux ETG IV et V (sortie) [†]	Cas admis [§]	Niveaux ETG I à III (sortie) [†]	Niveaux ETG IV et V (sortie) [†]	Cas admis [§]	Niveaux ETG I à III (sortie) [†]	Niveaux ETG IV et V (sortie) [†]	Cas admis [§]
Î.-P.-É.**	66,002	26,846	17,178	7,226	4.6	4.7	20.7	10.3	10.4	85.3
N.-É.**	294,976	155,285	68,087	24,312	4.7	3.3	12.9	11.0	7.4	54.5
Qc	3,626,684	1,195,200	1,503,940	404,561	5.7	3.6	21.2	17.5	11.0	54.9
Ont.	6,213,334	3,480,918	1,427,973	677,062	3.5	2.2	15.6	7.9	5.5	45.0
Man.**	282,416	115,007	79,971	34,830	6.0	4.2	21.5	16.4	10.9	55.8
Sask.**	606,903	199,213	241,843	64,587	3.7	2.2	9.0	9.6	6.5	38.2
Alb.	2,227,674	1,035,618	692,812	192,770	3.9	2.2	12.3	9.5	5.7	36.4
C.-B.**	1,769,587	892,591	522,662	221,255	3.9	2.7	18.0	7.9	5.6	55.0
Yn	41,737	14,415	20,849	2,748	2.7	2.0	7.6	5.4	4.4	20.5
Total	15,129,313	7,115,093	4,575,315	1,629,351	4.0	2.6	16.5	9.7	7.6	49.0

Source : (Institut canadien d'information sur la santé [ICIS], 2024).

ANNEXE E


Liste des captures d'écran du modèle analytique

MO-3 — Trois modèles d'analyse avancée des données



Source : (Sharda *et al.*, 2018, p. 49)

MO -4 — Modèle de régression linéaire



Source : (Sharda *et al.*, 2018, p. 113)

ANNEXE F

Les principaux jeux de données pour le développement du projet sur la DMS

Les jeux de données ont été créés sous forme de vues adaptées aux besoins de notre recherche. Chaque vue intègre les données nécessaires à l'analyse et à l'exploration via Power BI.

1. Système d'information de l'urgence MedUrge

1.1 Liste des patients sur civière à l'urgence

Vue : vUrgencesCiviere : cette vue contient la liste des patients en attente sur civière dans le service d'urgence.

Nom	Type	Description
NoDossier	INT	Numéro de dossier de patient
Épisode	INT	Numéro de l'épisode à l'urgence
DateDebutEpisode	Datetime	Date d'inscription de patient à l'urgence
DateDepart	Datetime	Date de départ de patient de l'urgence
CodeOrientation,	INT	Code Orientation de patient (ex. : hospitalisation)
Orientation	Varchar (50)	Description Orientation
IndCiviere	INT	1 : patient sur civière, 0 : ambulatoire
CodePostal	Varchar (6)	Zone régionale de patient
Sexe	Char (1)	M : masculin, F : féminin
AgeEffectif	INT	Âge de Patient
PrioriteTriage	Varchar (3)	Ordre de priorité de triage de patient
AliteDate	Datetime	Date de patient sur civière
CiviereId	Varchar (10)	Numéro de civière
SejourHreURG	Float	Durée de séjour de patient à l'urgence
SejourHreCIV	Float	Durée de séjour de patient sur civière
RaisonVisite	Varchar (100)	Raison de la visite de patient sur civière
CISSSNom	Varchar (50)	Ciss provenance de patient

1.2 Liste des demandes d'imagerie en provenance de l'urgence

Vue : vUrgencesDemandeImagerie : Cette vue regroupe la liste des demandes d'examens d'imagerie provenant de l'urgence.

Nom	Type	Description
DossierId	INT	Numéro de dossier de patient
EpisodeId	INT	Numéro de l'épisode de patient à l'urgence
Sexe	Char (1)	F : féminin. M : Masculin
Âge	INT	Âge de patient
DateInscription	Datetime	Date de l'inscription de patient à l'urgence
KardexId	Char (3)	Code de l'examen
DebutDate	Datetime	Date de demande de l'examen
FinDate	Datetime	Date de fin de l'examen
Statut	Char (1)	Statut de l'examen
Kardex	Varchar (10)	Code de l'examen
DescriptionStatut	Varchar (30)	Description de l'examen
Groupe	Varchar (10)	Groupe de l'examen
GroupeDescription	Varchar (30)	Description de groupe de l'examen

1.3 Liste des demandes d'admission depuis l'urgence

Vue : vDemandeAdmission : Cette vue regroupe les demandes d'admission des patients de l'urgence vers l'hôpital.

Nom	Type	Description
EpisodeDemandeAdmissionId	INT	Numéro de la demande d'admission
EpisodeId	INT	Numéro de l'épisode de patient à l'urgence
DossierId	INT	Numéro de dossier de patient
Sexe	Char (1)	F : féminin. M : Masculin
Âge	INT	Âge de patient
Priorité	INT	Priorité au triage
Civière	Char (5)	Numéro de civière
IndCiviere	Char (1)	1=patient sur civière, 0 =ambulant
Datedebut	Datetime	Date inscription de patient à l'urgence
AliteDate	Datetime	Date où un patient est mis sur une civière
DemandeDate	Datetime	Date de demande d'admission
AttributionLitDate	Datetime	Date d'attribution lit
DepartDate	Datetime	Date de départ de patient de l'urgence
AdmissionServiceAbrege	Char (5)	Description service d'admission
AdmissionService	Varchar (10)	Code de l'examen
RaisonVisite	Varchar (30)	Raison de la visite
Diagnostic	Varchar (10)	Diagnostique
AdmissionDelai	Float	Délai d'attente pour avoir un lit
CorrSpecId	Varchar (10)	Spécialité
MedecinOuSecteur	Varchar (20)	Médecin ou secteur
SpecialistId	Varchar (20)	spécialité
LitAssigne	Varchar (5)	Numéro de chambre et lit assigné au patient

1.4 Liste des consultations demandées auprès d'un spécialiste à l'urgence

Vue : vConsultationSpecialiste : cette vue regroupe les demandes de consultation spécialisées à l'urgence.

Nom	Type	Description
EpisodeConsultationId	INT	Numéro de la demande de consultation d'un spécialiste
EpisodeId	INT	Numéro de L'épisode de patient à l'urgence
DossierId	INT	Numéro de dossier de patient
Sexe	Char (1)	Type de sexe : F : féminin. M : Masculin
Âge	Int	Âge de patient
Priorité	Int	Priorité au triage
CivierId	Char (3)	Numéro de civière
ConsultSpecAbrege	Char (5)	Code de spécialité demandé
ConsultationSpecialite	Varchar (20)	Description de la spécialité demandée
InscriptionDate	Datetime	Date d'inscription de patient à l'urgence
AliteDate	Datetime	Date de mise sur civière le patient
DemandeDate	Datetime	Date demande de la consultation spécialisée
RealisationDate	Datetime	Date de réalisation de la consultation spécialisée
DelaiAttenteConsultation	Float	Temps d'attente avant la réalisation de la consultation
SejourUrgence	Float	Temps de séjour de patient à l'urgence
Raison	Varchar (255)	Raison de la consultation
Échéance	Varchar (5)	Type d'échéance (aujourd'hui, demain)
Statut	Varchar (10)	Statut de la consultation
MdDemandeur	Varchar (50)	Médecin demande la consultation d'un spécialiste

1.5 Liste des demandes de chirurgie provenant de l'urgence

Vue : vUrgenceDemandeChirurgie : Cette vue regroupe les demandes de chirurgie en provenance de l'urgence.

Nom	Type	Description
EpisodeDemandeAdmissionId	Int	Numéro de la demande d'admission
EpisodeId	Int	Numéro de l'épisode de patient à l'urgence
DossierId	INT	Numéro de dossier de patient
Sexe	Char (1)	F : féminin. M : Masculin
Âge	Int	Âge de patient
Priorité	Int	Priorité au triage
Civière	Char (5)	Numéro de civière
IndCiviere	Char (1)	1=patient sur civière, 0 =ambulant
Datedebut	Datetime	Date d'inscription de patient à l'urgence
AliteDate	Datetime	Date de mise sur une civière un patient
DemandeDate	Datetime	Date de demande d'admission
AttributionLitDate	Datetime	Date d'attribution lit
DepartDate	Datetime	Date de départ de patient de l'urgence
AdmissionServiceAbrege	Char (5)	Description service d'admission
AdmissionService	Varchar (10)	Code de l'examen
RaisonVisite	Varchar (30)	Raison de la visite
Diagnostic	Varchar (10)	Diagnostic
AdmissionDelai	Float	Délai d'attente pour avoir un lit
CorrSpecId	Varchar (10)	Spécialité
MedecinOuSecteur	Varchar (20)	Médecin ou secteur
SpecialistId	Varchar (20)	Spécialité
LitAssigne	Varchar (5)	Numéro de chambre et lit assigné au patient

2. Imagerie

2.1 Liste des demandes d'imagerie pour l'ensemble des épisodes

Vue : vPatientsImagerie : cette vue regroupe les requêtes traitées en imagerie.

Nom	Type	Description
DossierId	Int	Numéro de dossier
Requeteld	Int	Numéro de requête
SecteurId	Char (2)	Type de secteur
DebutDate	Datetime	Date de saisie
ExamenDate	Datetime	Date début de l'examen
CreationDate	Datetime	Date création requête
ExamenFinDate	Datetime	Date de fin de l'examen
DicteDate	Datetime	Date de dicte de l'examen
Provenance	Char (3)	Type de Provenance des patients
ProvenanceDetail	Varchar (50)	Détail type de Provenance des patients
BeneficiaireType	Char (1)	Type de bénéficiaire
ListeAttenteDate	Datetime	Date de saisie en attente
RequeteStatut	Varchar (50)	Statut de requête
Groupe	Varchar (50)	Groupe des examens
sous-groupe	Varchar (50)	Sous-Groupe des examens

3. Liste des hospitalisations des patients

3.1 Situation des hospitalisations

Vue : vHospitalisation : cette vue contient la liste des patients hospitalisés

Nom	Type	Description
Episodeld	INT	Numéro de l'épisode de patient à l'hôpital
DossierId	INT	Numéro de dossier de patient
Sexe	CHAR (1)	Type de sexe F : féminin. M : Masculin
Âge	INT	Âge de patient
UniteSoins	CHAR (5)	Unité de soins
ChambreLit	CHAR (10)	Numéro de chambre et lit
AdmissionDate	Datetime	Date admission à l'hôpital
CongePrevuDate	Datetime	Date prévue de congé de patient
CongeSigneDate	Datetime	Date de congé signé de patient
DepartDate	Datetime	Date de départ de patient
Raison	Varchar (50)	Raison de l'hospitalisation
Service	Char (5)	Service de soins
Médecin	Varchar (30)	Médecin de suivis
SejourDay	INT	Nombre des jours de séjour de patient à l'hôpital
SejourHour	INT	Nombre des heures de séjour de patient à l'hôpital
ProvenanceTypeld	INT	Provenance de patient (urgence,)
ProvenanceType	Varchar (50)	Description de la provenance de patient

3.2 Liste des hospitalisations des patients provenant de l'urgence

Vue : vHospitalisationSuiviUrgence : cette vue recense les patients hospitalisés depuis l'urgence.

Nom	Type	Description
EpisodeId	INT	Numéro de l'épisode de patient à l'hôpital
DossierId	INT	Numéro de dossier de patient
Sexe	CHAR (1)	F : féminin. M : Masculin
Âge	INT	Âge de patient
UniteSoins	CHAR (5)	Unité de soins
ChambreLit	CHAR (10)	Numéro de chambre et lit
InscriptionDateUrgence	Datetime	Date d'inscription à l'urgence
AliteDate	Datetime	Date de mise sur civière le patient
DemandeAdmissionDate	Datetime	Date demande d'admission de patient à l'hôpital
RealisationDateUrgence	Datetime	Date de relation de consultation d'un spécialiste
DepartDateUrgence	Datetime	Date de départ de l'urgence
AdmissionDate	Datetime	Date d'admission à l'hôpital
Service	Char (5)	Service d'admission à l'hôpital
DureeSejourUrgence	Float	Durée de séjour de patient à l'urgence
DureeSejourCiviere	Float	Durée de séjour de patient sur civière
SejourhospiHeure	Float	Durée de séjour à l'hôpital par heure
SejourhospiDay	Float	Durée de jour de patient par jour

ANNEXE G
Certificat d'éthique

**Groupe en éthique
de la recherche**

Piloter l'éthique de la recherche humaine

EPTC 2: FER 2022



Certificat de réussite

Ce document certifie que

Nejib Kachroudi

*a complété avec succès la Formation en éthique de la recherche
basée sur l'Énoncé de politiques des trois Conseils : Éthique de la
recherche avec des êtres humains (EPTC 2: FER 2022)*

Numero de certificat 0000949169

14 septembre, 2023

ANNEXE H

Formulaire d'approbation organisationnelle à l'utilisation des données d'entreprise



Formulaire d'approbation organisationnelle à l'utilisation des données d'entreprise

Titre du projet de recherche :	Améliorer le processus d'admission des patients à l'hôpital Cité de la santé
Nom de l'étudiante-chercheur/étudiant-chercheur :	Kachroudi Nejib
Programme d'études :	Maîtrise ès sciences (technologies de l'information - mémoire) (1758)
Nom et coordonnées de la direction de recherche :	Direction de la qualité, de l'évaluation, de la performance et de l'éthique
Nom de l'entreprise/organisme et de la division concernée (le cas échéant) :	
Centre intégré de santé et de services sociaux de Laval (CISSS de Laval)	

Accès aux données

Dans le cadre du projet de recherche intitulé **Améliorer le processus d'admission des patients à l'hôpital Cité de la santé**, Centre intégré de santé et de services sociaux de Laval (CISSS de Laval) consent à donner accès à (Kachroudi Nejib) aux données confidentielles suivantes :

- 1) Liste des patients à l'urgence par heure
- 2) Délai moyen de séjour des patients à l'urgence sur civière par heure
- 3) Nombre des demandes et de réalisation à l'imagerie par heure
- 4) Nombre de demande consultations spécialisé réalisé par heure
- 5) Nombre de demande consultations spécialisé en attente par heure
- 6) Nombre des demandes des soins en attente divers (laboratoire...) par heure
- 7) Nombre des médecins disponibles à l'urgence
- 8) Nombre des infirmières disponibles à l'urgence
- 9) Nombre des lits vacants, congés signé, départ à l'hôpital par service par jour

Centre intégré de santé et de services sociaux de Laval (CISSS de Laval) consent à donner accès à Kachroudi Nejib aux données non confidentielles suivantes :

- 1) Taux d'occupation des patients à l'urgence
- 2) Nombre de personnes dans les urgences de Laval
- 3) Taux d'occupation des civières
- 4) Durée moyenne dans les salles d'attente (de la veille)

Centre intégré de santé et de services sociaux de Laval (CISSS de Laval) confirme qu'elle ou qu'il détient l'autorité compétente afin d'octroyer cette autorisation. Elle ou il confirme que les données ont été collectées de façon à respecter les principes éthiques en matière de recherche universitaire auxquels le projet de (Kachroudi Nejib) est soumis.


Centre intégré de santé et de services sociaux de Laval (CISSS de Laval) confirme que les données auxquelles il donne accès à Kachroudi Nejib, pourront être utilisées à des fins de recherche et permet à l'étudiant de veiller à ce que les résultats issus en partie ou complètement de l'analyse de ces données puissent être utilisés à des fins de publications.

En acceptant que certains de vos employés. ées participent à cette étude, votre organisation s'engage également à ce que la participation –ou non- à l'étude et/ou les résultats qui découleront de l'étude n'entraînent aucune conséquence administrative pour ces employés.


En contrepartie Kachroudi Nejib s'engage à garder confidentiel le nom de Centre intégré de santé et de services sociaux de Laval (CISSS de Laval), à moins qu'une entente à cet effet ne lui soit octroyée par les représentants dument mandatés de l'organisation.

Kachroudi Nejib ainsi que Janosch Ortmann s'engagent à garder confidentielles toutes les informations obtenues dans le cadre de cette recherche. Ils s'engagent à protéger l'anonymat des répondants dans la mesure de ce qui est prévu dans le protocole de recherche soumis / approuvé par le CERPE-1 (conservation et destruction des données).

Je, (nom de l'employé mandaté), appuie la démarche de (Kachroudi Nejib)


Signature : 
Nom, prénom : Brisebois France
Titre et adresse complète : Chef de service de l'infocentre, bureau de la performance
Centre intégré de santé et de services sociaux de Laval (CISSSLAV)
800 BI Chomedey, Tour A, Laval, H7V 3Y4

Je, (nom de l'étudiant/étudiante), m'engage à respecter ce qui est convenu entre les parties en présence

Signature : 
Nom, prénom : Kachroudi Nejib
Titre et adresse complète : Analyste spécialisé en Informatique
6567 Rue Valade H7L 3E2 Laval

ANNEXE I

Architecture de la solution



RÉFÉRENCES

BIBLIOGRAPHIE

- Alecs, C., Grant, I., Daniel, K., Sara, K. et David, P. (2023). A systems approach to the future of emergency care. *CAEP*. <https://caep.ca/section-one-a-systems-approach-to-the-future-of-emergency-care/>
- Apprendre des meilleurs : étude comparative des urgences du Québec*. (2016). CSBE. https://www.csbe.gouv.qc.ca/salle-de-presse/communiquer/apprendre-des-meilleurs-etude-comparative-des-urgences-quebec.html?utm_source=chatgpt.com
- Barua, B. et Mackenzie, M. (2019, 11 décembre). *Waiting your turn: wait times for health care in Canada, 2019 Report* | Fraser Institute. <https://www.fraserinstitute.org/studies/waiting-your-turn-wait-times-for-health-care-in-canada-2019>
- Belorgey, N. (2011). « Réduire le temps d'attente et de passage aux urgences ». une entreprise de « réforme » d'un service public et ses effets sociaux. *Actes de la recherche en sciences sociales*, 189(4), 16-33. <https://doi.org/10.3917/arss.189.0016>
- Boulenger, S. et Vaillancourt, F. (2013). *Temps d'attente dans le secteur public de la santé au Québec : mesure, conséquences et moyens pour les réduire*.
- Carter, E. M. et Potts, H. W. 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. <https://doi.org/10.1186/1472-6947-14-26>
- Courville, E., Kazim, S. F., Vellek, J., Tarawneh, O., Stack, J., Roster, K., Roy, J., Schmidt, M. et Bowers, C. (2023). Machine learning algorithms for predicting outcomes of traumatic brain injury: a systematic review and meta-analysis. *Surgical Neurology International*, 14, 262. https://doi.org/10.25259/SNI_312_2023
- Cousineau, M.-E. (2022, 26 avril). *Une moyenne de 17 heures d'attente sur civière aux urgences*. Le Devoir. <https://www.ledevoir.com/societe/sante/703542/sante-une-moyenne-de-17-heures-d-attente-sur-civiere-aux-urgences>
- Coutin, A.-S. et Vaucel, E. (2014). Analyse de l'évolution des temps d'attente et durées de passage aux urgences gynécologiques et obstétricales du CHU de Nantes entre 2005 et 2012. *Journal de Gynécologie Obstétrique et Biologie de la Reproduction*, 43(5), 371-378. <https://doi.org/10.1016/j.jgyn.2013.08.009>
- Da Costa, I., Cottu, P., Bouleuc, C. et Moreau, P. (2022). La consultation médicale en urgence dans le parcours du patient en oncologie. *Bulletin du Cancer*, 109(12), 1277-1286. <https://doi.org/10.1016/j.bulcan.2022.06.012>
- Déry, P. (2018). *Les hôpitaux du Québec ont besoin d'entrepreneuriat*, 2.
- Déry, P. (2019). *Urgences : moins de patients, plus d'attente*, 2.
- Driesen, B. E. J. M., Riet, B. H. G. van, Verkerk, L., Bonjer, H. J., Merten, H. et Nanayakkara, P. W. B. (2018). Long length of stay at the emergency department is mostly caused by organisational

- factors outside the influence of the emergency department: a root cause analysis. *PLOS ONE*, 13(9), e0202751. <https://doi.org/10.1371/journal.pone.0202751>
- El Oualidi, M. A. et Saadi, J. (2013). Améliorer la prise en charge des urgences : apport de la modélisation et de la simulation de flux. *Santé Publique*, 25(4), 433-439. <https://doi.org/10.3917/spub.134.0433>
- Elazhary, N., Dolbec, M.-L., Boucher, T., Deshaies, J.-F., Vanasse, A. et Beaudoin, R. (2016). Étude des facteurs hospitaliers associés aux départs avant prise en charge médicale à l'urgence d'un centre hospitalier de soins tertiaires. *CJEM*, 18(1), 1-9. <https://doi.org/10.1017/cem.2015.101>
- Faubert, E. B. (2023). *Prendre son mal en patience: l'attente aux urgences augmente malgré les promesses*.
- Fenies, P. (2011). Une approche pour la prise en compte de la rationalité limitée des acteurs dans les modèles d'aide à la décision : mise en œuvre en contexte de logistique hospitalière. *Management & Avenir*, 48(8), 179-201. <https://doi.org/10.3917/mav.048.0179>
- Fortin, M.-F. et Gagnon, J. (2016). *Fondements et étapes du processus de recherche : méthodes quantitatives et qualitatives*. Chenelière éducation. <https://educ.info/xmlui/handle/11515/35682>
- Garcia-Carretero, R., Vigil-Medina, L., Mora-Jimenez, I., Soguero-Ruiz, C., Barquero-Perez, O. et Ramos-Lopez, J. (2020). Use of a k-nearest neighbors model to predict the development of type 2 diabetes within 2 years in an obese, hypertensive population. *Medical & Biological Engineering & Computing*, 58(5), 991-1002. <https://doi.org/10.1007/s11517-020-02132-w>
- Gawande, R. et Patil, Dr. V. (2022). Prediction of frequent hospitalisation of diabetic patients. *SSRN Electronic Journal*. <https://doi.org/10.2139/ssrn.4043544>
- Goldschmidt, G. et Matthews, B. (2022). Formulating design research questions: a framework. *Design Studies*, 78, 101062. <https://doi.org/10.1016/j.destud.2021.101062>
- Guazzo, A., Longato, E., Fadini, G. P., Sparacino, G., Battaggia, A., Franco-Novelletto, B., Cancian, M., Fusello, M., Avogaro, A. et Di, B. (2021). *Comparing the predictive power of heart failure hospitalisation risk scores across different care settings*.
- Gutkin, C. (2011). Temps d'attente inacceptables à l'urgence. *Canadian Family Physician*, 57(2), 255.
- Hachesu, P. R., Ahmadi, M., Alizadeh, S. et Sadoughi, F. (2013). Use of data mining techniques to determine and predict length of stay of cardiac patients. *Healthcare Informatics Research*, 19(2), 121-129. <https://doi.org/10.4258/hir.2013.19.2.121>
- Hong, W. S., Haimovich, A. D. et Taylor, R. A. (2018). Predicting hospital admission at emergency department triage using machine learning. *PLOS ONE*, 13(7), e0201016. <https://doi.org/10.1371/journal.pone.0201016>
- ICI.Radio-Canada.ca, Z. S.-. (2023a, 16 novembre). *Québec conclut un accord sans cible précise avec les médecins spécialistes*. Radio-Canada. Radio-Canada.ca. <https://ici.radio-canada.ca/nouvelle/2027352/patients-attente-medecin-specialiste-dube>
- ICI.Radio-Canada.ca, Z. S.-. (2023b, 22 novembre). *Un patient meurt aux urgences de l'hôpital grace après 33 heures d'attente*. Radio-Canada. Radio-Canada.ca. <https://ici.radio-canada.ca/nouvelle/2029058/attente-urgence-crise-sante-grace>

- Institut canadien d'information sur la santé (ICIS). (2023, août). *Durée totale du séjour au service d'urgence (en heures, percentile)*. <https://www.cihi.ca/fr/indicateurs/duree-totale-du-sejour-au-service-urgence-en-heures-percentile>
- Institut canadien d'information sur la santé (ICIS). (2024, 22 février). *Visites au service d'urgence et durée du séjour*. Visites au service d'urgence et durée du séjour selon les données du SNISA. <https://www.cihi.ca/fr/visites-au-service-urgence-et-duree-du-sejour-selon-les-donnees-du-snisa>
- Introduction - consultation médicale spécialisée - professionnels de la santé - MSSS*. (2024, 4 janvier). https://www.msss.gouv.qc.ca/professionnels/soins-et-services/guide-urgences-consultation-medicale-specialisee/?utm_source=chatgpt.com
- J Alapont, A. Bella-Sanjuán, C. Ferri², J. Hernández-Orallo, J. D. Llopis-Llopis et M. J. Ramírez-Quintana². (2005). *Specialised tools for automating data mining for hospital management*.
- Jacquemet, L. (2014). *Optimisation de la confection d'horaires de médecins urgentistes : application à l'hôpital Maisonneuve-Rosemont* [masters, École Polytechnique de Montréal]. <https://publications.polymtl.ca/1414/>
- Kadri, F., Chaabane, S., Harrou, F. et Tahon, C. (2014). Modélisation et prévision des flux quotidiens des patients aux urgences hospitalières en utilisant l'analyse de séries chronologiques. Dans *7ème conférence de Gestion et Ingénierie des Systèmes Hospitaliers (GISEH)* (p. 1-8). <https://hal.science/hal-01023299>
- Kim, Y. E. et Lee, H. Y. (2022). The effects of an emergency department length-of-stay management system on severely ill patients' treatment outcomes. *BMC emergency medicine*, 22(1), 204. <https://doi.org/10.1186/s12873-022-00760-z>
- K'ourio, H., Trebalag, A.-K., Gay, O. et Gourevitch, R. (2018). Les réintégrations en urgence lors de programme de soins : à propos d'une étude descriptive. *Annales Médico-psychologiques, revue psychiatrique*, 176(4), 410-415. <https://doi.org/10.1016/j.amp.2018.02.012>
- Lee, K.-S., Min, H. S., Moon, J. Y., Lim, D., Kim, Y., Ko, E., Kim, Y. S., Kim, J., Lee, J. et Sung, H. K. (2022). Patient and hospital characteristics predict prolonged emergency department length of stay and in-hospital mortality: a nationwide analysis in Korea. *BMC Emergency Medicine*, 22(1), 183. <https://doi.org/10.1186/s12873-022-00745-y>
- Levin, S., Toerper, M., Hamrock, E., Hinson, J. S., Barnes, S., Gardner, H., Dugas, A., Linton, B., Kirsch, T. et Kelen, G. (2018). Machine-learning-based electronic triage more accurately differentiates patients with respect to clinical outcomes compared with the emergency severity index. *Annals of Emergency Medicine*, 71(5), 565-574.e2. <https://doi.org/10.1016/j.annemergmed.2017.08.005>
- Lin, Y.-K., Chen, H., Brown, R. A., Li, S.-H. et Yang, H.-J. (2017). Healthcare predictive analytics for risk profiling in chronic care: a bayesian multitask learning approach: MIS Quarterly. *MIS Quarterly*, 41(2), 473-A3.
- Lopes, J., Vieira, G., Veloso, R., Ferreira, S., Salazar, M. et Santos, M. (2023). Optimization of surgery scheduling problems based on prescriptive analytics. Dans *Proceedings of the 12th International Conference on Data Science, Technology and Applications* (p. 474-479). SCITEPRESS - Science and Technology Publications. <https://doi.org/10.5220/0012131700003541>

- Maisonnave, M., Rajabi, E., Taghavi, M. et VanBerkel, P. (2024). Alternate level of care patients in Canada: a scoping review. *Canadian Geriatrics Journal*, 27(4), 519-530.
<https://doi.org/10.5770/cgj.27.755>
- McIntyre, D. et Clara K, C. (2019). *Waiting time as an indicator for health services under strain: a narrative review*. <https://journals.sagepub.com/doi/epub/10.1177/0046958020910305>
- Meschino, M. T., Giles, A. E., Rice, T. J., Saddik, M., Doumouras, A. G., Nenshi, R., Allen, L., Vogt, K. et Engels, P. T. (2020). Operative timing is associated with increased morbidity and mortality in patients undergoing emergency general surgery: a multisite study of emergency general services in a single academic network. *Canadian Journal of Surgery*, 63(4), E321-E328.
<https://doi.org/10.1503/cjs.012919>
- Mesurer les temps d'attente pour les examens par imagerie diagnostique ou la tomographie assistée par ordinateur – Qualité des services de santé Ontario*. (2025, 18 juin).
<https://www.hqontario.ca/Rendement-du-syst%C3%A8me/Mesurer-le-rendement-du-syst%C3%A8me/Mesurer-les-temps-dattente-en-imagerie-diagnostique>
- Ministère de la santé et des services sociaux. (2020, 2 avril). *Durée moyenne de séjour sur civière - répertoire des indicateurs de gestion en santé et services sociaux*. Gouvernement du Québec.
<https://msss.gouv.qc.ca/repertoires/indicateurs-gestion/indicateur-000027/>
- MSSS. (2022, 26 avril). *Suivi de l'utilisateur à l'urgence - Gestion clinique de l'épisode de soins - Professionnels de la santé - MSSS*. <https://www.msss.gouv.qc.ca/professionnels/soins-et-services/guide-urgences-gestion-clinique-de-l-episode-de-soins/suivi-de-l-usager-a-l-urgence/>
- Mulinganya, V., Mirindi, P., Karemere, H. et Florentin, A. (2018). Temps d'attente prolongés aux services de consultation médicale: enjeux et perspectives pour des hôpitaux de Bukavu en République Démocratique du Congo. *Pan African Medical Journal*, 29.
<https://doi.org/10.11604/pamj.2018.29.173.13651>
- No respite for Ontario patients: new report says five times more hospital beds needed than planned by Ford government | OCHU * CUPE. (2024). <https://ochu.on.ca/2024/09/05/no-respite-for-ontario-patients-new-report-says-five-times-more-hospital-beds-needed-than-planned-by-ford-government/>
- Oberlin, M., Andrès, E., Behr, M., Kepka, S., Le Borgne, P. et Bilbault, P. (2020). La saturation de la structure des urgences et le rôle de l'organisation hospitalière : réflexions sur les causes et les solutions. *La Revue de Médecine Interne*, 41(10), 693-699.
<https://doi.org/10.1016/j.revmed.2020.05.023>
- OECD. (2023). *Health at a glance 2023*. OECD. <https://doi.org/10.1787/7a7afb35-en>
- Ouellette-Vézina, H. (2023, 9 mars). Urgences du Québec: Le temps d'attente médian continue d'augmenter, selon une étude. *La Presse, Santé*. <https://www.lapresse.ca/actualites/sante/2023-03-09/urgences-du-quebec/le-temps-d-attente-median-continue-d-augmenter-selon-une-etude.php>
- Pak, A., Gannon, B. et Staib, A. (2021). Predicting waiting time to treatment for emergency department patients. *International Journal of Medical Informatics*, 145, 104303.
<https://doi.org/10.1016/j.ijmedinf.2020.104303>

- Paling, S., Lambert, J., Clouting, J., González-Esquerré, J. et Auterson, T. (2020). Waiting times in emergency departments: exploring the factors associated with longer patient waits for emergency care in England using routinely collected daily data. *Emergency Medicine Journal*, 37(12), 781-786. <https://doi.org/10.1136/emmermed-2019-208849>
- Perruche, F., Pourriat, J.-L. et Claessens, Y.-E. (2008). Satisfaction des patients consultant aux urgences. mise au point. *Journal Européen des Urgences*, 21(1), 14-21. <https://doi.org/10.1016/j.jeur.2008.06.009>
- Pettit, N., Vachon, E., Lash, R., Spackman, C. et Draucker, C. B. (2024). Perspectives of emergency department physicians and nurses on reasons for preventable emergency department visits by patients with cancer. *The American Journal of Emergency Medicine*, 78, 140-144. <https://doi.org/10.1016/j.ajem.2024.01.015>
- Prabhu, V. G., Taaffe, K., Shehan, M., Pirrallo, R., Jackson, W., Ramsay, M. et Hobbs, J. (2022, 24 septembre). *How does imaging impact patient flow in emergency departments?* arXiv. <https://doi.org/10.48550/arXiv.2209.12895>
- Renaud, S. et À Finalité. (2021). *Le vécu de la pandémie COVID-19 par les infirmiers des urgences et des soins intensifs et son impact sur la volonté d'y travailler à nouveau lors d'une prochaine pandémie : approche quantitative*. <https://matheo.uliege.be/handle/2268.2/12242>
- Sarty, J., Fitzpatrick, E. A., Taghavi, M., T. VanBerkel, P. et Hurley, K. F. (2023). Machine learning to identify attributes that predict patients who leave without being seen in a pediatric emergency department. *Canadian Journal of Emergency Medicine*, 25(8), 689-694. <https://doi.org/10.1007/s43678-023-00545-8>
- Sharda, R., Delen, D. et Turban, E. (2018). *Business intelligence, analytics, and data science: a managerial perspective* (Fourth edition). Pearson.
- Shmueli, G., Bruce, P. C., Yahav, I., Patel, N. R. et Lichtendahl, K. C. (2018). *Data mining for business analytics: concepts, techniques, and applications in R*. Wiley.
- Sørup, C. M., Jacobsen, P. et Forberg, J. L. (2013). Evaluation of emergency department performance - a systematic review on recommended performance and quality-in-care measures. *Scandinavian Journal of Trauma, Resuscitation and Emergency Medicine*, 21, 62. <https://doi.org/10.1186/1757-7241-21-62>
- SRLF et Springer-Verlag. (2014). Évaluation en médecine d'urgence. *Réanimation*, 23(S1), 201-205. <https://doi.org/10.1007/s13546-013-0780-x>
- Tancrez, J.-S., Roland, B., Cordier, J.-P. et Riane, F. (2011). Étude de la perturbation par les urgences du planning opératoire. *Logistique & Management*, world. <https://www.tandfonline.com/doi/abs/10.1080/12507970.2011.11516987>
- Tessier, L., Guilcher, S. J. T., Bai, Y. Q., Ng, R. et Wodchis, W. P. (2019). The impact of hospital harm on length of stay, costs of care and length of person-centred episodes of care: a retrospective cohort study. *CMAJ : Canadian Medical Association Journal*, 191(32), E879-E885. <https://doi.org/10.1503/cmaj.181621>
- Thompson, D. A., Yarnold, P. R., Williams, D. R. et Adams, S. L. (1996). Effects of actual waiting time, perceived waiting time, information delivery, and expressive quality on patient satisfaction in the

- emergency department. *Annals of Emergency Medicine*, 28(6), 657-665.
[https://doi.org/10.1016/S0196-0644\(96\)70090-2](https://doi.org/10.1016/S0196-0644(96)70090-2)
- Thompson, S., Whitaker, J., Kohli, R. et Jones, C. (2020). Chronic disease management: how It and analytics create healthcare value through the temporal displacement of care: MIS Quarterly. *MIS Quarterly*, 44(1), 227-256. <https://doi.org/10.25300/MISQ/2020/15085>
- Tsai, P.-F. (Jennifer), Chen, P.-C., Chen, Y.-Y., Song, H.-Y., Lin, H.-M., Lin, F.-M. et Huang, Q.-P. (2016). Length of hospital stay prediction at theaAdmission stage for cardiology patients using artificial neural network. *Journal of Healthcare Engineering*, 2016, 7035463.
<https://doi.org/10.1155/2016/7035463>
- Value & efficiency - health quality ontario*. (2019). https://www.hqontario.ca/System-Performance/Yearly-Reports/Measuring-Up-2019/Value-and-Efficiency?utm_source=chatgpt.com
- Wen, J., Zhang, T., Ye, S., Zhang, P., Han, R., Chen, X., Huang, R., Chen, A. et Li, Q. (2024). Quantitative patient graph analysis for transient ischemic attack risk factor distribution based on electronic medical records. *Heliyon*, 10(1), e22766. <https://doi.org/10.1016/j.heliyon.2023.e22766>
- Zhou, L., Zhao, P., Wu, D., Cheng, C. et Huang, H. (2018). Time series model for forecasting the number of new admission inpatients. *BMC Medical Informatics and Decision Making*, 18(1), 39.
<https://doi.org/10.1186/s12911-018-0616-8>