

UNIVERSITÉ DE LILLE

ÉCOLE DOCTORALE MADIS-631

Thèse

pour obtenir le grade de

Habilitation à Diriger les Recherches

Discipline : Informatique, Automatique

présentée et soutenue par

Kim Phuc TRAN

le 24 février 2022

**Surveillance, Détection d'Anomalies et
Optimisation des Systèmes Industriels avec
des Techniques Statistiques et
d'Apprentissage Automatique**

Philippe CASTAGLIOLA
Hind BRIL EL HAOUZI
François PERES
Christine THOMAS-AGNAN
El-Houssaine AGHEZZAF
Maryline CHETTO
Xianyi ZENG

Professeur, Université de Nantes
Professeur, Université de Lorraine
Professeur, École Nationale d'Ingénieurs de Tarbes
Professeur, Université Toulouse 1 Capitole
Professeur, Université de Gand
Professeur, Université de Nantes
Professeur, ENSAIT, Université de Lille

Président du jury
Rapporteuse
Rapporteur
Rapporteuse
Examineur
Examineur
Garant

« All models are wrong, but some are useful »

George E. P. Box

Dedicated to my parents and my wife,

Remerciements

Je tiens à remercier tous mes collègues de l'ENSAIT et du GEMTEX, Enseignants, Enseignants-Chercheurs, Ingénieurs, Techniciens, Ouvriers, Personnels administratifs, et mon collègue de bureau Guillaume qui ont contribué à l'accomplissement de mes activités de recherche et d'enseignement. Je tiens également à remercier tous les doctorants, les étudiants en master, et les post-docs que je co-encadre et co-dirige qui ont participé à mes travaux, et qui sont cités dans ce mémoire. Je n'oublie pas les partenaires, industriels ou académiques avec qui j'ai pu travailler.

Je tiens aussi à remercier Xianyi ZENG d'avoir accepté de se porter garant de mon HDR. J'adresse mes remerciements à Christine THOMAS-AGNAN, François PERES et Hind BRIL EL HAOUZI pour avoir accepté d'être rapporteur de ce manuscrit, ainsi qu'à Philippe CASTAGLIOLA, El-Houssaine AGHEZZAF, et Maryline CHETTO pour avoir accepté d'être examinateur de cette HDR.

Je tiens aussi à remercier Xianyi, Sébastien et Ludovic qui depuis le début de ma carrière m'a fait confiance et m'a laissé une autonomie très formatrice tant sur le co-encadrement et codirection des étudiants en thèse et que sur le suivi des projets de recherche. Je tiens aussi à remercier Philippe CASTAGLIOLA qui a été mon directeur de thèse pour ses conseils depuis ma thèse de doctorat qui sont toujours précieux et avisés.

Pour finir, je tiens à remercier tous mes proches, mes amis, mais surtout, ma femme et mes parents, qui me soutiennent à chaque instant, et font toujours preuve de beaucoup de patience.

Table des matières

Liste des sigles	8
Table des figures	9
Liste des tableaux	13
Chapitre 1 : Introduction	15
1.1 Rapport d'activités	16
1.1.1 Notice individuelle	16
1.1.2 Titres et diplômes	16
1.1.3 Experiences professionnelles antérieures	16
1.2 Synthèse des activités pédagogiques et encadrement d'étudiants	17
1.2.1 Résumé des enseignements	17
1.2.2 Responsabilités pédagogiques	18
1.2.3 Encadrement pédagogique d'étudiants	18
1.3 Activité d'encadrement	18
1.3.1 Thèses soutenues	18
1.3.1.1 Mme. Fatima Sehar Zaidi	18
1.3.1.2 M. Zhenglei He	19
1.3.1.3 M. Adel Nadi	19
1.3.2 Thèses en cours	20
1.3.2.1 Mme. Rita Sleiman	20
1.3.2.2 M. Moussab Orabi	20
1.3.2.3 M. Ali Raza	20
1.3.2.4 Mme. Van Nguyen Thi Thuy	20
1.3.2.5 Mme. Léa Catteau	21
1.3.3 Masters soutenus	21
1.3.3.1 Mme. Minh Chau Huynh	21
1.3.3.2 M. Ali Gazanayi	21
1.3.3.3 M. Phuong Bac Ta	21
1.3.3.4 M. Khaled Benzaidi	21
1.3.4 Post-doctorants :	22
1.3.4.1 M. Huu Du Nguyen	22
1.3.4.2 M. Quoc Thong Nguyen	22
1.3.4.3 M. Quoc Thong Nguyen	22
1.3.4.4 M. Ahmadi Nadi Adel	23
1.4 Diffusion et rayonnement	23
1.4.1 Examineur dans un jury de thèses	23
1.4.2 Examineur dans un jury de Master II	23
1.4.3 Membre COmités de Sélection (COS) à des fonctions de maîtres de conférences	23
1.4.4 Participation à des réseaux, sociétés savantes, communautés de programmation scientifique	24
1.4.5 Organisateur de session spéciale et chairman dans des conférences internationales	24
1.4.6 Séminaire invité	25
1.4.7 Orateur dans des conférences internationales	25

1.4.8	Evaluation d'articles	25
1.4.9	Activités d'expertise	26
1.5	Responsabilités scientifiques	26
1.5.1	Membre du comité scientifique des conférences internationales/nationales	26
1.5.2	Activités éditoriales	27
1.5.3	Activité administrative	27
1.5.4	Mobilité courte transfrontalière	27
1.6	Contrats de recherche	28
1.7	Liste de la production scientifique	29
1.7.1	Articles dans des revues internationales avec comité de lecture indexés JCR	30
1.7.2	Articles dans des revues internationales avec comité de lecture non indexés JCR	32
1.7.3	Ouvrages individuels et direction d'ouvrages collectifs	33
1.7.4	Chapitres d'ouvrage	33
1.7.5	Communications avec comité de lecture et avec acte dans un congrès international	34
1.7.6	Communications orales avec comité de lecture sans acte dans un congrès international ou national	36
1.8	Thème de recherche	37
1.9	Plan du mémoire	38

Chapitre 2 : Contributions à la carte de contrôle et l'apprentissage automatique pour la surveillance et la détection d'anomalies dans la fabrication . 40

2.1	Introduction	41
2.2	Cartes de contrôle pour surveiller le ratio de deux variables aléatoires et des données de composition	43
2.2.1	Cartes de contrôle surveillant le ratio de deux variables normales	43
2.2.1.1	Surveillance du ratio de deux variables normales à l'aide de deux cartes de contrôle Shewhart unilatérales	44
2.2.1.2	Surveillance du ratio de deux variables normales à l'aide des cartes de contrôle EWMA à intervalle d'échantillonnage variable	45
2.2.1.3	Modèle d'erreur de mesure à covariable linéaire pour l'échantillon du ratio	47
2.2.1.4	L'effet des erreurs de mesure sur les performances des cartes de contrôle EWMA pour le ratio de deux variables normalement distribuées	49
2.2.1.5	Conception de deux cartes Shewhart-RZ unilatérales pour des séries de production courtes	50
2.2.2	Cartes de contrôle surveillant les données de composition avec des erreurs de mesure	51
2.2.2.1	Modèle d'erreur de mesure à covariable linéaire pour CoDa	53
2.2.2.2	Performances de la carte de contrôle Hotelling T^2 pour les données de composition en présence d'erreurs de mesure	54

2.2.2.3	Performance de la carte de contrôle MEWMA-CoDa dans la présence d'erreurs de mesure	56
2.3	Application de l'apprentissage automatique pour la surveillance et la détection d'anomalies dans la fabrication	59
2.4	Conclusions	60
Chapitre 3 : Contributions à la modélisation et l'optimisation de la production avec l'apprentissage automatique et l'apprentissage par renforcement		63
3.1	Introduction	64
3.2	Un système d'aide à la décision multicritère basé sur l'apprentissage par renforcement en profondeur pour l'optimisation de la production avec l'application en industrie textile	65
3.2.1	Littérature pertinente	66
3.2.2	Contexte	66
3.2.2.1	Formulation du problème	66
3.2.2.2	Processus Hiérarchique Analytique pour une optimisation multicritère	67
3.2.2.3	Le processus décisionnel de Markov	68
3.2.2.4	Algorithme d'apprentissage par renforcement approfondi Q-networks	69
3.2.3	Cadre du système	71
3.2.4	Étude de cas	72
3.2.4.1	Modélisation du processus d'ozonation par décoloration à l'aide de la forêt aléatoire	73
3.2.4.2	Détermination des pondérations des critères à l'aide du processus de hiérarchie analytique	73
3.2.4.3	Q-networks profonds pour une prise de décision optimale	74
3.2.5	Résultats et discussion	75
3.3	Optimisation multiobjectif de la production à l'aide d'un apprentissage par renforcement multi-agent basé sur un réseau Q profond avec l'application en industrie textile	78
3.3.1	Revue de littérature	79
3.3.2	Formulation du problème	80
3.3.3	Méthodologie	81
3.3.3.1	Optimisation multiobjectif du processus de fabrication textile comme jeu de Markov	81
3.3.3.2	MARL basé sur DQN pour une optimisation multiobjectif du processus de fabrication textile	84
3.3.4	Étude de cas	85
3.3.5	Résultats et discussion	90
3.4	Conclusions	91
Chapitre 4 : Contributions à la prévision et la détection d'anomalies dans la gestion de la		

chaîne d’approvisionnement avec des techniques d’apprentissage automatique	93
4.1 Introduction	94
4.2 Travaux connexes	95
4.3 Scénarios	96
4.4 Approches proposées	98
4.4.1 Prédiction de séries chronologiques multivariées à l’aide de LSTM . .	98
4.4.2 Détection d’anomalies dans les séries chronologiques multivariées à l’aide d’Autoencodeur LSTM and OCSVM	99
4.5 Expérience et résultats	101
4.5.1 Analyse comparative des ensembles de données	101
4.5.1.1 C-MAPSS ensembles de données utilisés pour la prédiction	101
4.5.1.2 Données générées utilisées pour détecter une anomalie . .	102
4.5.2 Données réelles sur la vente au détail de mode	103
4.5.2.1 Prédiction des ventes	105
4.5.2.2 Détection d’anomalies dans les données de vente au détail de mode	105
4.6 Discussion	106
4.6.1 Apport théorique	106
4.6.2 Implications pour la pratique	108
4.7 Conclusions	109
Chapitre 5 : Contributions à la cybersécurité assurée à travers la détection d’anomalies avec des techniques d’apprentissage automatique	111
5.1 Introduction	112
5.2 Détection d’anomalies basée sur l’apprentissage automatique pour les applications de cybersécurité	114
5.2.1 Optimisation des hyperparamètres basée sur les données des machines à vecteurs de support à une classe pour la détection d’anomalies dans les réseaux de capteurs sans fil	115
5.2.2 Approches basées sur les données en temps réel pour la détection des fraudes par carte de crédit	115
5.2.3 Une approche axée sur les données pour la détection et la surveillance des anomalies de réseau basée sur l’espace nul du noyau	116
5.3 Détection d’anomalies basée sur l’apprentissage fédéré pour les applications de cybersécurité dans le système de contrôle industriel en fabrication intelligente	117
5.3.1 Architecture basée sur l’apprentissage fédéré pour la fabrication intelligente	118
5.3.2 Algorithme de détection d’anomalies utilisant le modèle hybride VAE-LSTM sur les appareils Edge	119
5.3.3 Évaluation des performances de détection	121
5.3.4 Évaluation de l’efficacité de l’Edge Computing	123
5.4 Conclusion	124

Chapitre 6 : Contributions à la surveillance pour les systèmes de santé intelligents avec des techniques d'apprentissage fédéré	125
6.1 Introduction	126
6.2 Travaux connexes et antécédents	129
6.2.1 Apprentissage automatique dans les soins de santé	129
6.2.2 Apprentissage fédéré	130
6.2.3 Apprentissage par transfert	132
6.2.4 Intelligence Artificielle Explicable	132
6.3 Le cadre proposé	132
6.3.1 Autoencodeur CNN	133
6.3.2 Classificateur basé sur CNN	134
6.3.3 XAI with Grad-CAM	135
6.3.4 Processus d'apprentissage	137
6.3.5 Réduction des coûts de communication et amélioration de la confidentialité	139
6.4 Résultats expérimentaux	141
6.4.1 Base de données	141
6.4.2 Analyse des performances de la méthode proposée	142
6.4.2.1 Reconstruction de l'Autoencodeur	143
6.4.2.2 Performance de classification	143
6.4.2.3 Analyse Qualitative	146
6.4.2.4 Comparaison avec d'autres méthodes de pointe	146
6.4.2.5 Amélioration de la confidentialité	148
6.4.2.6 Réduction des coûts de communication	149
6.4.2.7 Complexité temporelle de l'algorithme proposé	150
6.5 Conclusions	150

Chapitre 7 : Conclusion générale et Perspectives des thèmes de recherche	152
7.1 Conclusion générale	153
7.2 Perspectives des thèmes de recherche	154
7.2.1 Détection d'anomalies explicables pour la fabrication intelligente	155
7.2.1.1 Surveillance et détection d'anomalies pour les processus auto-corrélés et les processus non stationnaires avec optimisation des hyperparamètres	156
7.2.1.2 Carte de contrôle pour les types de données complexes	157
7.2.1.3 Détection d'anomalies explicables basée sur l'intelligence artificielle pour le journal des événements dans l'exploration de processus en ligne	159
7.2.2 Détection d'anomalies explicables et optimisation pour la gestion de la chaîne d'approvisionnement	160
7.2.3 Apprentissage fédéré sécurisé et explicable pour des soins de santé intelligents	160
7.2.4 Apprentissage fédéré explicable pour les applications de cybersécurité	162
7.2.5 Vers une mode durable avec l'intelligence artificielle et science des données	163

7.2.5.1	Prévision des tendances pour la mode durable	163
7.2.5.2	Optimisation d'un outil d'évaluation pour la filière textile- habillement : vers des modes de production et de consommation plus durables	164

Acronyme

Acronyme	Définition	Acronyme	Définition
AI	Artificial Intelligence	NN	Neural Networks
ANN	Artificial Neural Network	NSGA-II	Non-dominated Sorting Genetic Algorithm-II
ARIMA	Autoregressive Integrated Moving Average	VAR	Vector autoregression
<i>ARL</i>	Average Run Length	<i>CRL</i>	Conforming Run Length
AHP	Analytic Hierarchy Process	MCDM	Multiple Criteria Decision Making
MDP	Markov Decision Process	DQN	Deep Q-networks
MOPSO	Multiple Objective Particle Swarm Optimization	SCM	Supply Chain Management
RL	Reinforcement Learning	RF	Random Forest
MARL	Multi-Agent RL	DRL	Deep Reinforcement Learning
CNN	Convolutional Neural Network	DNN	Deep Neural Networks
CUSUM	CUmulative SUM	MFE	Mean Forecast Error
DS	Double Sampling	<i>EARL</i>	Expected Average Run Length
EWMA	Exponentially Weighted Moving Average	<i>LCL</i>	Lower Control Limit
MEWMA	Multivariate Exponentially Weighted Moving Average	<i>RL</i>	Run Length
ML	Machine Learning	Grad-CAM	Gradient-weighted Class Activation Mapping
ECG	Electrocardiography	XAI	Explainable Artificial Intelligence
<i>SDRL</i>	Standard-Deviation Run Length	SPC	Statistical Process Control
SPM	Statistical Process Monitoring	VSI	Variable Sampling Interval
IoT	Internet of Things	ECG	Electrocardiograph
LSTM	Long Short Term Memory	SVDD	Support Vector Data Description
KQE	Kernel Quantile Estimation	RUL	Remaining Useful Life
RMSE	Root Mean Squared Error	CE	Cross Entropy
CS	Computer Science	SVM	Support Vector Machine
VAE	Variational Autoencoder	CPD	Conditional Probability Distribution
RNN	Recurrent Neural Network	PCA	Principle Component Analysis
FL	Federated Learning	TF	Transfer Learning
TDA	Topological Data Analysis	GNN	Graph Neural Networks

Table des figures

1.1	Plan du mémoire.	39
2.1	Distribution des scores d'anomalies de l'ensemble de données d'entraînement [1]	61
2.2	Détection d'anomalies de défaillance de roulement [1]	61
3.1	La structure MDP de l'optimisation multicritère du processus de fabrication de produits chimiques textiles dans le cadre proposé [2].	71
3.2	Organigramme de l'algorithme mettant en œuvre le système d'aide à la décision multicritère basé sur l'apprentissage par renforcement en profondeur proposé pour l'optimisation du processus de fabrication de produits chimiques textiles [2].	72
3.3	Performances prédictives des modèles RF entraînés dans l'étude de cas pour aider à la prise de décision dans le processus d'ozonation des couleurs textiles [2]	74
3.4	La fonction de perte des réseaux cibles pour chaque scénario avec des cibles différentes [2]	76
3.5	Le nombre d'états explorés par l'agent DQN dans chaque épisode pour différents scénarios [2]	76
3.6	L'erreur minimale des solutions que l'agent DQN a atteint avec les pas de temps [2]	76
3.7	Résultats simulés de solutions avec un minimum d'erreurs obtenus respectivement à partir de cadres basés sur DQN et basés sur Q-learning[2]	77
3.8	Une illustration générale des procédés de fabrication textile de la fibre au vêtement [3]	79
3.9	Le jeu de Markov pour l'optimisation multi-objectif des processus de fabrication textile dans le cadre proposé [3]	83
3.10	Organigramme de l'algorithme mettant en œuvre le système multi-agent basé sur DQN proposé pour optimiser le processus de fabrication de textiles avec des objectifs multiples [3]	85
3.11	Performances prédictives des modèles RF entraînés dans l'étude de cas [3]	86
3.12	Augmentation de la politique ε -greedy pour le choix de l'action [3]	86
3.13	La fonction de perte de DQN pour quatre agents dans le jeu de Markov [3]	87
3.14	L'erreur minimale des agents DQN réglés et leur valeur totale en fonction des pas de temps [3]	89
3.15	Comparaison du cadre MARL proposé avec les algorithmes de base en ce qui concerne les résultats numériques [3]	89
3.16	Comparaison du cadre MARL proposé avec les algorithmes de base en ce qui concerne les échantillons simulés [3]	89
4.1	Une illustration d'une gestion de la chaîne d'approvisionnement en deux parties [4]	97
4.2	Une illustration du fonctionnement du réseau autoencodeur LSTM pour la fenêtre glissante de taille 2 [4]	100
4.3	La distribution des variables pour les données de séries chronologiques multivariées [4]	104
4.4	Une comparaison entre les ventes réelles et les ventes prévues à l'aide de LSTM [4]	106

4.5	Illustration de la représentation apprise de l'autoencodeur LSTM à partir de la série chronologique multivariée d'origine à l'aide de la méthode PCA [4]	107
4.6	La détection d'anomalies pour les données réelles basée sur le réseau Autoencodeur LSTM et l'algorithme OCSVM [4]	107
5.1	Approches basées sur les données proposées pour la détection de la fraude par carte de crédit [5]	116
5.2	Architecture basée sur FL- pour la détection d'anomalies dans la fabrication intelligente [6]	119
5.3	Schéma fonctionnel du modèle hybride VAE-LS [6]	120
5.4	Configuration du banc d'essai [6]	123
6.1	Architecture de l'apprentissage fédéré [7]	131
6.2	Un aperçu du cadre proposé [7]	133
6.3	L'architecture de l'autoencodeur de débruitage proposé [7]	134
6.4	Le classificateur proposé basé sur CNN [7]	136
6.5	Présentation du module XAI proposé dans notre framework [7]	137
6.6	La méthode de sélection de couche pour la réduction des coûts de communication [7]	140
6.7	La distribution de l'ensemble de données d'origine [7]	142
6.8	La distribution de l'ensemble de données suréchantillonné (rééquilibré) [7] .	143
6.9	Comparaison de la version originale et de la version bruitée du jeu de données [7]	144
6.10	Reconstruction MAE [7]	144
6.11	Les performances de classification du cadre proposé, avec la version bruitée du jeu de données [7]	145
6.12	Les principales ondes d'un seul tracé ECG normal [7]	147
6.13	Les sorties du module XAI	148
7.1	Thèmes de recherche	154
7.2	Perspectives des thèmes de recherche	155

Liste des tableaux

1.1	Bilan des co-encadrements de thèses	18
1.2	Bilan des co-encadrements et directions de postdoc	19
1.3	Bilan des co-encadrements de masters (recherche)	19
1.4	Bilan de la production scientifique	36
2.1	Comparaison en termes de ARLs hors-contrôle entre les cartes de contrôle Hotelling CoDa T^2 et MEWMA-CoDa en présence d'erreur de mesure [8]	58
3.1	Le résultat du réglage des hyperparamètres des modèles RF et les résultats de test du modèle optimisé [2]	73
3.2	Matrice de comparaison par paire de $k/s, L^*, a^*$ et b^* par rapport à la performance globale des couleurs [2].	73
3.3	Paramétrage de l'algorithme DQN dans l'étude de cas du processus d'ozonation textile	75
3.4	Les cibles expérimentales échantillonnées par des experts que nous avons utilisées dans l'application de l'étude de cas du système d'aide à la décision proposé [2]	77
3.5	Paramétrage de l'algorithme DQN dans l'étude de cas du processus d'ozonation textile [3]	87
3.6	Comparaison des algorithmes de base et du cadre proposé du résultat optimisé.	87
4.1	Comparaison RMSE avec la littérature sur le jeu de données C-MAPSS FD001 [4]	101
4.2	Comparaison des performances de notre méthode proposée[4] et la méthode suggérée dans [9]	102
5.1	Métriques de performance d'OCSVM et carte de contrôle T^2	116
5.2	Comparaison des performances	117
5.3	Approche FL par rapport à l'approche CL sur 7 séries de données chronologiques différentes	122
5.4	Résultats centralisés ou fédérés l'ensemble de données SCADA [6]	123
6.1	Les cinq classes de signaux ECG	135
6.2	La performance de classification du cadre proposé, avec l'ensemble de données d'origine (propre)	145
6.3	Comparaison avec les travaux de pointe [7]	147
6.4	Comparaison avec les études précédentes pour la classification ECG [7]	149
6.5	Comparaison avec les travaux de pointe en apprentissage fédéré pour la santé	150

Chapitre 1 :

Introduction

1.1 Rapport d'activités

1.1.1 Notice individuelle

Nom : TRAN KIM PHUC

Date et lieu de naissance : 20 Julliet 1986 à Hoi An, Vietnam

Situation actuelle : Maître de Conférences (depuis le 01/09/2018)

Bénéficiaire d'une PEDR depuis le 01/10/2021

Adresse professionnelle : 2 Allée Louise et Victor Champier, 59056 ROUBAIX

Unité de Recherche : GEMTEX

Etablissement : ENSAIT, Université de Lille

Discipline : Informatique, Automatique

Téléphone : 03 20 25 89 60

Mél : kim-phuc.tran@ensait.fr

Page web : <https://www.gemtex.fr/gemtex-members/phuc-tran/>

1.1.2 Titres et diplômes

- 2009 : Diplôme d'ingénieur en automatique et productique du Programme de Formation d'Ingénieurs d'Excellence au Vietnam (PFIEV), Université de Technologie de Da Nang, Vietnam.
- 2011 : DEA en automatique et productique du Programme de Formation d'Ingénieurs d'Excellence au Vietnam (PFIEV), Université de Technologie de Da Nang, Vietnam.
- 2014-2016 : Thèse en automatique et informatique appliquée à l'Université de Nantes, France, titre : Surveillance des procédés de type mélange, dirigée par le Professeur Philippe CASTAGLIOLA, présentée et défendue le 29 Septembre 2016.

1.1.3 Expériences professionnelles antérieures

- 2009-2013 : Enseignant chercheur en automatique à l'Université Phan Chau Trinh, Faculté du génie électrique et d'électronique, Hoi An, Vietnam.
- 2013-2014 : Enseignant chercheur en automatique à l'Université de Dong A, Faculté du génie électrique et d'électronique, Da Nang, Vietnam.
- 06/2016-07/2016 : Chercheur invité à l'aide de la bourse de recherche DAAD de courte durée (<https://www.daad.de/de/>) dans le cadre du projet "Steady-state ARL analysis of ARL-unbiased EWMA-RZ control chart for monitoring the ratio of two normal variables", Helmut-Schmidt-Universität, Hambourg, Allemagne.
- 2016-2018 : Chercheur invité au département Science des Données, Université TDT, Saïgon, Vietnam.
- 2016-2018 : Chercheur invité au département Intelligence Artificielle, Université Dong A, Danang, Vietnam.
- 12/2016-11/2017 : Stage post-doctoral dans le cadre du projet "Apprentissage automatique et classification statistique pour la détection et l'identification des défaillances à l'aide d'une surveillance spectrale automatique - Application aux

éoliennes terrestres" à GIPSA-lab, UMR 5216 CNRS& Grenoble INP, Grenoble, France.

- 12/2017-08/2018 : Stage post-doctoral dans le cadre du projet "Usine intelligente 4.0 avec apprentissage automatique et vision par ordinateur" à LMBA (Laboratoire de Mathématiques de Bretagne-Atlantique UMR CNRS 6205) & Université Bretagne Sud (avec partenaires industriels), Vannes, France.
- 2018-2021 : Chercheur invité à l'University of Liège, Liège, Belgique.
- 2018-2019 : Chercheur invité à l'Université de Gand, Gand, Belgique.
- 2018-2020 : Chercheur invité à l'Université du Kent, Kent, Royaume-Uni.

1.2 Synthèse des activités pédagogiques et encadrement d'étudiants

1.2.1 Résumé des enseignements

Avant d'intégrer l'ENSAIT, j'ai effectué des activités d'enseignement dans le domaine des mathématiques appliquées pour l'ingénierie, de la commande avancée, des automates programmables industriels (programmation et installation), des probabilités et des statistiques pour des niveaux de formation allant de la première année à la troisième année du cycle d'ingénieur en électrotechnique à l'université Phan Chau Trinh entre 2009 et 2013, et à l'université Dong A entre 2019 et 2014. De décembre 2017 à août 2018 : J'ai enseigné dans le domaine de la science des données et Modélisation Statistique à l'Université de Bretagne Sud, Faculté Sciences & Sciences de l'Ingénieur. Les détails sont ci-dessous.

- **12/2017-08/2018** : Chargé d'enseignement vacataire à l'Université de Bretagne Sud, Faculté Sciences & Sciences de l'Ingénieur
 - Chargé de TD en Python et machine learning
 - Chargé de projet tutoré Master 1 Data Science et Modélisation Statistique
- **12/2009-05/2013** : Enseignant chercheur à l'Université de Phan Chau Trinh, Faculté des Sciences et Technologie, Quang nam, Vietnam
 - CM et TD : Mathématiques appliquées pour l'ingénierie
 - CM et TD : Probabilités et Statistiques
 - CM et TD : Commande avancée
 - CM et TD : Automates programmables industriels (API)
- **06/2014-02/2014** : Enseignant chercheur à l'Université de Dong A, Faculté des Sciences et Technologie, Da Nang, Vietnam.
 - CM et TD : Probabilités et Statistiques
 - CM et TD : Commande avancée
 - CM et TD : Automates programmables industriels (API)

Depuis 2018, mes activités pédagogiques, déroulées à l'ENSAIT, se sont concentrés sur les disciplines relatives à l'automatique et l'informatique industrielle. Mes interventions concernent principalement les sciences pour l'ingénieur.

- Algorithmique et Programmation en Python (CM,TD,TP)
- Systèmes d'Informations des entreprises (TP)
- Gestion du cycle de vie des produits pour le secteur de la mode (TP)
- Optimisation du Système Logistique (CM)

Nom	début du thèse	fin de thèse	%de co-encadrement	% de co-direction
Zhenglei He	01/10/2017	15/12/2020	33%	
Fatima Sehar Zaidi	01/10/2017	5/11/2020	20%	
Ahmadi Nadi Adel	01/10/2018	22/09/2021		50%
Rita Sleiman	01/10/2019	en-cours	50%	
Moussab Orabi	01 /10/2020	en-cours		50%
Ali Raza	01 /10/2020	en-cours	50%	
Van Nguyen Thi Thuy	1/10/2020	en-cours		50%
Léa Catteau	1/9/2021	en-cours	50%	

TABLEAU 1.1 – Bilan des co-encadrements de thèses

- Textile and fashion innovation (CM)

1.2.2 Responsabilités pédagogiques

Mes responsabilités pédagogiques au sein de l'ENSAIT concernent les missions suivantes :

- Responsable projets pédagogiques pour le semestre international à l'ENSAIT. Cela implique par exemple de l'organisation des projets, de la proposition du sujet à l'évaluation finale de l'étudiant, de faire le bilan avec les étudiants et les tuteurs à la fin du projet.
- Responsable pédagogique de l'UE : Ingenierie Mathematique Informatique (avec 3 Modules composant l'UE : Algorithmique et Programmation en Python, Outils mathématiques , Programmation Visual Basic).

1.2.3 Encadrement pédagogique d'étudiants

L'encadrement des futurs ingénieurs en stage (première ou deuxième année) ou projet de fin d'études est une mission très enrichissante. Par ailleurs les sujets de stages et de projets de fin d'études sur les problématiques liées à l'amélioration de la qualité, la gestion de la production et la chaîne d'approvisionnement sont très prisés par les entreprises et les étudiants. Le nombre moyen de projets de fin d'études encadrés depuis 2018 est de l'ordre de 4 par an. Le nombre moyen de stages ingénieur (2ème année) et (1ème année) est de l'ordre de 4 par an. Ces stages et projets sont effectués dans des entreprises de différents secteurs. Les encadrements de projets de fin d'études sont particulièrement intéressants car ils permettent l'exposition à des problèmes importants qui doivent être résolus au sein des entreprises. Ils sont également contextuellement inspirants pour orienter les sujets de recherche vers la pratique.

1.3 Activité d'encadrement

1.3.1 Thèses soutenues

1.3.1.1 Mme. Fatima Sehar Zaidi

- Thèse soutenue le 05/11/2020 (Début de la thèse : 01/10/2017)

Nom	début postdoc	fin de postdoc	%de co-encadrement
Huu Du Nguyen	01/12/2018	31/01/2020	50%
Quoc Thong Nguyen	06/01/2020	31/03/2021	50%
Quoc Thong Nguyen	01/04/2021	15-12-2021	50%
Ahmadi Nadi Adel	22/05/2021	en-cours	100%

TABLEAU 1.2 – Bilan des co-encadrements et directions de postdoc

Nom	début master	fin de master	%de co-encadrement
Minh Chau Huynh	01/04/2019	30/09/2019	25%
Ali Gazanayi	01/04/2020	30/09/2020	50%
Phuong Bac Ta	01/04/2021	30/09/2020	50%
Khaled Benzaidi	01 /04/2021	30/09/2021	100%

TABLEAU 1.3 – Bilan des co-encadrements de masters (recherche)

- Taux d’encadrement : 20%.
- Directeurs de Thèse : Philippe Castagliola (LS2N, Université de Nantes)
- Co-encadrant : Kim-Phuc Tran (ENSAIT/GEMTEX)
- Financement : bourse pakistanaise.
- Titre : Développement de procédures de suivi statistique de données compositionnelles.
- Publications relatives à la thèse : deux articles dans des revues internationales avec comité de lecture indexés JCR [P11, P22].

1.3.1.2 M. Zhenglei He

- Thèse soutenue le 15/12/2020 (Début de la thèse : 01/10/2017)
- Taux d’encadrement : 33%.
- Directeurs de Thèse : Xianyi Zeng (ENSAIT/GEMTEX) et Sébastien Thomassey (ENSAIT/GEMTEX).
- Co-encadrant : Kim-Phuc Tran (ENSAIT/GEMTEX)
- Financement : bourse chinoise CSC.
- Publications relatives à la thèse : 2 communication [C13, C16], un chapitre d’ouvrage [B3], 4 articles dans des revues internationales avec comité de lecture indexés JCR [P17, P25, P26, P28].

1.3.1.3 M. Adel Nadi

- Thèse soutenue le 22/09/2021 (Début de la thèse : 01/10/2018)
- Taux d’encadrement : 50%
- Directeurs de Thèse : Bahram Sadeghpour Gildeh (Ferdowsi University of Mashhad, Iran) et Kim Phuc Tran (ENSAIT/GEMTEX). Le doctorant s’inscrit uniquement à l’Université Ferdowsi de Mashhad, Iran.
- Financement : bourse du gouvernement iranien
- Titre : A framework for end-to-end deep learning-based anomaly detection in Smart Manufacturing

- Publications relatives à la thèse 1 articles et 3 articles en révision dans des revues internationales avec comité de lecture indexés JCR [P30].

1.3.2 Thèses en cours

1.3.2.1 Mme. Rita Sleiman

- Thèse en cours (Début de la thèse : 01/10/2019). Soutenance prévue en Octobre 2022.
- Taux d'encadrement : 50%
- Directeur de Thèse : Sébastien Thomassey (ENSAIT/GEMTEX).
- Co-encadrant : Kim-Phuc Tran (ENSAIT/GEMTEX)
- Financement : allocations de recherche région Hauts de France (50%), ISITE ULNE (30%), et entreprise Camaïeu (20%).
- Titre : Optimisation de l'assortiment des collections et des achats d'articles de mode par les données massives et l'intelligence artificielle.
- Publication relatives au projet : 1 communication [C18].

1.3.2.2 M. Moussab Orabi

- Thèse en cours (Début de la thèse : 01/10/2020).
- Taux d'encadrement : 50%. Directeurs de Thèse : Sébastien Thomassey (ENSAIT/GEMTEX) et Kim Phuc Tran* (ENSAIT/GEMTEX), * : la demande autorisation de co-direction a été approuvé par l'Ecole Doctorale SPI Université Lille Nord de France avec la date soutenance prévue HDR prévue le 24 Février 2022.
- Financement : Moussab Orabi est salarié de la société Rosenberg (<http://www.rosenberger.com>), Allemagne. Il a une décharge horaire pour mener sa thèse .
- Titre : Activer le Process Mining avec la détection d'anomalies.

1.3.2.3 M. Ali Raza

- Thèse en cours (Début de la thèse : 01/10/2020).
- Taux d'encadrement : 50%.
- Directeur de Thèse : Ludovic Koehl (ENSAIT/GEMTEX, 25%) , Shujun Li (University of Kent, UK, 25%)
- Co-encadrant : Kim-Phuc Tran* (ENSAIT/GEMTEX), * : la thèse est financée par le projet intitulé "SHSFL" (Smart Healthcare System with Federated Learning) dont je suis le coordinateur.
- Financement : I-SITE ULNE
- Titre : Système de santé intelligent avec apprentissage fédéré
- Publication relatives au projet : 1 article dans des revues internationales avec comité de lecture indexés JCR [P33].

1.3.2.4 Mme. Van Nguyen Thi Thuy

- Thèse en cours (Début de la thèse : 01/10/2020).

- Taux d’encadrement : 50%.
- Directeurs de Thèse : Heuchenne Cédric (HEC Liège / Université de Liège) et Kim Phuc Tran (ENSAIT/GEMTEX). La doctorante s’inscrit uniquement à l’Université de Liège, Belgique.
- Financement : HEC-Ulg, Belgique
- Titre : Détection d’anomalies dans les données de séries temporelles multivariées IoT avec des techniques statistiques et d’apprentissage automatique
- Publication relatives au projet : 1 chapitres d’ouvrage [B8]

1.3.2.5 Mme. Léa Catteau

- Thèse en cours (Début de la thèse : 01/09/2021).
- Taux d’encadrement : 50%.
- Directeur de Thèse : Ludovic Koehl (ENSAIT/GEMTEX, 50%)
- Co-encadrant : Kim-Phuc Tran (ENSAIT/GEMTEX)
- Financement : CIFRE
- Titre : Optimisation d’un outil d’évaluation pour la filière textile-habillement : vers des modes de production et de consommation plus durables

1.3.3 Masters soutenus

1.3.3.1 Mme. Minh Chau Huynh

- Master II Génie électrique et électronique de l’université polytechnique d’Hô-Chi-Minh-Ville, Vietnam du 01/03/2019 au 30/09/2019
- Taux d’encadrement : 25% (Pr. X. Zeng 25%, Pr. P. Bruniaux 25%, Pr. L. Koehl 25%)
- Titre : Représentation virtuelle des textiles : drapé des étoffes.

1.3.3.2 M. Ali Gazanayi

- Master II Electronique, energie électrique et automatique de l’université Université de Perpignan Via-Domitia, du 01/03/2020 au 30/09/2020
- Taux d’encadrement : 50% (Pr. X. Zeng 25%, Pr. L. Koehl 25%)
- Titre : Reconnaissance de l’activité humaine à l’aide de l’apprentissage fédéré

1.3.3.3 M .Phuong Bac Ta

- Projet de fin d’études (PFE) de la formation d’ingénieur spécialité Electronique, energie électrique et automatique de Hanoi University of Science and Technology (Vietnam), du 01/03/2020 au 30/09/2020
- Taux d’encadrement : 50% (T.H. Truong 50%)
- Titre : Détecter les cyberattaques à l’aide de la détection d’anomalies dans les systèmes de contrôle industriels

1.3.3.4 M. Khaled Benzaidi

- Master 2 en électronique, énergie électrique, automatique parcours systèmes embarqués de l’École Nationale Supérieure d’Ingénieurs Sud-Alsace, du 01/03/2021

au 30/09/2021

- Taux d'encadrement : 100%
- Titre : Système d'aide à la décision pour la détection de l'actimétrie humaine avec apprentissage automatique

1.3.4 Post-doctorants :

1.3.4.1 M. Huu Du Nguyen

- Du 01/09/2018 au 31/01/2020
- Taux d'encadrement : 50%.
- Cordinateurs : Cédric Heuchenne (Université de Liège, Belgique) et Kim Phuc Tran (ENSAIT/GEMTEX).
- Financement : Université Dong A, Vietnam (50%) et Le Fonds de la Recherche Scientifique – FNRS, Belgique (50%).
- Titre : Multi-State models : inference and applications
- L'objectif du projet est de développer un certain nombre de nouvelles approches / méthodes basées sur les statistiques et l'apprentissage automatique pour traiter les problèmes de détection d'anomalies, de reconnaissance de l'activité humaine et de surveillance de la production en temps (en Smart Manufacturing).
- Publications relatives au projet : 7 communications [C8, C9, C10, C11, C12, C14, C17], 5 chapitres d'ouvrage [B2, B4, B9, B10, B11], 11 articles dans des revues internationales avec comité de lecture indexés JCR [P8, P12, P13, P14, P16, P18, P19, P20, P21, P23, P24]

1.3.4.2 M. Quoc Thong Nguyen

- Du 01/02/2020 au 31/03/2021)
- Taux d'encadrement : 50%.
- Cordinateurs : Cédric Heuchenne (Université de Liège, Belgique) et Kim Phuc Tran (ENSAIT/GEMTEX).
- Financement : Université Dong A, Vietnam (50%) et Le Fonds de la Recherche Scientifique – FNRS, Belgique (50%).
- Titre : Multi-State models : inference and applications (Quoc Thong Nguyen a continué à travailler sur le même projet après la démission de Huu Du Nguyen).
- Publications relatives au projet : 2 communications [C15, C17], 1 chapitre d'ouvrage [B7], 2 articles dans des revues internationales avec comité de lecture indexés JCR [P12, P27]

1.3.4.3 M. Quoc Thong Nguyen

- Du 01/04/2021 au 15/12/2021)
- Taux d'encadrement : 50%.
- Cordinateurs : Sébastien Thomassey (ENSAIT/GEMTEX) et Kim Phuc Tran (ENSAIT/GEMTEX).
- Financement : la société MatchMarket
- Titre : Apprentissage automatique pour l'industrie de la mode

1.3.4.4 M. Ahmadi Nadi Adel

- Projet en cours (22/05/2021-)
- Taux d'encadrement : 100%.
- Coadjuteurs : Kim Phuc Tran (ENSAIT/GEMTEX).
- Financement : bourse du gouvernement iranien
- Titre : Application de l'apprentissage automatique dans les diagrammes de contrôle statistique des processus pour la fabrication intelligente
- Publications relatives au projet : un chapitre d'ouvrage collectif [B5]

1.4 Diffusion et rayonnement

1.4.1 Examineur dans un jury de thèses

- Thèse Mme. Dorra RAHALI, intitulée "Surveillance Statistique du Temps et de l'amplitude entre évènements", soutenue à l'université de Nantes, le 24/06/2020. Jury de thèse composé de : Philippe CASTAGLIOLA (Université de Nantes, UMR 6004 - LS2N) directeur de thèse, Hind BRIL-EL HAOUZI (Université de Lorraine, UMR 7039 – CRAN) et Ahmed REBAI (Université de Sfax, Tunisie) rapporteurs, Kim Phuc TRAN et Imène KOOLI (Université de Sousse, Tunisie), examinateurs.
- Thèse M. Zhenglei HE, intitulée "Modeling and optimization of textile manufacturing processes using intelligent techniques", soutenue à l'université de Lille, le 15/12/2020. Jury de thèse composé de : Xianyi ZENG (ENSAIT) et Sébastien THOMASSEY (ENSAIT) directeurs de thèse, Laure MOREL (Université de Lorraine) et Stéphane NEGNY (ENSIACET) rapporteurs, Kim Phuc Tran et Philippe CASTAGLIOLA (Université de Nantes), examinateurs.

1.4.2 Examineur dans un jury de Master II

Thèse Master II M. Tan Kin LEONG, intitulée "Optimal designs of the Exponentially Weighted Moving Average Median chart based on Median Run Length and Expected Median Run Length ", soutenue à l'université Tunku Abdul Rahman, le 18/06/2020. Jury de thèse composé de : Chong Zhi LIN (Université Tunku Abdul Rahman, Malaisie) directeur de thèse, Kim Phuc TRAN rapporteur, Lam WENG (Université Tunku Abdul Rahman, Malaisie) et Teoh Wei LIN (Heriot-Watt University, Campus de Malaisie), examinateurs.

1.4.3 Membre COmités de Sélection (COS) à des fonctions de maîtres de conférences

Membre du comité de sélection des Maîtres de Conférences (IMT, profil 61) en sciences de données pour l'optimisation de la production et de la logistique au sein de l'équipe Sciences de la Fabrication et Logistique de Mines Saint-Etienne en 2021.

1.4.4 Participation à des réseaux, sociétés savantes, communautés de programmation scientifique

- Membre du ENBIS (European Network for Business and Industrial Statistics), une plateforme mettant en relation des individus et des organisations, intéressés par les développements théoriques et les applications pratiques dans le domaine des statistiques commerciales et industrielles.
- Membre du GIS GRAISyHM (Groupe d'Intérêt Scientifique de Recherche en Automatisation Intégrée et Systèmes Homme-Machine). Le GIS GRAISyHM rassemble tous les laboratoires de génie informatique, du traitement du signal et d'automatique de la région Hauts-de-France (section 61 du CNU). Au sein de ce groupe de recherche, j'appartiens au groupe de travail "Aide à la décision en milieu incertain"
- Membre du SAGIP (Société d'Automatique et de Génie Industrielle et de Productique) vient d'être créée pour reprendre une partie des activités du GDR MACS.
- Membre fondateur du GIS CybCom (Groupe d'Intérêt Scientifique sur la Cybersécurité des systèmes embarqués Communicant sans fil). Partenaires initiateurs du projet de création du GIS CybCom : CNRS, CRIStAL, IEMN, Univ. Gustave Eiffel, IMT Lille Douai, INRIA, IRCICA, Univ. Lille, UPHF, ENSAIT /GEMTEX. Je suis responsable de l'ENSAIT/GEMTEX dans la création du GIS CybCom avec ses partenaires fondateurs. Par ailleurs, côté GIS GRAISyHM, je suis la personne chargée de discuter directement avec GIS CybCom dans les projets et activités conjointes du 2 GIS.
- Membre du projet Campus Cyber Lille Hauts-de-France. Le campus Cyber Lille Hauts-de-France s'inscrit dans cette démarche pour bâtir le centre de gravité de la cybersécurité des Hauts-de-France.

1.4.5 Organisateur de session spéciale et chairman dans des conférences internationales

- Président du Programme (Program Chair) de ISSAT International Conference on Data Science in Business, Finance and Industry (DSBFI 2019) , Danang, Vietnam, July 3-5, 2019 (<https://www.issatconferences.org/Images/CallProgProc/dsbfi19prg.pdf>)
- Chairman dans la session 8 (Predictive Modeling and Recommender Systems for Business and Industry) de DSBFI 2019
- Membre du comité d'organisation de la session spéciale intitulé "Data Science and Artificial Intelligence in the Fashion Industry" dans la conférence internationale FLINS 2020, Cologne, Allemagne, 18-21 Aout, 2020 (<https://www.hrm-bildung.de/flins2020/files/SS06.pdf>).
- Membre du comité d'organisation de la session spéciale intitulé "Artificial Intelligence Based Optimization Techniques for Demand-Driven Manufacturing" dans la conférence internationale APMS 2021 International conference Advances in Production Management Systems, Nantes, France, 05-09

Septembre, 2021 (<https://www.apms-conference.org/apms-2021/program/special-sessions-tracks-proposal/>).

1.4.6 Séminaire invité

- K.P. Tran, "Machine learning and statistics for anomaly detection : main challenges and opportunities", séminaire à HEC Liège - École de gestion de l'université de Liège, December 2018.

1.4.7 Orateur dans des conférences internationales

- K.P. Tran (2021), "Advanced Statistical Process Control, Big Data and Machine learning : a perspective", International Webinar on Artificial Intelligence and Data Science with Applications 2021, Dong A University, Vietnam, 20 December 2021. (Conférence invitée)
- K.P. Tran (2018), "Advanced Statistical Process Control, Big Data and Machine learning : a perspective", International Symposium on Business and Industrial Statistics (ISBIS) 2018, University of Piraeus, Greece, 4-6 July 2018. (Conférence invitée)
- K.P. Tran*, H.D. Nguyen, S. Thomassey. "Anomaly detection using Long Short Term Memory Net- works and its applications in Supply Chain Management", 9th IFAC Conference on Manufacturing Modelling, Management and Control, Berlin, Germany, August 28-30, 2019.
- H.D. Nguyen, K.P. Tran*, X. Zeng, L. Koehl, P. Castagliola , and P. Bruniaux. "Industrial Internet of Things, Big Data, and Artificial Intelligence in a Smart Factory : a survey and perspective", ISSAT International Conference on Data Science in Business, Finance and Industry (DSBFI2019), Danang, Vietnam, July 3-5, 2019
- K.P. Tran*, P. Castagliola, T.H. Nguyen, A. Cuzol. "The Efficiency of the VSI Exponentially Weighted Moving Average Median Control Chart". Proceedings of the 24th ISSAT International Conference on Reliability and Quality in Design, pages 203-208, ISBN : 978-0-9910576-5-8, Toronto, ON, Canada, August 2018.
- K.P. Tran* H. D. Nguyen, Q. T. Nguyen, and W. Chattinnawat (2018) "One-Sided synthetic control charts for monitoring the Coefficient of Variation with Measurement Errors", In proceedings of The IEEE International Conference on Industrial Engineering and Engineering Management, 16-19 December, 2018, Bangkok, Thailand, <https://doi.org/10.1109/IEEM.2018.8607320>
- Pour l'ensemble des autres conférences mentionnées dans la production scientifique, l'orateur est un doctorant, post-doctorant co-encadré ou un membre permanent de laboratoires externes

1.4.8 Evaluation d'articles

- Depuis 2016, j'effectue des revues d'articles scientifiques pour des journaux :
- Automatika
 - IEEE Transactions on Industrial Informatics
 - Computers in Industry

- Computers & Industrial Engineering
- Applied Artificial Intelligence
- ISA Transactions
- Quality and Reliability Engineering International
- Quality and Safety Engineering, Quality Technology & Quantitative Management
- Journal of Testing and Evaluation
- European Journal of Operation Research
- Industrial & Engineering Chemistry Research
- International Journal of Computational Intelligence Systems
- Communications in Statistics-Theory and Methods
- Mathematical Problems in Engineering
- Sensors
- Symmetry
- Applied Sciences
- Journal of Visual Communication and Image Representation
- Engineering Science and Technology, an International Journal
- Scientific Reports

1.4.9 Activités d'expertise

- 2018-2019 : Expert dans le projet de recherche OPTIPROFIL (Optimisation et adaptation d'un outil d'étude de marché à des flux massifs et hétérogènes de données médias), collaborer entre Social Media Lab de l'Université catholique de Louvain et l'Université de Liège, financé par la Région Wallonne, Belgique.
<https://www.socialmedialab.be/projets/profiling-dutilisation/>
- 2020- : Expert et évaluateur pour le Service Public de Wallonie, la Direction générale opérationnelle Economie, Emploi, Recherche (SPW-EER), Belgique :
<https://recherche.wallonie.be/home.html>
- 2018- : Expert scientifique à l'Université Dong A, Vietnam

1.5 Responsabilités scientifiques

1.5.1 Membre du comité scientifique des conférences internationales/nationales

- Président du Programme (Program Chair) de ISSAT International Conference on Data Science in Business, Finance and Industry (DSBFI 2019) , Danang, Vietnam, July 3-5, 2019, <https://www.issatconferences.org/Images/CallProgProc/dsbfi19prg.pdf>
- Membre du comité scientifique de 7th Conference on Information Technology and Its Applications - CITA 2018, Vietnam, <http://sict.udn.vn/cita2018/>
- Membre du comité scientifique de 8th Conference on Information Technology and Its Applications - CITA 2019, Vietnam, <http://sict.udn.vn/cita2019/>

- Membre du comité scientifique de 9th Conference on Information Technology and Its Applications - CITA 2020, Vietnam, <http://sict.udn.vn/cita2020/>
- Membre du comité scientifique de 10th Conference on Information Technology and Its Applications - CITA 2021, Vietnam, <http://sict.udn.vn/cita2021/>
- Membre du comité scientifique et Track Chair de First International Conference on Intelligence of things (ICIT 2022), Hanoi, Vietnam, <https://icit2022.humg.edu.vn/>

1.5.2 Activités éditoriales

- Rédacteur de sujets (Topic Editor) de la revue Sensors (indexé JCR)
- Membre du comité scientifique de la revue Artificial Intelligence Evolution
- Rédacteur chef invité (Invited Editor) de la revue Sensors (indexé JCR) d'un numéro spécial sur "Artificial Intelligence for Smart Manufacturing : Methods and Applications". https://www.mdpi.com/journal/sensors/special_issues/AISM
- Rédacteur chef invité (Invited Editor) de la revue Sensors (indexé JCR) d'une collection thématique sur "IoT, Edge Computing and Artificial Intelligence for Fault Diagnosis" https://www.mdpi.com/journal/sensors/special_issues/IoT_fault_diagnosis
- Rédacteur chef invité (Invited Editor) de la revue Sensors (indexé JCR) d'un numéro spécial sur "IoT, AI Based Digital Twin for Smart Manufacturing " https://www.mdpi.com/journal/sensors/special_issues/AIDT
- Rédacteur chef invité (Invited Editor) de la revue Applied Sciences (indexé JCR) d'un numéro spécial sur "Artificial Intelligence and Machine Learning in Industrial Automation : Methods and Applications" https://www.mdpi.com/journal/applsci/special_issues/AIMLIAMA

1.5.3 Activité administrative

- Membre élu du conseil du laboratoire GEMTEX depuis 22/09/2020 : le conseil du laboratoire, composé des membres élus du laboratoire et présidé par le directeur du GEMTEX, participe à la gouvernance du laboratoire.

1.5.4 Mobilité courte transfrontalière

- Projet intitulé AICSSHS (Artificial Intelligence for Cyber Security in Smart Healthcare System) <http://www.isite-ulne.fr/wp-content/uploads/2019/01/LAUREATS-BOURSES-MOBILITE-FEV-2019-1.pdf> Porteur : Kim Phuc Tran
Destination : Université du Kent, Royaume-Uni
- Projet intitulé AISCOBDE (Artificial Intelligence for Supply Chain Optimization in the Big Data Era) <http://www.isite-ulne.fr/wp-content/uploads/2019/01/LAUREATS-BOURSES-MOBILITE-FEV-2019-1.pdf> Porteurs : Xianyi Zeng & Kim Phuc Tran
Destination : Université de Gand, Belgique
- Projet intitulé ESMAIBD (Enabling Smart Manufacturing with Artificial Intelligence and Big Data) <http://www.isite-ulne.fr/wp-content/uploads/2019/11>

/LAUREATS-BOURSES-MOBILITE-RECHERCHE-JANVIER-2020-4.pdf Porteur : Kim Phuc Tran

Destination : Université de Gand, Belgique

- Projet intitulé TSHFL (Towards Smart Healthcare system with Federated Learning)

<http://www.isite-ulne.fr/wp-content/uploads/2020/01/LAUREATS-BOURSES-MOBILITE-FEVRIER-2020-1.pdf> Porteur : Kim Phuc Tran

Destination : Université du Kent, Royaume-Uni

1.6 Contrats de recherche

1. Projet intitulé "SHSFL" (Smart Healthcare System with Federated Learning), financement 100% I-SITE ULNE (<http://www.isite-ulne.fr/wp-content/uploads/2020/02/LAUREATS-COTUTELLES-UNIV-KENT-2020-1.pdf>). Date de début du projet : 01/10/2020, durée globale du projet : 3 ans, budget total de 135 000 €. Financement d'une thèse pour l'ENSAIT, M. Ali RAZA

Rôle : Coordinateur

Les objectifs principaux du projet : en utilisant les technologies les plus avancées de l'IoT et en développant de nouveaux algorithmes d'IA efficaces, le nouveau système de soins de santé proposé devrait fournir un outil puissant pour à la fois améliorer la qualité des soins de santé publics et réduire les coûts.

2. Projet intitulé "OCMDMIA" (Optimisation de l'assortiment des Collections et des achats d'articles de Mode par les Données Massives et l'Intelligence Artificielle) financement 50% allocations de recherche région Hauts de France, 30% ISITE ULNE, et 20% entreprise Camaïeu. (<http://www.isite-ulne.fr/wp-content/uploads/2018/12/LAUREATS-ALLOCATIONS-RECHERCHE-ENTREPRISES-2019-1.pdf>). Date de début du projet : 01/10/2019, durée globale du projet : 3 ans, budget total de 135 000 €. Financement d'une thèse pour l'ENSAIT, Mme. Rita Sleiman.

Rôle : participation au montage et à la réalisation du projet.

L'objectif du projet OCMDMIA est de permettre de développer un outil d'aide à la décision pour les enseignes de la distribution textile afin d'optimiser les assortiments des collections en favorisant les produits à fort potentiels et en intégrant les contraintes stratégiques et stylistes de l'enseigne, et les quantités à acheter en indiquant aux acheteurs les potentiels de ventes par produit.

3. Projet intitulé "LACMC" (2020-2022) : Lancement et accompagnement de Text-CARE, la chaire de la mode circulaire, financé par la Région Hauts de France dans le cadre du dispositif Simule (Soutien aux Travaux Interdisciplinaires, Multi-établissements et Exploratoires) - Volet Partenarial (STIP), Date de début du projet : 01/09/2020, durée globale du projet : 2 ans, budget total de 191 386 €

Rôle : participation à la réalisation du projet.

Principales missions de cette chaire : Sensibiliser, éduquer à l'économie circulaire et accompagner la construction et l'épanouissement de nouveaux écosystèmes

4. Projet intitulé "AIMatchMarket" (2021-2022) : Apprentissage automatique pour l'industrie de la mode, financé par la société MatchMarket Date de début du projet :

01/04/2021, durée globale du projet : 9 mois, budget total de 35 000 €

Rôle : participation au montage et à la réalisation du projet.

L'objectif du projet est de développer une plate-forme basée sur l'intelligence artificielle pour prédire les tendances des produits à venir et leur comportement pour les prochaines saisons.

5. Projet intitulé "OTPCD" (2021-2025) : Optimisation d'un outil d'évaluation pour la filière textile-habillement : ver des modes de production et de consommation plus durables, financement CIFRE. Date de début du projet : 01/10/2021, durée globale du projet : 4 ans, budget total de 195 000 € . Financement d'une thèse pour l'ENSAIT, Mme. Léa Catteau

Rôle : participation au montage et à la réalisation du projet.

L'objectif du projet OTPCD est de développer un outil d'évaluation pour la filière textile-habillement vers des modes de production et de consommation plus durables avec intelligence artificielle et données massives combinant des niveaux de connaissances humaines expertes issues de professionnels et scientifiques de la chaîne d'approvisionnement textile, des sciences de gestion (comportements d'achat, appropriation et perception des consommateurs, traduction sémantique des termes scientifiques en lien avec la responsabilité sociale de l'entreprise, normalisation, etc.), et non expertes, ainsi que des données physiques issues de la caractérisation des produits textiles sur les aspects liés à la durabilité des produits.

6. Projet intitulé SEHFL (Secure and Explainable Healthcare with Federated learning) financé par le programme Réseau 3i : collaborations transfrontalières de l'I-SITE ULNE

Date de début du projet : 01/09/2021, budget total de 8000 €

Rôle : Coordinateur

L'objectif du projet est de renforcer des collaborations transfrontalières en organisant des événements, séminaires, réunions, colloques avec l'Université du Kent, Royaume-Uni.

1.7 Liste de la production scientifique

La tableau 1.4 présente la synthèse des publications scientifiques.

— *Source (dernière consultation le 01/03/2020) : https://clarivate.com/webofsciencigroup/wp-content/uploads/sites/2/dlm_uploads/2019/08/JCR_Full_Journal_list140619.pdf Note concernant la liste des publications.

Les co-auteurs des publications sont :

- les étudiants co-encadrés en thèse (Z. He, F. Zaidi, A.A. Nadi, T.T.V. Nguyen, QU Khaliq), en postdoc (H.D. Nguyen, Q.T. Nguyen), en master (P.B.Ta, M.L. Dao, B.D. Thang, N.T. Binh, D.L. Tran, M.D. Nguyen, A.Q. Le, D.T. Bui, T. N. Tran).
- des membres permanents du laboratoire GEMTEX (Pr X. Zeng, Pr. P. Bruniaux , Pr. L. Koehl, and Dr. G. Tartare) ou de laboratoires externes (Pr. P. Castagliola, Pr. C. Heuchenne , Pr. G. Celano, Pr. N.Balakrishnan, Pr. S. Knoth, Pr. P. D. Ho, Ms. P.H. Tran, ...).
- Les étudiants encadrés sont soulignés.
- * : auteur correspondant

1.7.1 Articles dans des revues internationales avec comité de lecture indexés JCR

- P1 . P.H.Tran and K.P.Tran (2016), "The efficiency of CUSUM schemes for monitoring the coefficient of variation", Applied Stochastic Models in Business and Industry, 32(6), 870-881, <https://doi.org/10.1002/asmb.2213>
- P2 . K.P.Tran*, P.Castagliola and N.Balakrishnan (2017),"On the performance of shewhart median chart in the presence of measurement errors", Quality and Reliability Engineering International, 33(5), 1019-1029, <https://doi.org/10.1002/qre.2087>
- P3 . K.P. Tran*, S. Knoth (2017), "Steady-state ARL analysis of ARL-unbiased EWMA-RZ control chart monitoring the ratio of two normal variables", Quality and Reliability Engineering International, 34(3), 377-390, <https://doi.org/10.1002/qre.2259>
- P4 . K.P.Tran*. (2017), "Run rules median control charts for monitoring process mean in manufacturing", Quality and Reliability Engineering International,33(8), 2437-2450, <https://doi.org/10.1002/qre.2201>
- P5 . K.P. Tran*. (2018), "Designing of Run Rules t control charts for Monitoring Changes in the Process Mean", Chemometrics and Intelligent Laboratory Systems, 174, 85-93, <https://doi.org/10.1016/j.chemolab.2018.01.009>
- P6 . P. Castagliola, K.P. Tran, G. Celano, A.C. Rakitzis and P. Maravelakis (2019), "An EWMA-Type Sign Chart with Exact Run Length Properties", Journal of Quality Technology, 51(1), 51-63, <https://doi.org/10.1080/00224065.2018.1545497>
- P7 . P.H. Tran, K.P. Tran* and A.C. Rakitzis (2019), "A Synthetic median control chart for monitoring the process mean with measurement errors", Quality and Reliability Engineering International, 35(4), 1100-1116, <https://doi.org/10.1002/qre.2447>
- P8 . **H.D. Nguyen, Q.T. Nguyen**, K.P. Tran, P. D. Ho (2019), "On the Performance of VSI Shewhart control chart for monitoring the Coefficient of Variation in the Presence of Measurement Errors", Journal of Advanced Manufacturing Technology, 104(1-4), 211-243, <https://doi.org/10.1007/s00170-019-03352-7>
- P9 . V. Giner-Bosch, K.P. Tran, P. Castagliola, M.B.C. Khoo "An EWMA Control Chart for the Multivariate Coefficient of Variation", Quality and Reliability Engineering International, 35(6), 1515-1541 <https://doi.org/10.1002/qre.2459>
- P10 . Q.T. Nguyen, K.P. Tran*, P Castagliola, G. Celano, S. Lardjane (2019), "One-Sided Synthetic control charts for monitoring the Multivariate Coefficient of Variation", Journal of Statistical Computation and Simulation, 89(10), 1841-1862, <https://doi.org/10.1080/00949655.2019.1600694>
- P11 . **F.Zaidi**, P.Castagliola, K.P.Tran, M.C.Khoo(2019), "Performance of the hotelling T2 control chart for compositional data in the presence of measurement errors", Journal of Applied Statistics, 46(14), 2583-2602, <https://doi.org/10.1080/02664763.2019.1605339>
- P12 . **Q.T. Nguyen**, K.P. Tran, C. Heuchenne, T.H. Nguyen, **H.D. Nguyen** (2019), "Variable Sampling Interval Shewhart control charts for monitoring the Multivariate Coefficient of Variation ", Applied Stochastic Models in Business and Industry, 35(5), 1253-1268, <https://doi.org/10.1002/asmb.2472>

- P13 . K.P. Tran*, **H.D. Nguyen**, P.H. Tran, C. Heuchenne (2019), "On the Performance of CUSUM control charts for monitoring the Coefficient of Variation with Measurement Errors", Journal of Advanced Manufacturing Technology, 104(5-8), 1903-1917, <https://doi.org/10.1007/s00170-019-03987-6>
- P14 . **H.D. Nguyen**, K.P. Tran* and C. Heuchenne (2019), "Monitoring the ratio of two normal variables using variable sampling interval exponentially weighted moving average control charts". Quality and Reliability Engineering International, 35(1), 439-460, <https://doi.org/10.1002/qre.2412>
- P15 . K.P. Tran*, C. Heuchenne, and N. Balakrishnan (2019), "On the performance of coefficient of variation charts in the presence of measurement errors". Quality and Reliability Engineering International, 35(1), 329-350, <https://doi.org/10.1002/qre.2402>
- P16 . **H.D. Nguyen**, K.P. Tran and C. Heuchenne (2019), "CUSUM control charts with Variable Sampling Interval for monitoring the ratio of two normal variables", Quality and Reliability Engineering International, 36(2), 474-497. <https://doi.org/10.1002/qre.2595>
- P17 . **Z. He**, K.P. Tran, S. Thomassey, X. Zeng and C. Yi (2019), "Modeling Color Fading Ozonation of Reactive-Dyed Cotton Using Extreme Learning Machine, Support Vector Regression and Random Forest", Textile Research Journal, 90(7-8), 896-908. <https://doi.org/10.1177/0040517519883059>
- P18 . **H.D. Nguyen**, K.P. Tran and T.N. Goh (2020), "Variable Sampling Interval Control Charts for Monitoring the Ratio of Two Normal Variables" , Journal of Testing and Evaluation, 48(3). <https://doi.org/10.1520/JTE20190327>
- P19 . **H.D. Nguyen**, K.P. Tran, G. Celano, P.E. Maravelakis, P. Castagliola (2020). "On the effect of the Measurement Error on Shewhart-t and EWMA-t Control Charts". Accepted for publication in International Journal of Advanced Manufacturing Technology, 107(9), 4317-4332. <https://doi.org/10.1007/s00170-020-05222-z>
- P20 . **H.D. Nguyen** and K.P. Tran* (2020), "Effect of the measurement errors on two one-sided Shewhart control charts for monitoring the ratio of two normal variables" Quality and Reliability Engineering International, 36(5), 1731-1750. <https://doi.org/10.1002/qre.2656>
- P21 . K.D. Tran, **H.D. Nguyen**, T.H. Nguyen, K.P. Tran (2020), "Design of a Variable Sampling Interval EWMA Median Control Chart in Presence of Measurement Errors" Quality and Reliability Engineering International, 37(1), 374-390. <https://doi.org/10.1002/qre.2726>
- P22 . **F. Zaidi**, P. Castagliola, K.P. Tran, M.C. Khoo (2020), "Performance of the MEWMA-CoDa Control Chart in the Presence of Measurement Errors" Quality and Reliability Engineering International, 36(7), 2411-2440. <https://doi.org/10.1002/qre.2705>
- P23 . **H. D. Nguyen**, K. P. Tran*, S. Thomassey, M. Hamad (2020), "Forecasting and Anomaly Detection approaches using LSTM and LSTM Autoencoder techniques with the applications in Supply Chain Management", International Journal of Information Management, 57, 102282. <https://doi.org/10.1016/j.ijinfomgt.2020.102282>
- P24 . **H. D. Nguyen**, K. P. Tran*, D. Tran (2020), "The effect of measurement errors on the performance of the Exponentially Weighted Moving Average control

- charts for the Ratio of Two Normally Distributed Variables", European Journal of Operational Research, 293(1), 203-218. <https://doi.org/10.1016/j.ejor.2020.11.042>
- P25 . **Z. He**, K.P. Tran, S. Thomassey, X. Zeng and C. Yi (2020), "A deep reinforcement learning based multi-criteria decision support system for optimizing textile chemical process", Computers in Industry, 125 (2021) : 103373. <https://doi.org/10.1016/j.compind.2020.103373>
- P26 . **Z. He**, K.P. Tran, S. Thomassey, X. Zeng and C. Yi (2021), "Multi-Objective Optimization of the Textile Manufacturing Process Using Deep-Q-Network Based Multi-Agent Reinforcement Learning", Journal of Manufacturing Systems , in press, <https://doi.org/10.1016/j.jmsy.2021.03.017>
- P27 . **Q T Nguyen**, V Giner-Bosch, K D Tran, C Heuchenne , K.P. Tran (2021). "One-sided Variable Sampling Interval EWMA Control Charts for Monitoring the Multivariate Coefficient of Variation in the Presence of Measurement Errors", International Journal of Advanced Manufacturing Technology, in press, <https://doi.org/10.1007/s00170-021-07138-8>
- P28 . **Z. He**, J.Xu, K.P. Tran, S. Thomassey, X. Zeng and C. Yi (2021), "Modeling of textile manufacturing processes using intelligent techniques : a review", International Journal of Advanced Manufacturing Technology, 116,39-67 , <https://doi.org/10.1007/s00170-021-07444-1>
- P29 . T.H. Truong, **P.B.Ta**, **M.L. Dao**, **D.L. Tran**, **M.D. Nguyen**, **A.Q. Le**, **D.T. Bui**, K.P. Tran (2021), "Detecting Cyberattacks using Anomaly Detection in Industrial Control Systems : A Federated Learning approach ", Computers in Industry, 132, 103509, <https://doi.org/10.1016/j.compind.2021.103509>
- P30 . K.D.Tran, **QU Khaliq**, **AA Nadi**, K.D.Tran, K.P. Tran* (2021), "One-sided Shewhart control charts for monitoring the ratio of two normal variables in Short Production Runs", Journal of Manufacturing Processes, 69,273-289, <https://doi.org/10.1016/j.jmapro.2021.07.031>
- P31 . T.T. Huong, **P.B.Ta**, **M.L. Dao**, **B.D. Thang**, **N.T. Binh**, **D.L. Tran**, K.P. Tran (2021), "LockEdge : Low-Complexity Cyberattack Detection in IoT Edge Computing", IEEE Access, 29696-29710, <https://doi.org/10.1109/ACCESS.2021.3058528>
- P32 . K.P.Tran (2021). Artificial Intelligence for Smart Manufacturing : Methods and Applications. Sensors, 21, 5584, <https://doi.org/10.3390/s21165584>
- P33 . **A. Raza**, K.P. Tran, L. Koehl, and S. Li (2022), "Designing ECG Monitoring Healthcare System with Federated Transfer Learning and Explainable AI". Knowledge-Based Systems, 236,107763, <https://doi.org/10.1016/j.knosys.2021.107763>

1.7.2 Articles dans des revues internationales avec comité de lecture non indexés JCR

- p1 . K.P. Tran* (2016), "The efficiency of the 4-out-of-5 Runs Rules scheme for monitoring the Ratio of Population Means of a Bivariate Normal distribution", International Journal of Reliability, Quality and Safety Engineering, 23(05),1650020, <https://doi.org/10.1142/S0218539316500200>
- p2 . K.P.Tran, P. Castagliola, T.H.Nguyen, A.Cuzol (2019),"Design of a Variable

Sampling Interval EWMA Median Control Chart", International Journal of Reliability, Quality and Safety Engineering, In press, <https://doi.org/10.1142/S0218539319500219>

- p3 . T.H. Truong, **P.B. Ta**, Q. T. Nguyen, **H.D. Nguyen**, K.P. Tran (2019), "A data-driven approach for Network Intrusion Detection and Monitoring based on Kernel Null Space", Industrial Networks and Intelligent Systems, In press, <https://doi.org/10.4108/eai.13-6-2019.159801>
- p4 . **H.D. Nguyen**, Q. T. Nguyen, T. H., N. Nguyen, Balakrishnan, , K. P. Tran (2020). "The Performance of the EWMA Median Chart in the Presence of Measurement Error", Artificial Intelligence Evolution, 48-62. <https://doi.org/10.37256/aie.112020401>

1.7.3 Ouvrages individuels et direction d'ouvrages collectifs

- O1 . K.P. Tran (2021). Control Charts and Machine Learning for Anomaly Detection in Manufacturing, Springer Nature Switzerland AG, <https://www.springer.com/gp/book/9783030838188>
- O2 . K.P. Tran (2021). Machine Learning and Probabilistic Graphical Models for Decision Support Systems, Taylor & Francis / CRC Press, USA, forthcoming.
- O3 . K.P. Tran (2022). Artificial Intelligence for Smart Manufacturing : Methods, Applications, and Challenges, Springer Nature Switzerland AG, forthcoming.

1.7.4 Chapitres d'ouvrage

- B1 . P. Castagliola, K.P. Tran, G. Celano, and P. Maravelakis (2019), "The Shewhart Sign Chart with Ties : Performance and Alternatives". In Distribution-free Methods for Statistical Process Monitoring and Control, Springer Nature Switzerland, accepted, https://doi.org/10.1007/978-3-030-25081-2_3
- B2 . **H.D. Nguyen**, K.P. Tran*, X. Zeng, L. Koehl, and G. Tartare (2019), "An Improved Ensemble Machine Learning algorithm for Wearable Sensor Data Based Human Activity Recognition". In Reliability and Statistical Computing, Springer Nature Switzerland AG, 207-228, https://doi.org/10.1007/978-3-030-43412-0_13
- B3 . **Z. He**, K.P. Tran, S. Thomassey, X. Zeng and C. Yi (2019), "Application of Artificial Intelligence in modeling a textile finishing process". In Reliability and Statistical Computing, Springer Nature Switzerland AG, accepted, https://doi.org/10.1007/978-3-030-43412-0_5
- B4 . P.H. Tran, K.P. Tran*, C. Heuchenne and **H.D. Nguyen** (2021), "Monitoring Coefficient of Variation using CUSUM control charts". In Handbook of Engineering Statistics, 2nd ed , Springer US, accepted.
- B5 . P.H. Tran, **A. A. Nadi**, T.H. Nguyen, K.D. Tran, and K.P. Tran (2021), "Application of Machine Learning in Statistical Process Control Charts : A Survey and Perspective". In Control Charts and Machine Learning for Anomaly Detection in Manufacturing, Springer Nature Switzerland, 7-42, https://doi.org/10.1007/978-3-030-83819-5_2
- B6 . K.P. Tran (2021), "Introduction to Control Charts and Machine Learning for Anomaly Detection in Manufacturing". In Control Charts and Machine Learning

- for Anomaly Detection in Manufacturing, Springer Nature Switzerland, 1-6, https://doi.org/10.1007/978-3-030-83819-5_1-
- B7 . **Q. T. Nguyen, T N. Tran**, C. Heuchenne, and K. P. Tran (2021), “Decision Support Systems for Anomaly Detection with the Applications in Smart Manufacturing : a survey and perspective”. In Machine Learning and Probabilistic Graphical Models for Decision Support Systems, Taylor & Francis / CRC Press, accepted.
- B8 . **T .T. V . Nguyen**, C. Heuchenne, and K. P. Tran (2021), “Machine learning for compositional data analysis in Support of the Decision Making Process”. In Machine Learning and Probabilistic Graphical Models for Decision Support Systems, Taylor & Francis / CRC Press, accepted.
- B9 . **H. D. Nguyen**, and K. P. Tran (2021), “Decision Support System using LSTM with Bayesian optimization for Predictive Maintenance : Remaining Useful Life Prediction”. In Machine Learning and Probabilistic Graphical Models for Decision Support Systems, Taylor & Francis / CRC Press, accepted.
- B10 . T. H. Nguyen, **H. D. Nguyen** , D. D. K. Nguyen, K .D. Tran, and K. P. Tran (2021), “Enabling Smart Supply Chain Management with Artificial Intelligence”. In Machine Learning and Probabilistic Graphical Models for Decision Support Systems, Taylor & Francis / CRC Press, accepted.
- B11 . **H. D. Nguyen**, K. P. Tran, P. Castagliola, and F. M. Megahed (2021), “Enabling smart manufacturing with Artificial Intelligence and Big Data : a survey and perspective”. In Manufacturing Methods for Mechanical Engineering and Microwave Devices, Taylor & Francis / CRC Press, accepted.
- B12 . Z. Lu, **Z. He**,K.P. Tran, S. Thomassey,X. Zeng, and M. Hongd (2021), "Decision Support Systems for Textile Manufacturing Process with Machine Learning". In Machine Learning and Probabilistic Graphical Models for Decision Support Systems, Taylor & Francis / CRC Press, accepted.

1.7.5 Communications avec comité de lecture et avec acte dans un congrès international

- C1 . V.V. Trinh, K.P. Tran and A.T. Mai. (2017), “Anomaly Detection in Wireless Sensor Networks via Support Vector Data Description with Mahalanobis Kernels and Discriminative Adjustment”, 3th IEEE Conference on Information and Computer Science, Hanoi, Vietnam, November 24-25, 2017, <https://doi.org/10.1109/NAFOSTED.2017.8108030>
- C2 . V.V. Trinh, K.P. Tran and T.H. Truong. (2017), “Data driven hyperparameter optimization of one-class support vector machines for anomaly detection in wireless sensor networks”, IEEE International Conference on Advanced Technologies for Communications, Quy Nhon, Vietnam, October 18-20, 2017, <https://doi.org/10.1109/ATC.2017.8167642>
- C3 . P.H. Tran K.P. Tran, T.H. Truong C. Heuchenne, T.A.D. Nguyen and C.N Do. (2018), “A Variable Sampling Interval EWMA distribution-free control chart for monitoring services quality”, In 2018 International Conference on E-Business and Applications (ICEBA 2018) <https://doi.org/10.1145/3194188.3194191>
- C4 . P.H. Tran K.P. Tran, T.H. Truong , C. Heuchenne, P.H. Tran and T.H. Le (2018), "Real Time Data-Driven approaches for Credit Card Fraud Detection",

- In 2018 International Conference on E-Business and Applications (ICEBA 2018)
<https://www.doi.org/10.1145/3194188.3194196>
- C5 . K.P. Tran **H. D. Nguyen**, Q. T. Nguyen, and W. Chattinnawat (2018)
"One-Sided synthetic control charts for monitoring the Coefficient of Variation with Measurement Errors", In proceedings of The IEEE International Conference on Industrial Engineering and Engineering Management, 16-19 December, 2018, Bangkok, Thailand, <https://doi.org/10.1109/IEEM.2018.8607320>
- C6 . **Q.T. Nguyen**, K.P. Tran*, P. Castagliola, T.T. Huong, M.K. Nguyen, S. Lardjane. "Nested One-Class Support Vector Machines for Network Intrusion Detection". Proceedings of the Seventh IEEE International Conference on Communications and Electronics (ICCE), Hue, Vietnam, 18-20 July, 2018, <https://doi.org/10.1109/CCE.2018.8465718>
- C7 . K.P. Tran, P. Castagliola, T.H. Nguyen, A. Cuzol. "The Efficiency of the VSI Exponentially Weighted Moving Average Median Control Chart". Proceedings of the 24th ISSAT International Conference on Reliability and Quality in Design, pages 203-208, ISBN : 978-0-9910576-5-8, Toronto, ON, Canada, August 2018.
- C8 . T.H. Nguyen, **H.D.Nguyen**, K.D.Tran, T.N. Nguyen, L.H. Nguyen, T.H. Truong, K.H. Phung and K.P. Tran. (2019), "One-Sided Synthetic-RZ Control Charts : a New Method for Anomaly Detection", 6th IEEE Conference on Information and Computer Science, Hanoi, Vietnam, December 12-13, 2019, <https://ieeexplore.ieee.org/abstract/document/9023851/>
- C9 . **Q.T. Nguyen**, **H.D.Nguyen**, K.P.Tran, P.Castagliola, and E.Frénod. "Real-Time Production Monitoring approach for Smart Manufacturing with Artificial Intelligence techniques", ISSAT International Conference on Data Science in Business, Finance and Industry (DSBFI2019),Danang, Vietnam, July 3-5, 2019
- C10 . K.P. Tran*, **H.D. Nguyen**, S. Thomassey. "Anomaly detection using Long Short Term Memory Networks and its applications in Supply Chain Management", 9th IFAC Conference on Manufacturing Modelling, Management and Control, Berlin, Germany, August 28-30, 2019, <https://www.sciencedirect.com/science/article/pii/S240589631931554X>
- C11 . **H.D. Nguyen**, K.P. Tran*, X. Zeng, L. Koehl, P. Castagliola , and P. Bruniaux. "Industrial Internet of Things, Big Data, and Artificial Intelligence in a Smart Factory : a survey and perspective", ISSAT International Conference on Data Science in Business, Finance and Industry (DSBFI2019),Danang, Vietnam, July 3-5, 2019
- C12 . **H.D. Nguyen**, K.P. Tran*. "Wearable Sensor Data Based Human Activity Recognition using Machine Learning : A new approach", ISSAT International Conference on Data Science in Business, Finance and Industry (DSBFI 2019), Danang, Vietnam, July 3-5,2019
- C13 . **Z.He**, K.P.Tran, S.Thomassey, X.Zeng and C.Yi" Modeling Color Fading Ozonation of Textile Using Artificial Intelligence", ISSAT International Conference on Data Science in Business, Finance and Industry (DSBFI 2019), Danang, Vietnam, July 3-5, 2019 [
- C14]. T.H. Truong, **B. Ta**, Q. T. Nguyen, **H.D. Nguyen**, K.P. Tran (2019), "A data-driven approach for Network Intrusion Detection and Monitoring based on Kernel Null Space", INISCOM 2019 – 5th EAI International Conference on Industrial Networks and Intelligent Systems,Vietnam, August, 192019 2018,

	Bilan de la production scientifique
Ouvrages individuels et direction d'ouvrages collectifs	3
Chapitres d'ouvrages scientifiques	12
Articles dans des revues internationales avec comité de lecture indexées JCR*	33
Articles dans des revues avec comité de lecture non indexées JCR*	4
Communications avec comité de lecture avec actes dans un congrès international	18
Communications orales avec comité de lecture sans acte dans un congrès international ou national	3
Communications par affiche dans un congrès international	0

TABLEAU 1.4 – Bilan de la production scientifique

https://doi.org/10.1007%2F978-3-030-30149-1_11

- C15 . P .H. Tran, **Q.T. Nguyen**, K.P. Tran, K. P and C. Heuchenne. (2020, September). Wearable Sensor Data Based Human Activity Recognition using Deep Learning : A new approach. In FLINS/ISKE 202-0, Germany, August 18-21 , 2020, https://www.worldscientific.com/doi/abs/10.1142/9789811223334_0070
- C16 . **Z. He**, K.P. Tran, S. Thomassey, X. Zeng, C. Yi (2020). A reinforcement learning based decision support system in textile manufacturing process. In FLINS/ISKE 2020, Germany, August 18-21, 2020, https://www.worldscientific.com/doi/10.1142/9789811223334_0066
- C17 . P.H. Tran, A.C. Rakitzis, **H.D. Nguyen**, **Q.T. Nguyen**, H. Tran, K. P. Tran, and C. Heuchenne, "New Methods for Anomaly Detection : Run Rules Multivariate Coefficient of Variation Control Charts ", In Proceedings of the 2020 International Conference on Advanced Technologies for Communications. Nha Trang, Vietnam October 08 – 10, 2020, <https://ieeexplore.ieee.org/document/9255479>
- C18 . **R. Sleiman**, A. Mazyad, K.P. Tran, S. Thomassey, H. Moez (2021), Long term demand forecasting system for demand driven manufacturing . In APMS 2021 International conference Advances in Production Management Systems, Nantes, France, https://link.springer.com/chapter/10.1007/978-3-030-85874-2_2

1.7.6 Communications orales avec comité de lecture sans acte dans un congrès international ou national

- 1. K.P. Tran (2018), “Advanced Statistical Process Control, Big Data and Machine learning : a perspective”, International Symposium on Business and Industrial Statistics (ISBIS) 2018, University of Piraeus, Greece, 4-6 July 2018.(Invited talk)
- 2. K. P. Tran (2021), "Forecasting and Anomaly Detection approaches using LSTM and LSTM Autoencoder techniques with the applications in Supply Chain Management", The 4th Int'l Conference on Machine Learning, Pattern Recognition and Intelligent Systems (MLPRIS 2021), July 16-18, 2021 in Kunming, China. (Keynote Speech)
- 3. K.P. Tran (2021), “Advanced Statistical Process Control, Big Data and Machine learning : a perspective”, International Webinar on Artificial Intelligence and Data Science with Applications 2021, Dong A University, Vietnam, 20 December 2021. (Invited talk)

1.8 Thème de recherche

Cette thèse est une synthèse de mes travaux de recherche, faisant suite à ma thèse en 2016. Avant l'intégration dans ENSAIT, GEMTEX, j'ai eu 5 ans d'expérience en tant qu'enseignant chercheur en Automatique à l'Université Phan Chau Trinh et l'Université de Dong A, Vietnam durant la période 2009-2014 et 2 ans d'expérience en recherche en tant que post-doctorant au GIPSA-lab, UMR 5216 CNRS et LMBA, UMR 6205 CNRS, France ainsi que chercheur invité au département science des données de l'université TDT et Université de Dong A, Vietnam durant la période 2016-2018. En 2018, j'ai intégré le laboratoire GEMTEX, notamment dans le groupe HCD (Human-Centered Design). L'association avec des collègues HDR de différentes spécialités du laboratoire (Pr. Xianyi Zeng, Pr. Ludovic Koelh, et Dr. Sébastien Thomassey) lors de co-encadrements et de co-direction de chercheurs en thèse m'ont permis d'enrichir mes thématiques de recherche : optimiser la production industrielle avec l'intelligence artificielle, prévision et détection d'anomalies dans la gestion de la chaîne d'approvisionnement de la mode avec des techniques d'apprentissage automatique, les problématiques liées au développement du système de santé intelligent. En outre, avec des projets collaboratifs avec mes partenaires vietnamiens, Hanoi University of Science & Technology (HUST) et l'Université de Dong A, et des collègues de GIS CybCom, j'ai développé une nouvelle direction de recherche sur la cybersécurité dans les systèmes industriels. Enfin, les relations de coopération internationale sont également renforcées lors des recherches menées à GEMTEX. Par exemple, grâce à la coopération internationale avec l'université de Liège, Belgique, en particulier le professeur Cédric Heuchenne, nous avons co-encadré 2 post-doctorants et publié 9 articles issus de projets collaboratifs, une thèse de cotutelle avec l'université de Liège est prévue en 2022. Une relation avec l'université du Kent, UK a également été établie, une thèse cotutelle est mis en œuvre à partir de septembre 2020 avec le financement d'un projet de ma part pour lequel je suis coordinateur. Mes travaux de recherche après la thèse de doctorat se sont articulés selon cinq thèmes principaux :

- Contributions à la carte de contrôle et l'apprentissage automatique pour la détection d'anomalies dans la fabrication
- Contributions à la modélisation et l'optimisation de la production avec l'apprentissage automatique et l'apprentissage par renforcement
- Contributions à la prévision et la détection d'anomalies dans la gestion de la chaîne d'approvisionnement avec des techniques d'apprentissage automatique
- Contributions à la cybersécurité assurée à travers la détection d'anomalies avec des techniques d'apprentissage automatique
- Contributions à la surveillance pour les systèmes de santé intelligents avec des techniques d'apprentissage fédéré

En termes d'enseignement, j'ai progressivement fait évoluer les disciplines enseignées afin d'avoir à ce jour un contenu en parfaite adéquation avec mes activités de recherche. L'expérience acquise sur mes thématiques de recherche me permet d'envisager aujourd'hui de conduire le développement de ces axes avec une équipe pérenne et efficace au sein de mon laboratoire d'accueil. J'ai été essayé d'équilibrer des tâches et responsabilités : activités pédagogiques, encadrement doctorat, et responsabilités et rayonnement scientifiques.

1.9 Plan du mémoire

L'apport scientifique de la thèse est brièvement présenté dans la Figure 1.1. Dans le chapitre 2, nous présentons les contributions à la carte de contrôle et l'apprentissage automatique pour la détection d'anomalies dans la fabrication. Le chapitre 3 détaille les contributions à la modélisation et l'optimisation pour la fabrication textile avec l'apprentissage automatique et l'apprentissage par renforcement. Le chapitre 4 présente la prévision et la détection d'anomalies dans la gestion de la chaîne d'approvisionnement avec des techniques d'apprentissage automatique. Dans le chapitre 5, nous abordons les contributions à la cybersécurité assurée à travers la détection d'anomalies avec des techniques d'apprentissage automatique. Le chapitre 6 s'intéressera à la surveillance pour les systèmes de santé intelligents avec des techniques d'apprentissage fédéré. Enfin, nous présentons une conclusion générale ainsi que quelques perspectives en fin de manuscrit dans le chapitre 7.

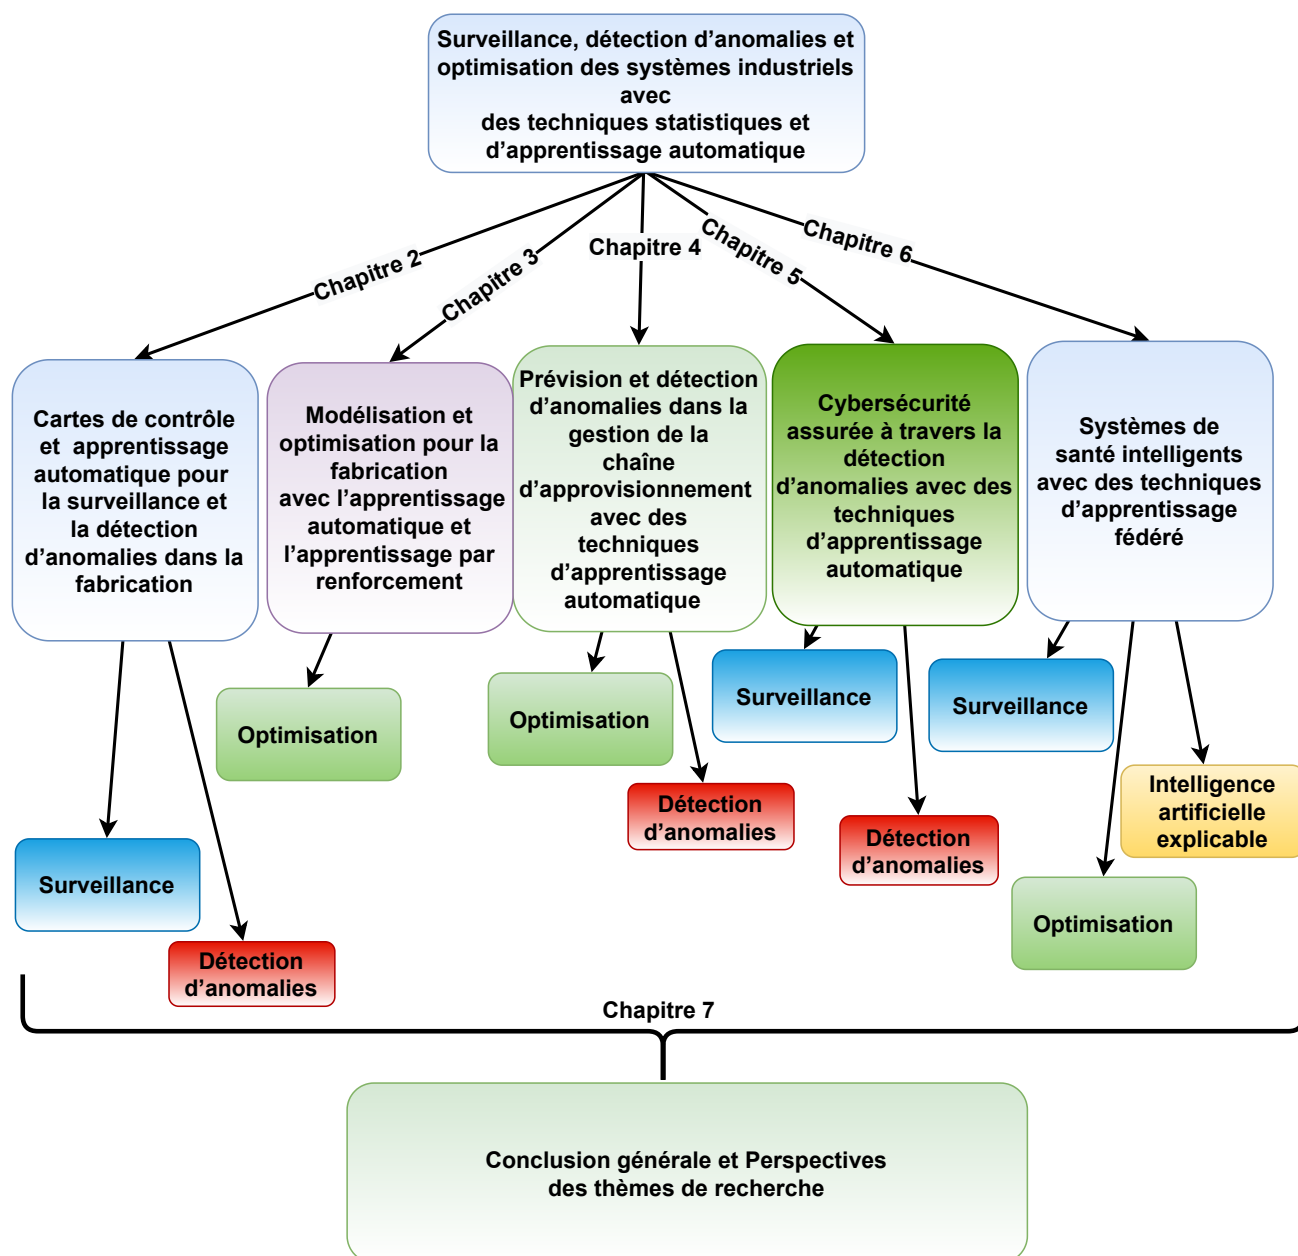


FIGURE 1.1 – Plan du mémoire.

Chapitre 2 :

Contributions à la carte de contrôle et l'apprentissage automatique pour la surveillance et la détection d'anomalies dans la fabrication

2.1 Introduction

La détection d'anomalies est un ensemble de techniques majeures visant à détecter des événements rares ou des observations qui s'écartent du comportement normal. La surveillance des processus et la détection des anomalies deviennent de plus en plus importantes pour améliorer la fiabilité et la productivité de la fabrication en détectant les anomalies à un stade précoce. Par exemple, un niveau de vibration dans un moteur électrique dépassant le seuil admissible peut être considéré comme une anomalie, il pourrait ne pas être considéré comme un défaut. Cependant, si le niveau de vibration continue d'augmenter et conduit à la destruction du moteur, il peut être considéré comme défectueux. Par conséquent, la détection d'anomalies peut offrir des avantages aux entreprises de fabrication en réduisant leurs temps d'arrêt dus aux pannes de machines en détectant une défaillance avant que cela n'entraîne un événement catastrophique pouvant entraîner une dégradation du processus et du produit [10]. Il existe diverses approches basées sur des données et des modèles pour détecter les anomalies survenant dans les systèmes de fabrication. L'approche la plus courante de la détection d'anomalies comprend les cartes de contrôle et les méthodes d'apprentissage automatique (en anglais Machine Learning, ML) qui est une forme d'intelligence artificielle (IA, ou AI en anglais pour Artificial Intelligence). Il existe de nombreux types de cartes de contrôle qui ont été développés à cet effet. De plus, les méthodes d'apprentissage automatique ont été beaucoup utilisées pour détecter des anomalies avec différentes applications dans la fabrication, telles que la détection d'attaques de réseau, la détection d'états anormaux dans les machines. Enfin, l'interférence de ces deux techniques se retrouve également dans la littérature telle que la conception de cartes de contrôle, l'interprétation de signaux d'anomalie et la reconnaissance de formes dans les cartes de contrôle à l'aide de techniques d'apprentissage automatique.

Ces dernières années, le développement rapide et la large application des technologies de pointe ont profondément impacté la fabrication industrielle. Le développement récent des technologies de l'information et de la communication telles que les réseaux de capteurs intelligents et l'Internet des objets (Internet of Things ou IoT en anglais) a engendré le concept de fabrication intelligente (Smart Manufacturing ou SM en anglais) qui ajoute de l'intelligence au processus de fabrication pour favoriser l'amélioration continue, le transfert de connaissances et l'utilisation des données pour la prise de décision. Dans ce contexte, le volume et la qualité croissants des données de production facilitent l'extraction d'informations significatives, prédisant des états futurs du système de fabrication qui seraient impossibles à obtenir même par des experts humains. En raison des avancées récentes dans le domaine SPM (en anglais Statistical Process Monitoring), de nombreuses cartes de contrôle avancées ont été développées, ainsi SPM peut devenir un outil puissant pour gérer de nombreuses applications Big Data qui vont au-delà de la surveillance de production dans le contexte de SM [11]. En outre, il existe de nombreuses études sur les applications d'intelligence artificielle dans SM qui exploitent les informations précieuses contenues dans les données pour faciliter la surveillance des processus, la prédiction des défauts et la maintenance prédictive [12]. L'utilisation de plusieurs capteurs pour collecter des données pendant la fabrication améliore la surveillance et la prise de décision en temps réel, mais la qualité des données doit également être garantie avant de les utiliser. Dans ce cas, nous pouvons utiliser

des algorithmes de détection d'anomalies pour supprimer les valeurs aberrantes dans l'ensemble de données. Il s'agit de la première application des algorithmes de détection d'anomalies dans la fabrication intelligente, en outre, il est également beaucoup utilisé dans différents aspects des opérations de fabrication tels que la détection d'anomalies dans les opérations de machine, la détection d'attaques dans les systèmes industriels, la détection d'anomalies mécaniques avant qu'elles n'affectent la qualité du produit, ... Par conséquent, la détection d'anomalies joue un rôle très important dans la fabrication intelligente. Lopez et al. [13] ont catégorisé les anomalies dans les machines, les contrôleurs et les réseaux ainsi que leurs mécanismes de détection, et les unifie sous un cadre commun pour permettre l'identification des lacunes dans la détection des anomalies dans les systèmes fabrication intelligente qui devraient être traitées dans les futures études de solutions.

En résumé, les connaissances existantes sur la détection d'anomalies avec des applications dans la fabrication sont classées comme apprentissage automatique et approche statistique. L'approche statistique de détection d'anomalies comme les cartes de contrôle peut être développée avec peu d'effort de calcul. Cependant, leur efficacité a été prouvée au cours d'une longue période d'application industrielle. Par conséquent, un effort devrait être fait pour développer des cartes de contrôle avancées pour une application dans des contextes industriels modernes, voir [14], [11] et [15] pour quelques exemples. Cependant, dans les contextes fabrication intelligente où les hypothèses sur la distribution et l'indépendance des données sont violées, les méthodes de détection d'anomalies entreront en jeu, bien qu'elles nécessitent des efforts de calcul et des ressources considérables. Par exemple, Nguyen et al. [4] a développé un nouveau modèle hybride profond pour la détection d'anomalies pour des séries chronologiques multivariées sans utiliser aucune hypothèse pour la distribution des erreurs de prédiction. L'autoencodeur LSTM (réseaux à mémoire longue et courte durée ou Long Short Term Memory Network en anglais) est utilisé comme extracteur de caractéristiques pour extraire des représentations importantes de l'entrée de séries chronologiques multivariées, puis ces caractéristiques sont entrées dans un OCSVM (en anglais One Class Support Vector Machine) pour détecter les anomalies. Ce modèle se traduit par de meilleures performances par rapport aux performances de plusieurs études précédentes. Par conséquent, des efforts sont nécessaires pour développer des méthodes de détection d'anomalies d'apprentissage automatique adaptées aux applications en fabrication intelligente. Enfin, il existe des études qui combinent les deux techniques pour développer des méthodes hybrides pour combiner les forces des deux techniques [16, 17]. Ce chapitre présente nos contributions sur les cartes de contrôle avancées et les nouvelles approches d'apprentissage automatique pour la détection d'anomalies dans le processus de fabrication et en particulier dans les contextes de fabrication intelligente.

2.2 Cartes de contrôle pour surveiller le ratio de deux variables aléatoires et des données de composition

Dans l'industrie, il existe plusieurs scénarios dans lesquels le ratio de deux grandeurs est la caractéristique d'intérêt [18]. En particulier, dans le cas multivarié, une carte de contrôle pour surveiller des données de composition (en anglais Compositional Data, CoDa) sont vu comme une extension des cartes de contrôle ratio. Dans cette sous-section, nous présenterons les principales contributions aux cartes de contrôle pour surveiller le ratio de deux variables aléatoires et des données de composition.

2.2.1 Cartes de contrôle surveillant le ratio de deux variables normales

Dans les cartes de contrôle surveillant le ratio de deux variables normales, la statistique d'intérêt est $Z = \frac{X}{Y}$, où X et Y sont deux composantes d'un vecteur aléatoire normal bivarié $\mathbf{W} = (X, Y)^T$ avec vecteur moyen $\boldsymbol{\mu}_{\mathbf{W}}$ et matrice de variance-covariance $\boldsymbol{\Sigma}_{\mathbf{W}}$, où

$$\boldsymbol{\mu}_{\mathbf{W}} = \begin{pmatrix} \mu_X \\ \mu_Y \end{pmatrix}$$

et

$$\boldsymbol{\Sigma}_{\mathbf{W}} = \begin{pmatrix} \sigma_X^2 & \rho\sigma_X\sigma_Y \\ \rho\sigma_X\sigma_Y & \sigma_Y^2 \end{pmatrix},$$

où σ_X et σ_Y sont les écarts types des deux variables aléatoires X et Y de \mathbf{W} ; $\rho \in (-1, 1)$ est le coefficient de corrélation. Soit $\gamma_X = \frac{\sigma_X}{\mu_X}$ et $\gamma_Y = \frac{\sigma_Y}{\mu_Y}$ les coefficients de variation de X et Y , respectivement, et soit $\omega = \frac{\sigma_X}{\sigma_Y}$ soit leur rapport d'écart-type. Dans cette étude, nous recourons à une approximation proposée par [19] de la fonction de distribution cumulative (en anglais cumulative distribution function, c.d.f.) de Z :

$$F_Z(z|\gamma_X, \gamma_Y, \omega, \rho) \simeq \Phi\left(\frac{A}{B}\right), \quad (2.1)$$

où $\Phi(\cdot)$ est le c.d.f. de la distribution normale standard; A et B sont des fonctions de z , γ_X , γ_Y , ω et ρ , c'est-à-dire

$$A = \frac{z}{\gamma_Y} - \frac{\omega}{\gamma_X}, \quad (2.2)$$

$$B = \sqrt{\omega^2 - 2\rho\omega z + z^2}. \quad (2.3)$$

La fonction de distribution cumulative inverse (en anglais inverse cumulative distribution function, i.d.f) $F_Z^{-1}(p|\gamma_X, \gamma_Y, \omega, \rho)$ de Z proposée par [19] est définie comme :

$$F_Z^{-1}(p|\gamma_X, \gamma_Y, \omega, \rho) \simeq \begin{cases} \frac{-C_2 - \sqrt{C_2^2 - 4C_1C_3}}{2C_1} & \text{if } p \in (0, 0.5], \\ \frac{-C_2 + \sqrt{C_2^2 - 4C_1C_3}}{2C_1} & \text{if } p \in [0.5, 1), \end{cases} \quad (2.4)$$

où C_1 , C_2 and C_3 are functions of p , γ_X , γ_Y , ω , and ρ , i.e.

$$\begin{aligned} C_1 &= \frac{1}{\gamma_Y^2} - (\Phi^{-1}(p))^2, \\ C_2 &= 2\omega \left(\rho(\Phi^{-1}(p))^2 - \frac{1}{\gamma_X \gamma_Y} \right), \\ C_3 &= \omega^2 \left(\frac{1}{\gamma_X^2} - (\Phi^{-1}(p))^2 \right). \end{aligned}$$

Pour surveiller le ratio Z , les praticiens collectent un échantillon de n couples indépendants $\{\mathbf{W}_{i,1}, \mathbf{W}_{i,2}, \dots, \mathbf{W}_{i,n}\}$ à chaque période d'échantillonnage $i = 1, 2, \dots$, où $\mathbf{W}_{i,j} = (X_{i,j}, Y_{i,j})^T \sim N(\boldsymbol{\mu}_{\mathbf{W},i}, \boldsymbol{\Sigma}_{\mathbf{W},i})$, $j = 1, \dots, n$. La statistique que nous suggérons de surveiller est le ratio des moyennes des deux échantillons lorsque les sous-groupes contiennent $n \geq 1$ unités d'échantillonnage

$$\hat{Z}_i = \frac{\hat{\mu}_{X,i}}{\hat{\mu}_{Y,i}} = \frac{\bar{X}_i}{\bar{Y}_i} = \frac{\sum_{j=1}^n X_{i,j}}{\sum_{j=1}^n Y_{i,j}}, i = 1, 2, \dots \quad (2.5)$$

Auparavant, les cartes de contrôle surveillant le ratio de deux variables aléatoires ont été discutées dans de nombreux articles. [20, 21, 18, 19, 22, 23, 22]. Les cartes EWMA (en anglais Exponentially Weighted Moving Average) et la CUMSUM (en anglais Cumulative Sum) pour le ratio sont étudiées dans [24] et [25], respectivement. Tran et al. [26] a été la première étude à considérer une carte de contrôle Shewhart-RZ en présence d'erreurs de mesure.

2.2.1.1 Surveillance du ratio de deux variables normales à l'aide de deux cartes de contrôle Shewhart unilatérales

Les deux cartes de contrôle de Shewhart unilatérales se composent d'une carte de contrôle supérieure, qui vise à détecter une augmentation du rapport (notée "Shewhart-RZ⁺"), et une carte de contrôle inférieure qui vise à détecter une diminution du ratio (noté "Shewhart-RZ⁻") [27]. Étant donné l'ARL (en anglais Average Run Length) sous-contrôle ARL_0 , la limite de contrôle inférieure LCL^- de la carte de contrôle Shewhart-RZ⁻ est définie de telle sorte que le taux d'erreur de type I est égal à α_0 où $ARL_0 = 1/\alpha_0$. Ainsi, le LCL^- est égal à

$$LCL^- = F_Z^{-1} \left(\alpha_0 \mid \frac{\gamma_X}{\sqrt{n}}, \frac{\gamma_Y}{\sqrt{n}}, \frac{z_0 \gamma_X}{\gamma_Y}, \rho_0 \right). \quad (2.6)$$

La limite de contrôle supérieure correspondante UCL^- de la carte de contrôle Shewhart-RZ⁻ est $UCL^- = +\infty$.

De même, pour de la carte de contrôle Shewhart-RZ⁺, la limite de contrôle supérieure UCL^+ est définie de telle sorte que le taux d'erreur de type I soit égal à α_0 . Cela signifie que l'UCL est égal à

$$UCL^+ = F_Z^{-1} \left(1 - \alpha_0 \mid \frac{\gamma_X}{\sqrt{n}}, \frac{\gamma_Y}{\sqrt{n}}, \frac{z_0 \gamma_X}{\gamma_Y}, \rho_0 \right), \quad (2.7)$$

La limite de contrôle inférieure correspondante LCL^+ de la carte de contrôle Shewhart-

RZ^+ est $LCL^+ = -\infty$. Dans l'implémentation de ces deux cartes de contrôle, lorsque $\hat{Z} < LCL^-$ dans la carte Shewhart- RZ^- ou lorsque $\hat{Z} > UCL^+$ dans la carte de contrôle Shewhart- RZ^+ , le processus est considéré comme hors-contrôle et les causes attribuables doivent être étudiées et supprimées. Maintenant, supposons que le ratio sous-contrôle z_0 est déplacé vers $z_1 = \tau \times z_0$, où $\tau > 0$ est l'amplitude du changement et le coefficient de corrélation sous-contrôle $\rho = \rho_0$ est décalée vers $\rho = \rho_1$ en raison d'une condition hors-contrôle. Pour la carte de contrôle de type Shewhart, l' ARL_1 (ARL hors-contrôle) est calculée par

$$ARL = \frac{1}{p} \quad (2.8)$$

où p est la probabilité de détecter des changements. Dans notre cas, la probabilité p est définie comme

— pour la carte de contrôle Shewhart- RZ^- ,

$$\begin{aligned} p &= Pr(\hat{Z}_i < LCL^-) \\ &= F_{\hat{Z}} \left(LCL^- \mid \frac{\gamma_X}{\sqrt{n}}, \frac{\gamma_Y}{\sqrt{n}}, \frac{z_0 \gamma_X}{\gamma_Y}, \rho_0 \right), \end{aligned} \quad (2.9)$$

— pour la carte de contrôle Shewhart- RZ^+ ,

$$\begin{aligned} p &= Pr(\hat{Z}_i < UCL^+) \\ &= 1 - F_{\hat{Z}} \left(UCL^+ \mid \frac{\gamma_X}{\sqrt{n}}, \frac{\gamma_Y}{\sqrt{n}}, \frac{z_0 \gamma_X}{\gamma_Y}, \rho_0 \right). \end{aligned} \quad (2.10)$$

2.2.1.2 Surveillance du ratio de deux variables normales à l'aide des cartes de contrôle EWMA à intervalle d'échantillonnage variable

Nous suggérons d'intégrer la fonction d'intervalle d'échantillonnage variable (en anglais Variable Sampling Interval, VSI) dans les cartes EWMA pour surveiller du ratio par [28]. Nous rappelons tout d'abord les cartes de contrôle FSI EWMA-RZ proposées dans [24] comme suit.

— une première carte EWMA (notée EWMA- RZ^+) visant à détecter une *augmentation* de ratio et définie par

$$Y_i^+ = \max(z_0, (1 - \lambda^+)Y_{i-1}^+ + \lambda^+ \hat{Z}_i) \quad (2.11)$$

avec $Y_0^+ = z_0$ comme valeur initiale et une unique limite de contrôle supérieure $UCL^+ = H_U \times z_0$ (i.e. la limite de contrôle inférieure $LCL^- = z_0$). Pour cette carte de contrôle, une situation hors-contrôle est signalée dès que $Y_i^+ > UCL^+$.

— une seconde carte EWMA (notée EWMA- RZ^-) visant à détecter une *diminution* de ratio et définie par

$$Y_i^- = \min(z_0, (1 - \lambda^-)Y_{i-1}^- + \lambda^- \hat{Z}_i) \quad (2.12)$$

avec $Y_0^- = z_0$ comme valeur initiale et une unique limite de contrôle inférieure $LCL^- = H_D \times z_0$ (i.e. la limite de contrôle supérieure $UCL^- = z_0$). Pour cette carte de contrôle, une situation hors-contrôle est signalée dès que $Y_i^- < LCL^-$.

Dans cette définition, $\lambda^+ \in (0, 1]$ et $H_U > 1$ ($\lambda^- \in (0, 1]$ et $H_D < 1$) sont

respectivement le paramètre de lissage et les paramètres de la carte EWMA-RZ⁺ (EWMA-RZ⁻).

Dans les cartes de contrôle VSI EWMA-RZ [28], les limites de contrôle $UCL^+ = H_U \times z_0$ et $LCL^- = H_D \times z_0$ sont identiques à celles des cartes FSI d'origine. La différence est que l'intervalle d'échantillonnage, c'est-à-dire le temps entre deux échantillons successifs Z_i et Z_{i+1} , peut varier en fonction de la valeur actuelle de Y_i^+ ou Y_i^- . Pour la carte de contrôle ascendante (descendante), un intervalle d'échantillonnage plus long, h_L , est utilisé lorsque la statistique de contrôle se situe dans la région $[z_0, UWL^+][LWL^-, z_0]$, dans laquelle

- $UWL^+ = z_0 + R_U(UCL^+ - z_0)$ est la limite d'avertissement supérieure,
- $LWL^- = z_0 - R_D(z_0 - LCL^-)$ est la limite d'avertissement inférieure.

De même, l'intervalle d'échantillonnage court, h_S , est utilisé lorsque la statistique de contrôle se situe dans la région $[UWL^+, UCL^+]$ (pour la carte VSI EWMA-RZ⁺) et $[LCL^-, LWL^-]$ (pour la carte VSI EWMA-RZ⁻). De plus, un signal hors-contrôle est donné au temps i si $Z_i^+ > UCL^+$ pour la carte VSI EWMA-RZ⁻ ou $Z_i^- < LCL^-$ pour la carte VSI EWMA-RZ⁺. Ainsi, dans le schéma VSI EWMA-RZ, l'intervalle de contrôle est séparé en trois régions : la région "sûre" ou centrale, la région d'avertissement et la région hors contrôle. La limite d'avertissement UWL^+ ou LWL^- est définie par les nouveaux paramètres $R_U \in (0, 1)$ ou ($R_D \in (0, 1)$). Ces nouveaux paramètres sont appelés coefficients limites d'alerte. Ils représentent la relation entre la région d'avertissement et la région sûre dans le sens où plus les valeurs de R_U ou R_D sont petites, plus la "région sûre" est petite par rapport à la région d'avertissement.

Nous évaluons les performances de la carte proposée en utilisant l'ATS (en anglais Average Time to Signal). L'ATS compte le temps prévu avant qu'une carte de contrôle ne signale une "condition hors-contrôle" après l'apparition d'une cause attribuable ou l'émission d'une fausse alarme. Lorsqu'un processus s'exécute sous-contrôle, il est noté ATS_0 ; sinon, il est noté ATS_1 . De par sa signification, il est souhaitable de concevoir une carte avec des ATS_1 plus petits tandis que le ATS_0 est toujours le même par rapport aux autres.

Pour un modèle FSI, le ATS est un multiple du ARL puisque l'intervalle d'échantillonnage h_F est fixe, à savoir,

$$ATS^{\text{FSI}} = h_F \times ARL^{\text{FSI}}. \quad (2.13)$$

For a VSI model, the ATS is defined as :

$$ATS^{\text{VSI}} = E(h) \times ARL^{\text{VSI}}. \quad (2.14)$$

où $E(h)$ est l'intervalle d'échantillonnage moyen.

La formule et le calcul du ATS pour la carte de contrôle VSI EWMA-RZ sont effectués en implémentant une approche de chaîne de Markov discrète proposée par [29] telle que présentée dans [28]. Étant donné la taille τ , on trouve la combinaison $(\lambda^{+*}, H_U^*, h_L^*)$ ou $(\lambda^{-*}, H_D^*, h_L^*)$ tel que

— pour la carte VSI EWMA-RZ⁻

$$(\lambda^{+*}, H_U^*, h_L^*) = \underset{(\lambda^+, H_U, h_L)}{\operatorname{argmin}} \operatorname{ATS}(n, \lambda^+, H_U, R_U, \rho, \gamma_X, \gamma_Y, \tau, h_L, h_S) \quad (2.15)$$

soumis à la contrainte

$$\begin{cases} \operatorname{ATS}(n, \lambda^{+*}, H_U^*, R_U, \rho, \gamma_X, \gamma_Y, \tau = 1, h_L^*, h_S) = \operatorname{ATS}_0 \\ E_0(h) = 1 \end{cases} \quad ; \quad (2.16)$$

— pour la carte VSI EWMA-RZ⁺,

$$(\lambda^{-*}, H_D^*, h_L^*) = \underset{(\lambda^-, H_D, h_L)}{\operatorname{argmin}} \operatorname{ATS}(n, \lambda^-, H_D, R_D, \rho, \gamma_X, \gamma_Y, \tau, h_L, h_S) \quad (2.17)$$

soumis à la contrainte

$$\begin{cases} \operatorname{ATS}(n, \lambda^{-*}, H_D^*, R_D, \rho, \gamma_X, \gamma_Y, \tau = 1, h_L^*, h_S) = \operatorname{ATS}_0 \\ E_0(h) = 1 \end{cases} \quad . \quad (2.18)$$

Par conséquent, nous pouvons conclure que la carte de contrôle VSI EWMA-RZ est capable de détecter les petits changements plus rapidement que la carte de contrôle FSI EWMA-RZ.

2.2.1.3 Modèle d'erreur de mesure à covariable linéaire pour l'échantillon du ratio

En raison d'erreurs de mesure, les *vrais* caractéristiques de qualité $\mathbf{W}_{i,j}$ sont inobservables. Au lieu de cela, il est évalué à partir d'un ensemble d'opérations de mesure $m \geq 1$, $\{\mathbf{W}_{i,j,1}^*, \mathbf{W}_{i,j,2}^*, \dots, \mathbf{W}_{i,j,m}^*\}$. D'après le modèle d'erreur de covariable linéaire ([30]), nous avons

$$\mathbf{W}_{i,j,k}^* = \mathbf{A} + \mathbf{B}\mathbf{W}_{i,j} + \boldsymbol{\varepsilon}_{i,j,k}, \quad k = 1, \dots, m, \quad (2.19)$$

où \mathbf{A} est un vecteur (2×1) de constantes,

$$\mathbf{A} = \begin{pmatrix} a_X \\ a_Y \end{pmatrix}, \quad (2.20)$$

\mathbf{B} est une matrice (2×2) , $\boldsymbol{\varepsilon} \sim N(\mathbf{0}, \boldsymbol{\Sigma}_M)$ est un vecteur aléatoire normal bivarié centré supposé indépendant de \mathbf{W} . La matrice de variance-covariance dans la distribution de $\boldsymbol{\varepsilon}$ est désigné par

$$\boldsymbol{\Sigma}_M = \begin{pmatrix} \sigma_{MX}^2 & \rho_M \sigma_{MX} \sigma_{MY} \\ \rho_M \sigma_{MX} \sigma_{MY} & \sigma_{MY}^2 \end{pmatrix}, \quad (2.21)$$

où σ_{MX} (resp. σ_{MY}) est l'écart-type des erreurs de mesure de X (resp. Y), et $\rho_M \in (-1, +1)$ est le coefficient de corrélation correspondant. Dans [30], les auteurs préconisaient une matrice $p \times p$ inversible de constantes, souvent diagonale, pour la matrice \mathbf{B} . Par conséquent, nous supposons que $\mathbf{B} = b\mathbf{I}_{2 \times 2}$, où b est une constante, c'est-à-dire

$$\mathbf{B} = \begin{pmatrix} b & 0 \\ 0 & b \end{pmatrix}. \quad (2.22)$$

En pratique, la moyenne $\bar{\mathbf{W}}_{i,j}^* = (\bar{X}_{i,j}^*, \bar{Y}_{i,j}^*)$ des quantités observables $\{\mathbf{W}_{i,j,1}^*, \mathbf{W}_{i,j,2}^*, \dots, \mathbf{W}_{i,j,m}^*\}$ est souvent considéré comme une valeur représentée pour la vraie valeur $\mathbf{W}_{i,j}$. Cette moyenne est calculée par

$$\begin{aligned}\bar{\mathbf{W}}_{i,j}^* &= \frac{1}{m} \sum_{k=1}^m \mathbf{W}_{i,j,k}^* \\ &= \mathbf{A} + \mathbf{B}\mathbf{W}_{i,j} + \frac{1}{m} \sum_{k=1}^m \boldsymbol{\varepsilon}_{i,j,k}.\end{aligned}\quad (2.23)$$

Soit $\mu_{X^*}, \mu_{Y^*}, \sigma_{X^*}^2, \sigma_{Y^*}^2$ et ρ^* la moyenne, la variance et le coefficient de corrélation des deux composantes $(\bar{X}_{i,j}^*, \bar{Y}_{i,j}^*)$ du vecteur $\bar{\mathbf{W}}_{i,j}^*$, respectivement. Ensuite, nous supposons que le sous-contrôle $\boldsymbol{\mu}_{0,\mathbf{W}}$ est déplacé vers $\boldsymbol{\mu}_{1,\mathbf{W}} = (\mu_{0,X} + \delta_X \sigma_X, \mu_{0,Y} + \delta_Y \sigma_Y)^T$ où δ_X et δ_Y représentent l'amplitude de la dérive en position de $X_{i,j}$ et $Y_{i,j}$, [31]. Alors, l'équation $z_1 = \tau z_0$ devient

$$\frac{\mu_{0,X} + \delta_X \sigma_X}{\mu_{0,Y} + \delta_Y \sigma_Y} = \tau \times \frac{\mu_{0,X}}{\mu_{0,Y}},$$

et on obtient la formule suivante :

$$1 + \delta_X \gamma_X = \tau(1 + \delta_Y \gamma_Y). \quad (2.24)$$

Selon Nguyen et al. [31], en présence d'erreurs de mesure, les coefficients de variation $\gamma_{X^*} = \frac{\sigma_{X^*}}{\mu_{X^*}}$ et $\gamma_{Y^*} = \frac{\sigma_{Y^*}}{\mu_{Y^*}}$, le coefficient de la corrélation ρ^* et le ratio d'écart-type $\omega^* = \frac{\sigma_{X^*}}{\sigma_{Y^*}}$ de $\bar{X}_{i,j}^*$ et $\bar{Y}_{i,j}^*$ sont égaux à

$$\gamma_{X^*} = \frac{\sqrt{b^2 + \frac{\eta_X^2}{m}}}{b(1 + \delta_X \gamma_X) + \theta_X} \times \gamma_X = \frac{\sqrt{b^2 + \frac{\eta_X^2}{m}}}{b\tau(1 + \delta_Y \gamma_Y) + \theta_X} \times \gamma_X \quad (2.25)$$

où $\eta_X = \frac{\sigma_{MX}}{\sigma_X}$ (erreur de calibration), $\theta_X = \frac{a_X}{\mu_{0,X}}$ (erreur d'exactitude), et $\gamma_X = \frac{\sigma_X}{\mu_{0,X}}$.

$$\gamma_{Y^*} = \frac{\sqrt{b^2 + \frac{\eta_Y^2}{m}}}{b(1 + \delta_Y \gamma_Y) + \theta_Y} \times \gamma_Y, \quad (2.26)$$

$$\rho^* = \frac{b^2 \rho + \rho_M \frac{\eta_X \eta_Y}{m}}{\sqrt{b^2 + \eta_X^2/m} \sqrt{b^2 + \eta_Y^2/m}}, \quad (2.27)$$

$$\omega^* = \sqrt{\frac{b^2 + \frac{\eta_X^2}{m}}{b^2 + \frac{\eta_Y^2}{m}}} \times \omega, \quad (2.28)$$

où $\eta_Y = \frac{\sigma_{MY}}{\sigma_Y}$ (erreur de calibration), $\theta_Y = \frac{a_Y}{\mu_{0,Y}}$ (erreur d'exactitude), $\gamma_Y = \frac{\sigma_Y}{\mu_{0,Y}}$ et $\omega = \frac{\sigma_X}{\sigma_Y}$.

Il convient de considérer que le ratio sous-contrôle et hors-contrôle en présence des

erreurs de mesure est

$$z_0^* = \frac{\mu_{0,X^*}}{\mu_{0,Y^*}} = \frac{b\mu_{0,X} + a_X}{b\mu_{0,Y} + a_Y} = \frac{b + \theta_X}{b + \theta_Y} \times z_0, \quad (2.29)$$

$$z_1^* = \frac{\mu_{1,X^*}}{\mu_{1,Y^*}} = \frac{\theta_X + \tau(1 + \delta_Y\gamma_Y)}{\theta_Y + (1 + \delta_Y\gamma_Y)} \times z_0. \quad (2.30)$$

Ainsi, en général nous avons $z_1^* \neq \tau z_0^*$ [31].

Dans [26], les auteurs ont supposé que la relation entre le ratio hors-contrôle et le ratio en contrôle est indépendante des erreurs de mesure (voir l'équation (36) dans [26] et l'explication correspondante). En pratique, les erreurs de mesure peuvent affecter les véritables observations du ratio. En conséquence, cette relation devrait changer avec les erreurs de mesure. Nous modéliserons avec précision l'évolution des paramètres d'un processus après avoir été décalé sous la présence d'erreurs de mesure pour voir plus clairement cette variation [31]. En présence d'erreur de mesure, la statistique surveillée dans (2.5) est de la forme

$$\hat{Z}_i^* = \frac{\hat{\mu}_{X_i^*}}{\hat{\mu}_{Y_i^*}} = \frac{\bar{X}_i^*}{\bar{Y}_i^*} = \frac{\sum_{j=1}^n X_{i,j}^*}{\sum_{j=1}^n Y_{i,j}^*}. \quad (2.31)$$

où $\bar{X}_i^* = \frac{1}{n} \sum_{j=1}^n \bar{X}_{i,j}^*$, $\bar{Y}_i^* = \frac{1}{n} \sum_{j=1}^n \bar{Y}_{i,j}^*$, $\bar{X}_{i,j}^*$ et $\bar{Y}_{i,j}^*$ sont deux composantes du vecteur normal bivarié $\bar{\mathbf{W}}_{i,j}^*$ dans (2.23).

D'après leur définition, il est facile de voir que $\bar{X}_i^* \sim N(\mu_{X^*}, \frac{\sigma_{X^*}}{\sqrt{n}})$ et $\bar{Y}_i^* \sim N(\mu_{Y^*}, \frac{\sigma_{Y^*}}{\sqrt{n}})$, les coefficients de variation de \bar{X}_i^* et \bar{Y}_i^* sont maintenant

$$\gamma_{\bar{X}^*} = \frac{\sigma_{X^*}}{\mu_{X^*}\sqrt{n}} = \frac{\gamma_{X^*}}{\sqrt{n}}, \quad (2.32)$$

$$\gamma_{\bar{Y}^*} = \frac{\sigma_{Y^*}}{\mu_{Y^*}\sqrt{n}} = \frac{\gamma_{Y^*}}{\sqrt{n}}, \quad (2.33)$$

et le ratio d'écart type ω_i^* de \bar{X}_i^* et \bar{Y}_i^* est

$$\omega_i^* = \frac{\sigma_{X^*}/\sqrt{n}}{\sigma_{Y^*}/\sqrt{n}} = \frac{\sigma_{X^*}}{\sigma_{Y^*}} = \omega^* \quad (2.34)$$

Le c.d.f. et le i.d.f de \hat{Z}_i^* peuvent maintenant être obtenus à partir de (2.4) et (2.4) où γ_X , γ_Y , ω et ρ sont remplacés par $\gamma_{\bar{X}^*}$, $\gamma_{\bar{Y}^*}$, ω^* et ρ^* définis dans (2.32), (2.33), (2.34) et (2.27).

2.2.1.4 L'effet des erreurs de mesure sur les performances des cartes de contrôle EWMA pour le ratio de deux variables normalement distribuées

Dans la conception de deux cartes de contrôle EWMA unilatérale, la statistique \hat{Z}_i^* n'est pas surveillée directement. Au lieu de cela, la statistique suivante sera surveillée [31] :

- une première carte EWMA-RZ⁺ visant à détecter une *augmentation* dans le ratio

et définie par,

$$Y_i^{*+} = \max(z_0^*, (1 - \lambda^+)Y_{i-1}^{*+} + \lambda^+ \hat{Z}_i^*) \quad (2.35)$$

où $Y_0^{*+} = z_0^*$ est une valeur initiale. La limite de contrôle supérieure correspondante UCL^+ de la carte de contrôle EWMA-RZ⁺ est $UCL^+ = K^+ \times z_0^*$ ($K^+ > 1$).

- une seconde carte EWMA-RZ⁻ visant à détecter une *diminution* dans le ratio et définie par,

$$Y_i^{*-} = \min(z_0^*, (1 - \lambda^-)Y_{i-1}^{*-} + \lambda^- \hat{Z}_i^*) \quad (2.36)$$

où $Y_0^{*-} = z_0^*$ est une valeur initiale. La limite de contrôle inférieure correspondante LCL^- de la carte de contrôle EWMA-RZ⁻ est $LCL^- = K^- \times z_0^*$ ($K^- < 1$).

Les deux cartes de contrôle EWMA-RZ⁻ et EWMA-RZ⁺ ci-dessus sont définies lorsque les lissages $\lambda^+ \in (0, 1]$, $\lambda^- \in (0, 1]$ et les paramètres de la carte de contrôle K^+ , K^- sont définis. Certaines conclusions importantes peuvent être tirées de cette étude[31] comme suit.

- L'erreur de calibration (η_X et η_Y) et l'erreur d'exactitude (θ_X et θ_Y) ont des impacts négatifs sur les cartes de contrôle EWMA-RZ unilatérales. Cependant, lorsque ces erreurs ne sont pas trop importantes, disons $\eta_X, \eta_Y \leq 0.5$ et $\theta_X, \theta_Y \leq 0.025$ dans cette étude, ces impacts sont insignifiants.
- Prendre plusieurs mesures par élément n'est pas un moyen efficace de réduire l'effet des erreurs de mesure sur les performances des cartes proposés.
- Indépendamment des erreurs de mesure, les cartes de contrôle unilatérales EWMA-RZ surpassent de manière significative la carte de contrôle unilatérale Shewhart-RZ dans la détection des changements du processus.

2.2.1.5 Conception de deux cartes Shewhart-RZ unilatérales pour des séries de production courtes

Le cycle de production est prévu pour produire un lot de petite taille ayant N pièces après une longueur de laminage fixe H . Soit I le nombre d'inspections planifiées de l'horizon glissant H et supposons qu'aucune inspection n'a lieu à la fin de l'exécution. Par ces paramètres, la fréquence d'échantillonnage (l'intervalle de temps entre deux inspections consécutives) sera de $\mathcal{S}_h = \frac{H}{(I+1)}$ heures. Les cartes Shewhart-RZ unilatérales séparées sont définies comme dans la section précédente. Comme le cycle de production est trop petit, la longueur de cycle traditionnelle ne sera pas applicable pour déterminer les propriétés de longueur de cycle des cartes de contrôle Shewhart-RZ unilatérales [32]. Pour servir l'objectif, TRL (en anglais Truncated Run Length) et sa moyenne (en anglais Truncated Average Run Length, $TARL$) seront utilisés pour déterminer les performances des cartes. Les résultats suivants peuvent être tirés [32] :

- Lorsque l'amplitude du changement τ diminue (augmente) aux valeurs fixes de γ_X, γ_Y, I, n et ρ_0 , le $TARL_1$ correspondant au Shewhart-RZ⁻ (Shewhart-RZ⁺) diminuera en conséquence.
- Étant donné $\tau, I, \gamma_X = \gamma_Y$, et ρ_0 , la taille de l'échantillon n influence les performances des cartes de contrôle dans la détection des amplitudes du changement du ratio z_0 . En particulier, à mesure que la taille de l'échantillon augmente, les valeurs $TARL_1$ des cartes de contrôle Shewhart-RZ⁻ et Shewhart-RZ⁺ diminuent.

2.2.2 Cartes de contrôle surveillant les données de composition avec des erreurs de mesure

Dans le cas des processus multivariés continus, la grande majorité des cartes de contrôle suppose que les données sont **sans contraintes**. Mais il existe une catégorie spécifique de données multivariées qui sont **contraintes** par définition. Ce type de données est appelé des données de composition (en anglais Compositional Data, CoDa) et il est représenté par des vecteurs dont les composantes **strictement positifs** véhiculent que des informations relatives. Le CoDa comprend des mesures en probabilité, proportions, pourcentages et parties. La somme des composantes du vecteur CoDa est exprimée comme une constante κ égale à 1 si nous travaillons avec des proportions, 100 si nous travaillons avec des pourcentages, 10^6 si nous travaillons avec des parties par million (ppm), et ainsi de suite. Certaines applications de CoDa peuvent être trouvées dans le domaine de la géologie (voir par exemple, [33], [34] ou [35]), dans l'industrie agroalimentaire (voir par exemple [36]) et dans le domaine de la biologie (voir par exemple [37]). Aujourd'hui, on considère qu'une rigueur le fondement mathématique de CoDa est dû à [38], qui a développé une géométrie adéquate pour modéliser et transformer de telles données. Afin de travailler avec CoDa et, avant la mise en œuvre de toute technique SPM, il est important d'expliquer comment modéliser et transformer ces données.

Une p -composition est définie comme un *vecteur ligne* $\mathbf{x} = (x_1, \dots, x_p)$ qui appartient au simplexe \mathcal{S}^p défini comme

$$\mathcal{S}^p = \left\{ \mathbf{x} = (x_1, x_2, \dots, x_p) \mid x_i > 0, i = 1, 2, \dots, p \text{ et } \sum_{i=1}^p x_i = \kappa \right\},$$

où $\kappa > 0$ est une constante (par exemple, $\kappa = 1$ si les composants x_1, x_2, \dots, x_p sont des proportions et $\kappa = 100$ si ce sont des pourcentages). Remarque importante : Afin d'éviter tout malentendu, tous les vecteurs de ce chapitre sont considérés comme des vecteurs *ligne*, et non comme des vecteurs colonnes. Par définition, deux compositions \mathbf{x} et \mathbf{y} peuvent être différentes (par exemple $\mathbf{x} = (0.2, 0.5, 0.3)$ et $\mathbf{y} = (20, 50, 30)$) mais elles sont *compositionnellement équivalentes* (c'est-à-dire qu'elles portent la même information relative) si $\mathcal{C}(\mathbf{x}) = \mathcal{C}(\mathbf{y})$, où la fonction *clôture* est définie comme

$$\mathcal{C}(\mathbf{x}) = \left(\frac{\kappa x_1}{\sum_{i=1}^p x_i}, \frac{\kappa x_2}{\sum_{i=1}^p x_i}, \dots, \frac{\kappa x_p}{\sum_{i=1}^p x_i} \right).$$

La géométrie euclidienne standard qui définit un espace vectoriel avec une structure métrique en \mathbb{R}^p (espace non contraint) ne peut pas être utilisée pour des compositions en \mathcal{S}^p (espace contraint). Par exemple, si $\mathbf{x} = (0.2, 0.5, 0.3) \in \mathcal{S}^p$ et $\mathbf{y} = (0.3, 0.6, 0.1) \in \mathcal{S}^p$ alors $\mathbf{x} + \mathbf{y} = (0.5, 1.1, 0.4) \notin \mathcal{S}^p$ et $2\mathbf{x} = (0.4, 1, 0.6) \notin \mathcal{S}^p$ (c'est-à-dire les opérateurs traditionnels $+$ et \cdot sont inutiles). Par conséquent, si nous voulons un espace vectoriel avec une structure métrique pour \mathcal{S}^p , il est nécessaire de définir une géométrie. Cette géométrie spécifique, proposée par [38] (et appelée la géométrie d'Aitchison) définit deux nouveaux opérateurs

- l'opérateur *perturbation* \oplus de $\mathbf{x} \in \mathcal{S}^p$ par $\mathbf{y} \in \mathcal{S}^p$ (analogue au traduction en \mathbb{R}^p) défini comme

$$\mathbf{x} \oplus \mathbf{y} = \mathcal{C}(x_1 y_1, x_2 y_2, \dots, x_p y_p),$$

- l'opérateur *powering* \odot de $\mathbf{x} \in \mathcal{S}^p$ par une constante $a \in \mathbb{R}$ (analogue à la multiplication scalaire dans \mathbb{R}^p par une constante) défini comme

$$a \odot \mathbf{x} = \mathcal{C}(x_1^a, x_2^a, \dots, x_p^a).$$

Sur la base de ces définitions, l'élément neutre pour \oplus est $\mathbf{0}_{\mathcal{S}^p} = \mathcal{C}(1, 1, \dots, 1) = (\frac{1}{p}, \dots, \frac{1}{p})$, c'est-à-dire le "centre" du simplexe \mathcal{S}^p , l'inverse de la composition \mathbf{x} est $\mathbf{x}^{-1} = \mathcal{C}(x_1^{-1}, x_2^{-1}, \dots, x_p^{-1})$ et la *différence de perturbation* est $\mathbf{x} \ominus \mathbf{y} = \mathbf{x} \oplus \mathbf{y}^{-1}$.

Une représentation des coordonnées du rapport logarithmique pour une composition $\mathbf{x} \in \mathcal{S}^p$ est la transformation *clr* (*centered logratio* en anglais) défini comme

$$\text{clr}(\mathbf{x}) = \left(\ln \frac{x_1}{\bar{x}_G}, \ln \frac{x_2}{\bar{x}_G}, \dots, \ln \frac{x_p}{\bar{x}_G} \right),$$

où \bar{x}_G est la moyenne géométrique par composant de \mathbf{x} , c'est à dire.

$$\bar{x}_G = \left(\prod_{i=1}^p x_i \right)^{\frac{1}{p}} = \exp \left(\frac{1}{p} \sum_{i=1}^p \ln x_i \right).$$

Cette formule transforme une composition $\mathbf{x} \in \mathcal{S}^p$ en un vecteur $\text{clr}(\mathbf{x}) = \boldsymbol{\xi} = (\xi_1, \xi_2, \dots, \xi_p) \in \mathbb{R}^p$ satisfaisant la contrainte $\xi_1 + \xi_2 + \dots + \xi_p = 0$.

Une autre représentation des coordonnées du rapport logarithmique pour une composition $\mathbf{x} \in \mathcal{S}^p$ est la transformation *ilr* (*isometric logratio* en anglais) définie comme

$$\text{ilr}(\mathbf{x}) = \mathbf{x}^* = \text{clr}(\mathbf{x})\mathbf{B}^\top$$

où \mathbf{B} est une matrice $(p-1, p)$. Il y a beaucoup de choix possibles pour \mathbf{B} (pour plus explications, voir par exemple [39, page 40]) et l'une d'elles est donnée ci-dessous :

$$B_{i,j} = \begin{cases} \sqrt{\frac{1}{(p-i)(p-i+1)}} & j \leq p-i \\ -\sqrt{\frac{p-i}{p-i+1}} & j = p-i+1 \\ 0 & j > p-i+1 \end{cases}$$

La transformation *ilr* est fondamentale car c'est une isométrie qui permet une transformation unique des coordonnées (contraintes) d'une composition \mathbf{x} en (sans contrainte) *ilr*-coordonnées $\mathbf{x}^* \in \mathbb{R}^{p-1}$. A l'inverse, si l'on veut obtenir la coordonnées de composition \mathbf{x} à partir des *ilr*-coordonnée \mathbf{x}^* nous devons utiliser la transformation ilr^{-1} (*inverse isometric logratio* en anglais) définie comme

$$\text{ilr}^{-1}(\mathbf{x}^*) = \mathbf{x} = \mathcal{C}(\exp(\mathbf{x}^*\mathbf{B})).$$

Il y a deux façons de traiter avec CoDa. Une façon est de travailler avec la géométrie d'Aitchison sur le simplexe et d'utiliser les opérateurs de puissance et de perturbation. La deuxième façon est de transformer les données dans l'espace réel au moyen de coordonnées de rapport logarithmique isométrique, d'appliquer les statistiques classiques et d'utiliser la transformation en arrière vers le simplexe pour l'interprétation, si nécessaire. Enfin,

par définition (voir [39], \mathbf{x} est une *composition aléatoire normale multivariée* sur le simplexe \mathcal{S}^p , notée $\text{MNOR}_{\mathcal{S}^p}(\boldsymbol{\mu}^*, \boldsymbol{\Sigma}^*)$, if $\mathbf{x}^* = \text{ilr}(x) \sim \text{MNOR}_{\mathbb{R}^{p-1}}(\boldsymbol{\mu}^*, \boldsymbol{\Sigma}^*)$, i.e. \mathbf{x}^* est un vecteur aléatoire normal multivarié sur \mathbb{R}^{p-1} , où $\boldsymbol{\mu}^*$ and $\boldsymbol{\Sigma}^*$ sont le vecteur (ligne) $(1, p-1)$ et matrice de variance-covariance $(p-1, p-1)$, respectivement. Il est important de noter que tout au long du chapitre, afin d'éviter tout malentendu, les vecteurs ou matrices sans exposant "*" sont supposés définis sur \mathcal{S}^p (par exemple \mathbf{x}), tandis que les mêmes vecteurs ou matrices avec un exposant "*" sont supposés être définis sur \mathbb{R}^{p-1} (par exemple \mathbf{x}^*).

Concernant la surveillance statistique des processus de CoDa, les contributions sont actuellement peu nombreuses. Pour la première fois, Boyles [40] a suggéré une carte de contrôle du Khi-deux pour CoDa. Cette carte a d'abord été considéré comme utile pour les données de processus multinomiales, mais il a également été constaté que ce type de graphique peut être utile pour les CoDa qui découlent d'une distribution de Dirichlet. Guevara-González et al. [41] a utilisé une technique de régression de Dirichlet pour étudier cinq types de carte de contrôle Hotelling T^2 pour la surveillance des profils (en phase I) de CoDa. Comme extension, Vives-Mestres et al. [42] a proposé une carte de contrôle pour les observations individuelles pour CoDa basée sur la transformation ilr (logratio isométrique) (la carte de contrôle T_C^2) et ils l'ont comparée avec la carte de contrôle T^2 après suppression d'une variable. Le T_C^2 s'est avéré plus cohérent et a de meilleures performances que les cartes de contrôle T^2 en termes de ARL. Récemment, Tran et al. [43] a suggéré de surveiller CoDa à l'aide d'un schéma MEWMA (en anglais Multivariate Exponentially Weighted Moving Average). La carte MEWMA-CoDa résultante s'est avérée plus sensible que la carte de contrôle T_C^2 .

Comme il est résumé dans le document d'enquête de [44], le modèles d'erreurs de mesure récemment étudiés dans la littérature sont les *additif* (i.e. $Y = a + bX + \sigma_M$), *multiplicative* (c'est-à-dire $Y = X\sigma_M$), *bi-composant* et *quatre-composant*. De toute évidence, le modèle additif est le plus populaire puisque 56 des 60 articles analysés par [44] ont adopté ce modèle simple et intuitif. Pour cette raison, cette étude considérera également l'erreur additive maquette. Concernant la variance du terme d'erreur de mesure σ_M^2 , elle peut être considérée comme une *constante* ou comme une fonction *linéairement croissante* de la moyenne du processus μ , c'est-à-dire $\sigma_M^2 = c + d\mu$, où c et $d > 0$ sont deux paramètres supplémentaires à définir. Sur la base du document d'enquête de [44], la variance du terme d'erreur de mesure constante est le choix le plus populaire (52 articles parmi 60 articles analysés) car il évite d'ajouter / estimer deux paramètres supplémentaires et conserve le modèle sous une forme simple. Cette variance de terme d'erreur de mesure constante sera utilisée dans ce chapitre. Pour une revue détaillée de la littérature sur erreurs de mesure dans la surveillance statistique des processus, voir [44].

2.2.2.1 Modèle d'erreur de mesure à covariable linéaire pour CoDa

Supposons qu'au temps $i = 1, 2, \dots$, la caractéristique de qualité est une composition p -partie $\mathbf{y}_i = (y_{i,1}, \dots, y_{i,p}) \in \mathcal{S}^p$ et $\mathbf{y}_1, \mathbf{y}_2, \dots$ sont composition aléatoire normale multivariée indépendants $\text{MNOR}_{\mathcal{S}^p}(\boldsymbol{\mu}^*, \boldsymbol{\Sigma}^*)$. De plus, supposons également que la caractéristique de qualité \mathbf{y}_i n'est pas directement observable, mais ne peut être évalué à partir des résultats

$\mathbf{x}_{i,1}, \dots, \mathbf{x}_{i,m}$ d'un ensemble de $m \geq 1$ opérations de mesure avec chaque $\mathbf{x}_{i,j}$, $j = 1, \dots, m$, étant égal à :

$$\mathbf{x}_{i,j} = \mathbf{a} \oplus (b \odot \mathbf{y}_i) \oplus \boldsymbol{\varepsilon}_{i,j}, \quad (2.37)$$

où $\mathbf{a} \in \mathcal{S}^p$ et $b \in \mathbb{R}$ sont des constantes connues et où $\boldsymbol{\varepsilon}_{i,j}$ est un multinormal $\text{MNOR}_{\mathcal{S}^p}(\mathbf{0}, \boldsymbol{\Sigma}_M^*)$ terme d'erreur aléatoire à l'imprécision de la mesure, qui est indépendant de \mathbf{y}_i et $\boldsymbol{\Sigma}_M^*$ est la matrice de variance-covariance d'erreur de mesure connue.

Ce modèle d'erreur de mesure pour CoDa [45] est inspiré de celui proposé par [46] et [30] pour les données univariées et multivariées "classiques", respectivement. Dans ces articles, ces auteurs préconisent de prendre plusieurs mesures (m) et de les moyenner afin de compenser l'effet des erreurs de mesure et de diminuer la variance de la composante d'erreur de mesure. Bien entendu, le praticien qualité devra trouver le bon équilibre entre les surcoûts et le temps liés à un trop grand nombre de mesures et un niveau d'erreur de mesure acceptable. Par conséquent, à l'instar de [46] et [30], nous suggérons de définir, au temps $i = 1, 2, \dots$, la moyenne de l'échantillon de composition comme (voir [39]) :

$$\begin{aligned} \bar{\mathbf{x}}_i &= \frac{1}{m} \odot (\mathbf{x}_{i,1} \oplus \dots \oplus \mathbf{x}_{i,m}), \\ &= \mathbf{a} \oplus (b \odot \mathbf{y}_i) \oplus \left(\frac{1}{m} \odot (\boldsymbol{\varepsilon}_{i,1} \oplus \dots \oplus \boldsymbol{\varepsilon}_{i,m}) \right). \end{aligned}$$

Définissons $\mathbf{a}^* = \text{ilr}(\mathbf{a})$. En utilisant le théorème 6.20 dans [39], nous avons $\bar{\mathbf{x}}_i \sim \text{MNOR}_{\mathcal{S}^p}(\boldsymbol{\mu}_{\bar{\mathbf{x}}}^*, \boldsymbol{\Sigma}_{\bar{\mathbf{x}}}^*)$ avec

$$\boldsymbol{\mu}_{\bar{\mathbf{x}}}^* = \mathbf{a}^* + b\boldsymbol{\mu}^*, \quad (2.38)$$

$$\boldsymbol{\Sigma}_{\bar{\mathbf{x}}}^* = b^2 \boldsymbol{\Sigma}^* + \frac{1}{m} \boldsymbol{\Sigma}_M^*. \quad (2.39)$$

2.2.2.2 Performances de la carte de contrôle Hotelling T^2 pour les données de composition en présence d'erreurs de mesure

Supposons qu'au temps $i = 1, 2, \dots$, nous avons m mesures $\mathbf{x}_{i,1}, \dots, \mathbf{x}_{i,m}$ de la qualité caractéristique \mathbf{y}_i . Lorsque le processus est sous-contrôle, nous avons $\mathbf{y}_i \sim \text{MNOR}_{\mathcal{S}^p}(\boldsymbol{\mu}_0^*, \boldsymbol{\Sigma}^*)$ et, lorsque le processus est hors contrôle, nous avons $\mathbf{y}_i \sim \text{MNOR}_{\mathcal{S}^p}(\boldsymbol{\mu}_1^*, \boldsymbol{\Sigma}^*)$, où $\boldsymbol{\mu}_0^*$ et $\boldsymbol{\mu}_1^*$ sont les vecteurs moyens sous-contrôle et hors-contrôle, respectivement ($\boldsymbol{\Sigma}^*$ est supposé être inchangé). Soit $\bar{\mathbf{x}}_i^* = \text{ilr}(\bar{\mathbf{x}}_i)$. En utilisant une approche similaire à celle de [47], une carte de contrôle Hotelling T^2 pour CoDa, prenant en compte les erreurs de mesure, peut être proposée. D'après les résultats obtenus à la fin de la section précédente, la statistique suivie par la carte de contrôle Hotelling CoDa T^2 avec des erreurs de mesure est (rappelons que dans ce chapitre, les vecteurs sont considérés comme des vecteurs lignes)

$$Z_i = (\bar{\mathbf{x}}_i^* - \mathbf{a}^* - b\boldsymbol{\mu}_0^*) \left(b^2 \boldsymbol{\Sigma}^* + \frac{1}{m} \boldsymbol{\Sigma}_M^* \right)^{-1} (\bar{\mathbf{x}}_i^* - \mathbf{a}^* - b\boldsymbol{\mu}_0^*)^\top. \quad (2.40)$$

Lorsque le processus est sous-contrôle, nous avons $Z_i \sim \chi^2(p-1)$, c'est-à-dire une distribution χ^2 avec $p-1$ degrés de liberté. En conséquence, une limite de contrôle

supérieure UCL peut être définie pour ce Hotelling T^2 carte de contrôle comme

$$\text{UCL} = F_{\chi^2}^{-1}(1 - \alpha_0 | p - 1),$$

où $F_{\chi^2}^{-1}(\dots | p - 1)$ est l'i.d.f de la distribution $\chi^2(p - 1)$ et $\alpha_0 = \frac{1}{\text{ARL}_0}$ est l'erreur de type I, ARL_0 étant l'ARL sous-contrôle. Lorsque le processus est hors-contrôle, la statistique $Z_i \sim \chi^2(p - 1, \delta_M)$, soit une distribution χ^2 non centrale avec $p - 1$ degrés de liberté et paramètre de non-centralité δ_M égal à

$$\delta_M = b^2(\boldsymbol{\mu}_1^* - \boldsymbol{\mu}_0^*) \left(b^2 \boldsymbol{\Sigma}^* + \frac{1}{m} \boldsymbol{\Sigma}_M^* \right)^{-1} (\boldsymbol{\mu}_1^* - \boldsymbol{\mu}_0^*)^\top.$$

Il faut noter que δ_M dépend de b mais il ne dépend pas de \mathbf{a}^* . Une valeur particulière de δ_M est $\delta = (\boldsymbol{\mu}_1^* - \boldsymbol{\mu}_0^*)(\boldsymbol{\Sigma}^*)^{-1}(\boldsymbol{\mu}_1^* - \boldsymbol{\mu}_0^*)^\top$ correspondant au cas "sans erreur de mesure", c'est-à-dire lorsque $\boldsymbol{\Sigma}_M^* = \mathbf{0}$ et $b = 1$. L'erreur de type II de la carte de contrôle Hotelling CoDa T^2 avec les erreurs de mesure sont $\beta = F_{\chi^2}(\text{UCL} | p - 1, \delta_M)$ et le ARL hors-contrôle correspondant est $\text{ARL}_1 = \frac{1}{1 - \beta}$. Idéalement, nous voulons un ARL élevé lorsque le processus est sous-contrôle et un ARL faible lorsque le processus est hors-contrôle.

Comme indiqué dans [30], les cartes de contrôle multivariées basé sur des covariables (c'est-à-dire l'équation (2.37)) ne possèdent la propriété d'invariance directionnelle aux changements de le vecteur moyenne (ici $\bar{\mathbf{x}}_i^*$) et, en présence de mesure erreurs, ces cartes de contrôle multivariées sont donc plus puissantes à détecter des changements dans certaines directions que dans d'autres. Afin de surmonter ce problème, Linna et al. [30] a suggéré de calculer δ_{\min} et δ_{\max} comme minimum et maximum valeurs de δ_M correspondant à une valeur fixe de δ . En utilisant les résultats de l'annexe A dans [45], il peut être prouvé que

$$\begin{aligned} \delta_{\min} &= \delta \lambda_1, \\ \delta_{\max} &= \delta \lambda_{p-1}, \end{aligned}$$

où λ_1 et λ_{p-1} sont les plus petites et les plus grandes valeurs propres de la matrice $(p - 1, p - 1) b^2 \boldsymbol{\Sigma}^* (b^2 \boldsymbol{\Sigma}^* + \frac{1}{m} \boldsymbol{\Sigma}_M^*)^{-1}$, respectivement. Une fois que δ_{\min} et δ_{\max} sont évalués, il est possible de calculer les erreurs minimales et maximales de Type II $\beta_{\min} = F_{\chi^2}(\text{UCL} | p - 1, \delta_{\min})$ et $\beta_{\max} = F_{\chi^2}(\text{UCL} | p - 1, \delta_{\max})$ ainsi que le les ARL hors-contrôle minimum et maximum correspondants, $\text{ARL}_{1,\min} = \frac{1}{1 - \beta_{\min}}$ et $\text{ARL}_{1,\max} = \frac{1}{1 - \beta_{\max}}$. Ces valeurs doivent être considéré comme étant les ARL hors-contrôle "meilleur" et "pire" de la carte de contrôle Hotelling CoDa T^2 en présence de erreurs de mesure pour une valeur fixe de δ .

Les principales conclusions tirées de ces investigations sont : i) si b et m sont maintenus constants, le ARL augmente lorsque la valeur de σ_M augmente, ii) si σ_M et m sont maintenus constants, le ARL diminue à mesure que la valeur de b augmente, iii) si σ_M et b sont conservés constante, le ARL diminue (lentement) à mesure que la valeur de m augmente [45].

2.2.2.3 Performance de la carte de contrôle MEWMA-CoDa dans la présence d'erreurs de mesure

Lorsque le processus est sous-contrôle, nous supposons que $\mathbf{y}_i \sim \text{MNOR}_{\mathcal{S}^p}(\boldsymbol{\mu}_0^*, \boldsymbol{\Sigma}^*)$ et, lorsque le processus est hors contrôle, nous supposons que $\mathbf{y}_i \sim \text{MNOR}_{\mathcal{S}^p}(\boldsymbol{\mu}_1^*, \boldsymbol{\Sigma}^*)$ où $\boldsymbol{\mu}_0^*$ et $\boldsymbol{\mu}_1^*$ sont les vecteurs moyens sous-contrôle et hors-contrôle, respectivement, et $\boldsymbol{\Sigma}^*$ est la matrice de variance-covariance supposée inchangée dans les deux cas. Selon le modèle d'erreur de mesure à covariables linéaires décrite dans la section précédente, la statistique suivie par la carte de contrôle MEWMA-CoDa avec erreurs de mesure [8] est

$$Q_i^* = \mathbf{w}_i^* \boldsymbol{\Sigma}_{\mathbf{w}_i^*}^{-1} \mathbf{w}_i^{*\top}, \quad (2.41)$$

avec

$$\mathbf{w}_i^* = r(\bar{\mathbf{x}}_i^* - \mathbf{a}^* - b\boldsymbol{\mu}_0^*) + (1-r)\mathbf{w}_{i-1}^*, \quad (2.42)$$

où $\bar{\mathbf{x}}_i^* = \text{ilr}(\bar{\mathbf{x}}_i)$, $\mathbf{w}_0^* = \mathbf{0}$ et $0 < r \leq 1$ est un paramètre de lissage. La carte de contrôle MEWMA-CoDa avec des erreurs de mesure émet un signal d'avertissement lorsque $Q_i^* > H$ où $H > 0$ est une limite de contrôle supérieure spécifiée et $\boldsymbol{\Sigma}_{\mathbf{w}_i^*}$ est la matrice de variance-covariance de \mathbf{w}_i^* . La matrice de variance-covariance asymptotique proposée par [48] sera utilisée dans la suite du chapitre, c'est-à-dire

$$\boldsymbol{\Sigma}_{\mathbf{w}_i^*} = \frac{r}{(2-r)} \boldsymbol{\Sigma}_{\bar{\mathbf{x}}^*} = \frac{r}{(2-r)} \left(b^2 \boldsymbol{\Sigma}^* + \frac{1}{m} \boldsymbol{\Sigma}_M^* \right). \quad (2.43)$$

En pratique, la carte de contrôle MEWMA-CoDa avec erreurs de mesure peut être mise en œuvre en 3 phases :

1. A "Phase 0" (étalonnage) où les paramètres de mesure \mathbf{a}^* (ou \mathbf{a}), b et $\boldsymbol{\Sigma}_M^*$ doivent être estimés à partir d'un échantillon de référence spécifique, mesuré m fois aux fins du calage et en utilisant la méthode d'estimation fournie à l'annexe B de [45].
2. A Phase I où les paramètres de la carte de contrôle $\boldsymbol{\mu}_0^*$ et $\boldsymbol{\Sigma}^*$ doivent être estimés à partir d'un jeu de données CoDa supposé en contrôle $\mathbf{x}_{i,j}$. Ces estimateurs peuvent être obtenus en calculant $\bar{\mathbf{x}}_i$ et $\bar{\mathbf{x}}_i^*$, en estimant le vecteur moyen $\hat{\boldsymbol{\mu}}_{\bar{\mathbf{x}}}^*$ et la matrice de variance-covariance $\hat{\boldsymbol{\Sigma}}_{\bar{\mathbf{x}}}^*$ du $\bar{\mathbf{x}}_i^*$ et, enfin, en résolvant des equations (2.38) et (2.39) pour $\hat{\boldsymbol{\mu}}_0^*$ et $\hat{\boldsymbol{\Sigma}}_M^*$, c'est-à-dire

$$\hat{\boldsymbol{\mu}}_0^* = \frac{1}{\hat{b}} (\hat{\boldsymbol{\mu}}_{\bar{\mathbf{x}}}^* - \hat{\mathbf{a}}^*), \quad (2.44)$$

$$\hat{\boldsymbol{\Sigma}}^* = \frac{1}{\hat{b}^2} \left(\hat{\boldsymbol{\Sigma}}_{\bar{\mathbf{x}}}^* - \frac{1}{m} \hat{\boldsymbol{\Sigma}}_M^* \right). \quad (2.45)$$

3. Une phase II où un ensemble de données CoDa entrant $\mathbf{x}_{i,j}$ (mesuré m fois) doit être surveillé pour détecter d'éventuels changements dans le processus. A chaque fois $i = 1, 2, \dots$, la procédure de surveillance consiste à calculer $\bar{\mathbf{x}}_i$, $\bar{\mathbf{x}}_i^*$, \mathbf{w}_i^* en utilisant (2.42) de manière récursive, Q_i^* en utilisant (2.41) et un signal hors-contrôle est déclenché au temps i si $Q_i^* > H > 0$.

Lowry et al. [48] a prouvé que les performances des cartes de contrôle MEWMA dépendent du paramètre de non-centralité δ . Lorsqu'il y a des erreurs de mesure présentes dans le processus, les performances des cartes de contrôle MEWMA dépendent du paramètre de non-centralité δ δ_M . Le ARL de la carte de contrôle MEWMA-CoDa

(avec ou sans erreurs de mesure) peut être obtenu en utilisant une méthode de chaîne de Markov dédiée. Cette méthode est complexe et ne sera pas détaillée dans ce chapitre. Les lecteurs intéressés par la mise en œuvre de cette méthode de chaîne de Markov doivent se référer à [43].

Dans ce chapitre, au temps $i = 1, 2, \dots$, la taille de l'échantillon est supposée être $n = 1$ et nous ne pouvons surveiller les changements dans le vecteur moyen de composition qu'en utilisant l'approche MEWMA. Maintenant, si nous relâchons cette contrainte et que nous autorisons $n > p$, alors il devient également possible de surveiller (sans la fonctionnalité MEWMA) la composition *variabilité* en utilisant l'approche dérivée de [49] qui suggère d'utiliser le statistique W_i définie comme

$$W_i = \frac{(n-1)|\hat{\Sigma}_i^*|^{1/p}}{|b^2 \Sigma^* + \frac{1}{m} \Sigma_M^*|^{1/p}}.$$

Cette statistique est connue pour suivre exactement une distribution gamma des paramètres $a = \frac{p(np)}{2}$ et $b = \frac{2}{p} \left(1 - \frac{(p-1)(p-2)}{2n}\right)^{-1/p}$ quand $p \leq 2$ et, pour suivre approximativement cette distribution, quand $p > 2$. Cela permet de définir une limite de contrôle supérieure pour W_i comme $UCL = F_G^{-1}(1 - \alpha_0 | a, b)$ où α_0 est l'erreur de type I et $F_G^{-1}(\dots | a, b)$ est la fonction de distribution cumulative inverse de la distribution gamma des paramètres a et b et, par conséquent, cette approche permet de surveiller le CoDa.

TABLEAU 2.1 – Comparaison en termes de ARLs hors-contrôle entre les cartes de contrôle Hotelling CoDa T^2 et MEWMA-CoDa en présence d'erreur de mesure [8]

δ	Paramètres		Hotelling CoDa T^2						MEWMA-CoDa						Pourcentage de performances					
	σ_M	b	m	Case#1		Case#2		Case#1		Case#2		Case#1		Case#2		Case#1		Case#2		
				ARL _{min}	ARL _{max}	ARL _{min}	ARL _{max}	ARL _{min}	ARL _{max}	ARL _{min}	ARL _{max}	ARL _{min}	ARL _{max}	Δ_{min}	Δ_{max}	Δ_{min}	Δ_{max}	Δ_{min}	Δ_{max}	
0.25	0.1	1	3	314.78	336.99	312.24	340.83	92.69	92.98	93.23	92.98	70.56	72.41	70.15	72.72					
0.25	0.3	1	3	346.46	357.35	345.06	359.01	95.63	96.52	95.22	97.26	72.4	73	72.41	72.91					
0.25	0.6	1	3	357.35	363.43	356.54	364.32	100.05	101.82	99.23	103.32	72.01	71.99	72.18	71.65					
0.25	0.3	0.25	3	368.31	369.15	368.2	369.27	159.51	171.77	153.57	181.65	56.7	53.47	58.3	50.81					
0.25	0.3	1	3	346.46	357.35	345.06	359.01	95.63	96.52	95.22	97.26	72.4	73	72.41	72.91					
0.25	0.3	8	3	216.63	228.9	215.75	232.5	91.29	91.3	91.28	91.31	57.87	60.12	57.7	60.73					
0.25	0.3	1	1	361.35	365.57	360.78	366.17	104.48	107.13	103.24	109.37	71.09	70.7	71.39	70.14					
0.25	0.3	1	3	346.46	357.35	345.06	359.01	95.63	96.52	95.22	97.26	72.4	73	72.41	72.91					
0.25	0.3	1	6	328.68	346.46	326.53	349.36	32.95	33.11	93.22	94.24	89.98	90.45	71.46	73.03					
0.75	0.1	1	3	237.85	283.92	233.05	292.73	18.02	18.08	17.99	18.13	92.43	93.64	92.29	93.81					
0.75	0.3	1	3	306.2	334.11	302.78	338.59	18.62	18.8	11.98	12.25	93.93	94.38	96.05	96.39					
0.75	0.6	1	3	334.11	350.86	331.92	353.39	19.52	19.89	19.35	20.2	94.16	94.34	94.18	94.29					
0.75	0.3	0.25	3	364.97	367.46	364.62	367.82	33.22	36.69	31.65	39.76	90.9	90.02	91.33	89.2					
0.75	0.3	1	3	306.2	334.11	302.78	338.59	18.62	18.8	11.98	12.25	93.93	94.38	96.05	96.39					
0.75	0.3	8	3	104.1	116.31	103.26	120.08	17.74	17.74	17.74	17.74	82.97	84.75	82.83	85.23					
0.75	0.3	1	1	345.03	356.95	343.44	358.71	20.44	20.99	20.18	21.47	94.08	94.12	94.13	94.02					
0.75	0.3	1	3	306.2	334.11	302.78	338.59	18.62	18.8	11.98	12.25	93.93	94.38	96.05	96.39					
0.75	0.3	1	6	265.73	306.2	261.21	313.38	18.17	18.26	18.13	18.34	93.17	94.04	93.07	94.16					
2	0.1	1	3	137.9	197.68	132.58	211.16	3.97	3.99	3.97	4	97.13	97.99	97.02	98.11					
2	0.3	1	3	233.29	285.76	227.48	295.15	4.11	4.15	4.09	4.19	98.25	98.55	98.21	98.59					
2	0.6	1	3	285.76	322.39	281.29	328.31	4.32	4.4	4.28	4.47	98.5	98.64	98.49	98.64					
2	0.3	0.25	3	356.82	363.29	355.93	364.22	7.59	8.42	7.21	9.15	97.88	97.69	97.98	97.49					
2	0.3	1	3	233.29	285.76	227.48	295.15	4.11	4.15	4.09	4.19	98.25	98.55	98.21	98.59					
2	0.3	8	3	33.99	40.31	33.58	42.37	3.91	3.91	3.91	3.91	88.51	90.31	88.37	90.78					
2	0.3	1	1	309.16	336.83	305.64	341.12	4.53	4.65	4.47	4.76	98.54	98.62	98.55	98.61					
2	0.3	1	3	233.29	285.76	227.48	295.15	4.11	4.15	4.09	4.19	98.25	98.55	98.21	98.59					
2	0.3	1	6	172.08	233.29	166.14	245.88	4.01	4.03	4	4.05	97.68	98.28	97.6	98.36					
												86.59	87.01	86.19	86.5					

Dans cette section, nous fixons d'abord le contrôle ARL des cartes de contrôle Hotelling CoDa T^2 et MEWMA-CoDa en présence d'erreurs de mesure à 370. Dans la table Table 2.1, nous comparons les performances hors-contrôle des cartes de contrôle Hotelling CoDa T^2 et MEWMA-CoDa en présence d'erreurs de mesure pour plusieurs combinaisons de $\sigma_M \in \{0.1, 0.3, 0.6\}$, $b \in \{0.25, 1, 8\}$, $m \in \{1, 3, 6\}$ (un de ces paramètres varie et les autres restent fixes) et pour plusieurs valeurs du décalage $\delta \in \{0.25, 0.75, 2\}$. Pour les cartes de contrôle Hotelling CoDa T^2 et MEWMA-CoDa, les valeurs les meilleures (ARL_{\min}) et les pires (ARL_{\max}) ARL sont fournies pour les deux cas #1 (non corrélé) et cas #2 (corrélé) ainsi que leurs indicateurs de pourcentage d'amélioration $\Delta_{\min} = \frac{100(ARL_{\min}^{(T^2)} - ARL_{\min}^{(MEWMA)})}{ARL_{\min}^{(T^2)}}$ et $\Delta_{\max} = \frac{100(ARL_{\max}^{(T^2)} - ARL_{\max}^{(MEWMA)})}{ARL_{\max}^{(T^2)}}$. Les valeurs ARL pour la carte de contrôle Hotelling T^2 CoDa ont déjà été obtenues dans [45]. De Table 2.1, nous pouvons tirer les conclusions suivantes :

- Quel que soit le cas (corrélé ou non corrélé), la carte de contrôle MEWMA-CoDa a clairement la meilleure valeur ARL_{\min} la plus petite et la pire valeur ARL_{\max} par rapport à la valeur Hotelling CoDa *Cartedecontrôle* T^2 . Par exemple, lorsque $\sigma_M = 0.3$, $b = 1$, $m = 3$ et $\delta = 0.25$ les meilleures et les pires valeurs ARL pour la carte de contrôle Hotelling CoDa T^2 est ($ARL_{\min} = 346.46$, $ARL_{\max} = 357.35$) pour le cas #1 et ($ARL_{\min} = 345.05$, $ARL_{\max} = 359.01$) pour le Cas #2 tandis que, pour la carte de contrôle MEWMA-CoDa, ces valeurs sont ($ARL_{\min} = 95.65$, $ARL_{\max} = 96.51$) pour le Cas #1 et ($ARL_{\min} = 95.21$, $ARL_{\max} = 97.26$) pour le cas #2.
- Au niveau de leurs indicateurs de pourcentage d'amélioration, nous pouvons voir que, selon les paramètres σ_M , b , m et le niveau de décalage δ , la carte de contrôle MEWMA-CoDa est entre 70% à 90% plus efficace que la carte de contrôle Hotelling CoDa T^2 . Plus précisément (voir la dernière ligne de Table 2.1), pour le Cas #1, la carte de contrôle MEWMA-CoDa est en moyenne 86,59% plus efficace que la carte Hotelling CoDa T^2 pour ARL_{\min} et 87,01% plus efficace pour ARL_{\max} et, pour le cas #2, ce dernier est en moyenne 86,19% plus efficace que le premier pour ARL_{\min} et 86,5% plus efficace pour ARL_{\max} (c'est-à-dire que la carte de contrôle MEWMA-CoDa est environ 86%-87% plus efficace que la carte Hotelling CoDa T^2 dans le présence d'erreurs de mesure).

2.3 Application de l'apprentissage automatique pour la surveillance et la détection d'anomalies dans la fabrication

Dans cette section, nous présentons une application de la carte de contrôle basée sur apprentissage automatique pour la surveillance et la détection précoce des défauts dans le roulement [1]. La détection d'anomalies dans les signaux de vibration est une technique importante pour la surveillance, la détection précoce de la défaillance et le diagnostic des pannes pour les machines tournantes. Très récemment, [50], [51] et, [4] ont développé des méthodes très efficaces avec les réseaux de mémoire à long terme (en anglais Long Short Term Memory networks, LSTM) et les techniques d'autoencodeur LSTM pour détecter les anomalies pour les données de séries temporelles multivariées. Dans cette étude de cas, nous combinerons ces deux méthodes pour proposer une

nouvelle carte de contrôle basée sur l'apprentissage automatique qui effectue la détection d'anomalies dans un contexte industriel. D'après [4], nous supposons que l'autoencodeur LSTM a été entraîné à partir d'une séquence normale $\{\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_N\}$, où N est le nombre d'échantillons et $\mathbf{x}_t = \{x_t^{(1)}, x_t^{(2)}, \dots, x_t^{(k)}\}, t = 1, 2, \dots$ est la valeur de la série chronologique multivariée à l'instant t avec k nombre de variables (ces notations proviennent de la section précédente). En utilisant une fenêtre glissante de taille m , l'autoencodeur entraîné LSTM peut lire la séquence d'entrée $\mathbf{X}_i = \mathbf{x}_t, \dots, \mathbf{x}_{t-m+1}$, encodez-le et recréez-le dans la sortie $\hat{\mathbf{X}}_i = (\hat{\mathbf{x}}_t, \dots, \hat{\mathbf{x}}_{t-m+1})$, avec $i = m + 1, \dots, N$. Puisque ces valeurs ont été observées à partir des données, on peut calculer l'erreur de prédiction $e_i = \|\hat{\mathbf{X}}_i - \mathbf{X}_i\|$, $i = m + 1, \dots, N$. La détection d'anomalie est alors basée sur ces erreurs de prédiction. La distribution des scores d'anomalie de l'ensemble de données d'apprentissage est illustrée à la Figure 2.1. Dans de nombreuses études, ces vecteurs d'erreur sont supposés suivre une distribution gaussienne, puis utilisent la méthode d'estimation du maximum de vraisemblance pour estimer les paramètres de cette distribution. Cependant, on peut soutenir que l'hypothèse d'une distribution gaussienne pour les vecteurs d'erreur peut ne pas être vraie en pratique. Pour surmonter l'inconvénient de cette méthode, [50] a proposé d'utiliser la carte de contrôle d'estimation de quantile de noyau (KQE) ([52]) pour déterminer automatiquement un seuil de détection d'anomalies de séries chronologiques. En particulier, au nouveau temps t , si $e_t > \tau$, x_t est classé comme point d'anomalie et vice versa, voir [50] pour plus de détails.

Les données expérimentales ont été générées à partir d'un banc d'essai de roulements capable de produire des données allant jusqu'à la défaillance. Ces données ont été téléchargées depuis le Centre d'excellence en pronostics (en anglais Prognostics Center of Excellence) via un référentiel de données pronostiques fourni par le Système de maintenance intelligent (en anglais Intelligent Maintenance System), l'Université de Cincinnati ([53]). Selon ([53]), les signaux de vibrations étaient collectés toutes les 10 minutes avec un taux d'échantillonnage des données de 20 kHz et la longueur des données était de 20 480 points de données du capteur.

Cette carte de contrôle basée sur l'apprentissage automatique permet une surveillance conditionnelle et une prédiction du dysfonctionnement à venir du roulement bien avant la défaillance physique réelle. Il permet de définir automatiquement une valeur seuil pour signaler les anomalies tout en évitant trop de faux positifs en conditions normales de fonctionnement. La détection précoce d'une défaillance du roulement est illustrée sur la Figure 2.2, la défaillance du roulement est confirmée à la fin de cette expérience ([53]). Cette approche prometteuse pourrait fournir un outil parfait pour permettre la mise en œuvre de la maintenance prédictive dans la fabrication intelligente.

2.4 Conclusions

À travers ce chapitre, nous avons présenté des contributions importantes à la surveillance des données de ratio, des données de composants avec des cartes de contrôle avancées pour améliorer les performances de détection des anomalies dans le processus avec des décalages petits et moyens. En outre, des modèles d'erreur de mesure ont également été développés pour ces types de cartes de contrôle afin de




FIGURE 2.1 – Distribution des scores d'anomalies de l'ensemble de données d'entraînement [1]




FIGURE 2.2 – Détection d'anomalies de défaillance de roulement [1]

rendre leur application aux processus du monde réel plus efficace. Enfin, l'application de l'apprentissage automatique dans la conception de cartes de contrôle pour la fabrication intelligente est discutée. Nous avons également des contributions ce domaine pour développer de nouvelles cartes de contrôle pour surveiller le ratio ([54], [55], [56], [57], [58]), la médiane ([59], [60], [61], [62], [63], [64]), statistique de signe ([65], [66]), la statistique t [67], [68], le coefficient de variation ([69], [70], [71], [72]), le coefficient de variation multivarié ([73], [74], [75], [75], [76], [77]). Cependant, par souci de concision, nous ne les présentons pas en détail dans cette thèse. Ce sujet de recherche est également publié dans un livre édité [78] pour souligner son importance, discuter de nouvelles directions de recherche

et encourager l'application des cartes de contrôle et de l'apprentissage automatique aux processus de fabrication. Ce chapitre est écrit principalement sur les travaux de 2 thèses soutenues (Mme. Fatima Sehar Zaidi et M. Adel Nadi) et 2 post-doctorants (M. Huu Du Nguyen, M. Quoc Thong Nguyen). Cette direction de recherche se poursuivra avec 2 doctorants (M. Moussab Orabi, Mme. Van Nguyen Thi Thuy).

Chapitre 3 :

Contributions à la modélisation et l'optimisation de la production avec l'apprentissage automatique et l'apprentissage par renforcement

3.1 Introduction

Nous assistons maintenant au développement rapide et à l’application puissante de technologies de pointe, conduisant à l’Industrie 4.0 [79]. La numérisation change tous les aspects de la société et de l’industrie. Les capteurs intégrant la technologie IoT (en anglais Internet of Things) sont de plus en plus utilisés dans le processus de transformation numérique des entreprises. L’utilisation généralisée des systèmes cyber-physiques et de l’IoT a conduit à l’ère du Big Data. La masse, la complexité et l’hétérogénéité des flux de données nécessitent des technologies informatiques avancées qui sont désormais exécutées efficacement grâce à la disponibilité de l’intelligence artificielle (IA, ou AI en anglais pour Artificial Intelligence) et du cloud computing [80]. L’industrie 4.0 peut fournir des solutions automatiques à la fabrication. Cependant, il existe de nombreux défis dans l’industrie 4.0 tels que des cycles de vie des produits plus courts, le besoin de ressources pour concevoir, fabriquer et contrôler la qualité, que les processus de prise de décision dans les entreprises deviennent extrêmement complexes et nécessitent de plus en plus de connaissances [80].

En particulier, la fabrication de textiles est l’une des manufacturières traditionnelles typiques qui sont généralement basées sur des petites et moyennes entreprises avec une capacité limitée d’investir dans des technologies d’ingénierie de pointe [81]. Elle repose fortement sur la personnalisation des produits et des cycles de fabrication courts, car les distributeurs et les consommateurs recherchent de plus en plus la variété et la personnalisation. La vive concurrence mondiale pousse les entreprises de ce domaine industriel à relever les défis de la réduction des coûts et de l’amélioration des performances, tandis que les préoccupations croissantes du public vis-à-vis de l’environnement, d’autre part, imposent des limites supplémentaires aux fabricants de textiles sur l’exploitation de l’énergie, de l’eau, et les ressources associées. C’est pourquoi davantage d’efforts sont nécessaires dans l’industrie textile pour évoluer vers une fabrication intelligente (en anglais Smart Manufacturing, SM). La construction de modèles de processus et le développement d’un système d’aide à la décision sur des modèles de processus virtuels pour optimiser les solutions de processus textiles reste un défi ouvert [82].

Étant donné que la fabrication textile consiste en une très longue chaîne de valeur de processus allant des matières premières aux produits finis (un bref exemple est fourni dans la Figure 3.8), les combinaisons de processus et de paramètres à différentes étapes pourraient être stochastiques et immenses lorsque les facteurs de la performance ciblée varient à tous égards [83, 84, 85]. Et en raison du nombre de facteurs tels que l’augmentation de la complexité des composants (ou produits), il est difficile d’obtenir le scénario optimal d’un processus de fabrication textile. Pendant ce temps, la performance du processus textile est toujours régie par quelques critères et la qualité de leur signification avec un objectif global est différente [86]. Ainsi, les problèmes d’optimisation dans ce domaine prennent toujours en compte des objectifs multiples. C’est très difficile pour l’optimisation simultanée de plusieurs cibles dans un schéma de production textile à partir d’un espace de grande dimension. Les chercheurs avaient tendance à utiliser des algorithmes pour surmonter les problèmes d’optimisation des processus de fabrication de textiles [87, 88, 89]. Comme on le sait, une méthode heuristique comme l’algorithme génétique prend du temps et peut difficilement être appliquée dans le contexte de la

pratique industrielle, lorsque le nombre de variables est très grand, avec de grands intervalles de changement. Des recherches sur des systèmes d’aide à la décision avec méthodes intelligentes innovantes telles que l’apprentissage par renforcement pour optimiser la production industrielle sont nécessaires.

3.2 Un système d’aide à la décision multicritère basé sur l’apprentissage par renforcement en profondeur pour l’optimisation de la production avec l’application en industrie textile

Les facteurs du processus chimique du textile se composent d’effets objectifs et subjectifs, sur lesquels ce chapitre propose un système d’aide à la décision pour optimiser le processus chimique textile en combinant les modèles intelligents basés sur les données de forêt aléatoire (en anglais Random Forest, RF) et la structure multicritères basée sur les connaissances humaines du processus analytique hiérarchique (en anglais Analytic Hierarchy Process, AHP). Ici, la proposition de l’approche d’apprentissage d’ensemble de RF pour modéliser le processus textile réside dans l’excellente capacité d’approximation RF montrée dans une étude précédente ([90]) pour traiter les impacts complexes et incertains des variables du processus textile sur ses performances, alors que l’application de l’AHP, un outil d’aide à la décision multicritères (en anglais Multiple Criteria Decision Making, MCDM), tient au fait qu’il existe quelques critères régissant la qualité de la performance du processus textile et que leur importance avec un objectif global est différente. Pendant ce temps, concernant la complexité croissante en termes de données à grande échelle et d’espace de décision de grande dimension dans le secteur de la fabrication de produits chimiques textiles, ce système développé formule le problème d’optimisation du processus de fabrication de produits chimiques textiles dans un paradigme de processus de décision de Markov (en anglais Markov Decision Process, MDP) et applique un apprentissage par renforcement approfondi (plus précisément, les Deep Q-networks, DQN) au lieu des méthodes actuelles pour aborder de manière collaborative les problèmes d’optimisation dans le processus de fabrication de produits chimiques textiles [2]. Les principales contributions de cette section sont répertoriées ci-dessous :

1. Les incertitudes de la fabrication textile sont chassées par l’approche RF en termes de modélisation des processus.
2. En termes de problèmes MCDM largement existants dans le domaine du textile, AHP est présenté dans cette étude pour travailler en coopération avec les mesures susmentionnées.
3. La formulation de l’optimisation du processus de fabrication textile en tant que problème de processus décisionnel de Markov et la solution basée sur l’algorithme apprentissage par renforcement (en anglais Reinforcement Learning, RL) sont proposées pour la première fois pour traiter les problèmes de prise de décision dans l’industrie textile.
4. L’application de DQN est étendue à l’aide à la décision sur les solutions de fabrication textile. Par rapport aux algorithmes tabulaires RL appliqués dans des

travaux antérieurs connexes, DQN est plus applicable et préférable pour faire face au problème réaliste complexe de l'industrie textile.

5. Construction d'un système d'aide à la décision pour l'optimisation des processus de fabrication de produits chimiques textiles.

3.2.1 Littérature pertinente

Majumdar et al. [88] ont brièvement décrits les méthodes appliquées dans l'industrie textile pour la modélisation des processus (régression linéaire, réseau de neurones artificiels et logique floue), l'optimisation (programmation linéaire, algorithme génétique), et la prise de décision multicritères (AHP). Concernant les techniques intelligentes, l'utilisation combinée de réseaux de neurones artificiels (en anglais Artificial Neural Network, ANN) et d'algorithmes génétiques était généralement le premier choix appliqué par les chercheurs pour traiter les problèmes d'optimisation dans le domaine textile ([91, 92, 93, 94, 95, 96, 97, 98, 99, 100, 101, 102]). Dans la fabrication, l'apprentissage par renforcement offre de nouvelles opportunités aux fabricants qui cherchent à optimiser des processus complexes. Le RL est une approche d'apprentissage automatique utilisant un cadre de MDP bien compris et mathématiquement fondé qui a été largement appliqué pour résoudre les problèmes pratiques d'optimisation et de prise de décision dans l'industrie [103, 104, 105, 106, 107, 108, 109, 110, 111, 112, 113, 114, 115, 116, 117, 118, 119]). Des applications connexes du RL pour la prise de décision ont été rapportées ([120, 121]), cependant, à l'heure actuelle, il n'existe aucune étude complète pour résoudre un problème de production complexe, en particulier dans l'industrie textile. En tant que MCDM le plus fréquemment utilisé et largement discuté de la discipline récemment développée de la recherche opérationnelle, AHP s'est avéré être une méthode de prise de décision extrêmement utile dans l'industrie textile à partir des applications publiées d'AHP estimant la qualité des fibres ([122]) et les tissus ([123]), bien que certains rapports aient soulevé leurs préoccupations sur la base théorique de l'AHP ([100, 101, 124]). Dans le cadre proposé, le RL serait appliqué en coopération avec les modèles RF ([125, 126, 127, 128]) et AHP [129] pour optimiser les solutions du processus de fabrication de produits chimiques textiles par rapport à plusieurs critères.

3.2.2 Contexte

3.2.2.1 Formulation du problème

Suggérer un processus de fabrication de produits chimiques textiles P implique un ensemble de variables de paramètres $\{v_1, v_2, \dots, v_n\}$, et la performance de ce processus est évaluée par des multi-critères de $\{c_1, c_2, \dots, c_m\}$. La prise de décision doit comprendre comment ces variables de paramètres affectent les performances du processus en termes de chaque critère, et si une solution de $P\{v_{1i}, v_{2j}, \dots, v_{nk}\}$ est bon ou pas lié à $\{c_1, c_2, \dots, c_m\}$. Supposons qu'il existe un modèle de cartes v_1, v_2, \dots, v_n du processus à sa performance conformément aux $\{c_1, c_2, \dots, c_m\}$, alors la performance de la solution spécifique pourrait être présentée par :

$$f_i(v_1, v_2, \dots, v_n) | c_i, \text{ pour } i = 1, \dots, m \quad (3.1)$$

Lorsque le domaine de $v_j \in V_j$ est connu, et que le problème multi-critères $\{c_1, c_2, \dots, c_m\}$ pourrait être en quelque sorte représenté par C , l'équation (3.1) pourrait être simplifié en (3.2), et pour que l'objectif des décideurs soit de trouver (3.3) :

$$f(v_1, v_2, \dots, v_n) | C, v_j \in V_j \quad (3.2)$$

$$\operatorname{argmax}_{v_j \in V_j} [f(v_1, v_2, \dots, v_n) | C] \quad (3.3)$$

L'équation (3.3) vise à rechercher la solution optimale des paramètres variables, tandis que l'opération traditionnelle dans ce domaine reposait généralement beaucoup sur les essais et les erreurs.

3.2.2.2 Processus Hiérarchique Analytique pour une optimisation multicritère

Le problème de prise de décision multicritères (MCDM) présenté dans l'équation (3.3) pourrait être résumé comme un problème d'optimisation objectif unique en structurant une hiérarchie de critères en termes de poids ou de priorités :

$$\operatorname{argmax}_{v_j \in V_j} [f(v_1, v_2, \dots, v_n) | C] = \operatorname{argmax}_{v_j \in V_j} \sum_{i=1}^m w_i f_i(v_1, v_2, \dots, v_n) \quad (3.4)$$

où w_1 à w_m sont les poids du critère c_1 à c_m respectivement.

L'AHP est une méthode MCDM introduite par Saaty [129] qui utilise une méthode typique de comparaison par paires pour extraire les poids relatifs des critères et des scores alternatifs et transforme un problème multicritères en paradigme de l'équation (3.4). Surtout, il construit une matrice de comparaison par paires d'attributs à l'aide d'une échelle d'importance relative en neuf points, dans laquelle le nombre 1 désigne un attribut par rapport à lui-même ou à tout autre attribut aussi important que lui, les nombres de 2, 4, 6, et 8 indiquent des valeurs intermédiaires entre deux jugements adjacents, tandis que les nombres 3, 5, 7 et 9 correspondent respectivement à des jugements comparatifs "importance modérée", "importance forte", "importance très forte" et "importance absolue". Une matrice de comparaison typique (C_m) de $m \times m$ pourrait être établie pour les critères m comme démontré ci-dessous :

$$C_m = \begin{bmatrix} 1 & \dots & a_{1m} \\ \vdots & \ddots & \vdots \\ a_{m1} & \dots & 1 \end{bmatrix} \quad (3.5)$$

où a_{ij} représente l'importance relative du critère c_i par rapport au critère c_j . Ainsi $a_{ij} = 1/a_{ji}$ et $a_{ij} = 1$ lorsque $i = j$. A noter qu'un indice de cohérence (CI) est introduit dans AHP avec un ratio de cohérence (CR) sur la base du vecteur propre principal (λ_{max}) pour valider la cohérence dans la matrice de comparaison par paires :

$$CI = \frac{\lambda_{max} - m}{m - 1} \quad \text{and} \quad CR = \frac{CI}{RCI} \quad (3.6)$$

Où RCI est un indice de cohérence aléatoire et les valeurs de celui-ci sont disponibles

dans [100]. Par la suite, le poids relatif des critères i^{th} (w_i) serait calculé par la moyenne géométrique du vecteur propre principal, la ligne i^{th} (GM_i), de la matrice ci-dessus , puis en normalisant les moyennes géométriques des lignes :

$$GM_i = \left\{ \prod_{j=1}^m a_{ij} \right\}^{\frac{1}{m}} \quad \text{et} \quad w_i = \frac{GM_i}{\sum_{i=1}^m GM_i} \quad (3.7)$$

3.2.2.3 Le processus décisionnel de Markov

Le RL est un algorithme d'apprentissage automatique qui trie le processus de décision de Markov dans la formule d'un tuple : S, A, T, R , où S est un ensemble d'états d'environnement, A est un ensemble d'actions, T est une fonction de transition, R est un ensemble de récompenses ou de pertes. Un agent dans un environnement MDP apprendrait comment agir à partir de A en observant l'environnement avec les états de S , selon la probabilité de transition correspondante T et la récompense R obtenue à partir de l'interaction. La propriété de Markov indique que les transitions d'état ne dépendent que de l'état actuel et que l'action en cours est entreprise, mais indépendante de tous les états et actions antérieurs ([130]). Comme on sait qu'un processus de fabrication de produits chimiques textiles a un certain nombre de variables de paramètres telles que $P\{v_1, v_2, \dots, v_n\}$, si la valeur probable de v_j est $p(v_j)$, le paramètre de le processus définissant l'espace d'environnement ψ de $\prod_{j=1}^n p(v_j)$, $v_j \in V_j$ impactant les performances du processus textile au regard des critères $\{c_1, c_2, \dots, c_m\}$. Ces variables de paramètres sont indépendantes les unes des autres et obéissent à un processus de Markov qui modélise les transitions stochastiques d'un état S_t au pas de temps t à l'état suivant S_{t+1} , où l'état d'environnement au pas de temps t est :

$$S_t = [s_t^{v_1}, s_t^{v_2}, \dots, s_t^{v_n}] \in \psi \quad (3.8)$$

Le RL entraîne un agent à agir de manière optimale dans un environnement donné sur la base de l'observation d'états et de la rétroaction de leur interaction, en acquérant des récompenses et en maximisant les récompenses futures accumulées au fil du temps à partir de l'interaction ([130]). Ici, l'agent apprend dans l'interaction avec l'environnement en prenant des actions qui peuvent être menées sur les variables de paramètre $\in P\{v_1, v_2, \dots, v_n\}$ au pas de temps t . Plus précisément, dans un pas de temps t , l'action de chaque variable v_j pourrait être conservée (0) ou modifiée vers le haut (+) / vers le bas (-) dans la plage donnée avec une unité spécifique u_j . Il y a donc 3^n actions totalement dans l'espace d'action et, pour simplifier, le vecteur d'action A_t au pas de temps t pourrait être :

$$A_t = [a_t^{v_1}, a_t^{v_2}, \dots, a_t^{v_n}], \quad \text{où} \quad a_t^{v_j} \in \{-u_j, 0, +u_j\}, \quad v_j \in V_j \quad (3.9)$$

Les probabilités de transition d'état, comme mentionné, ne dépendent que de l'état actuel S_t et de l'action A_t . Il spécifie comment l'agent de renforcement prend l'action A_t au pas de temps t pour passer de S_t à l'état suivant S_{t+1} en termes de $T(S_{t+1}|S_t, A_t)$. Pour tout $a_t^{v_j} \in \{-u_j, 0, +u_j\}$, $v_j \in V_j$, $T(S_{t+1}|S_t, A_t) > 0$ et $\sum_{S_{t+1} \in \psi} T(S_{t+1}|S_t, A_t) = 1$. La récompense obtenue par un agent dans un environnement est spécifiquement liée à sa transition entre les états, qui évalue la qualité de la conduite de l'agent de transition et lui permet de converger plus rapidement vers une solution optimale.

3.2.2.4 Algorithme d’apprentissage par renforcement approfondi Q-networks

Les algorithmes RL classiques, tels que le Q-learning et le State-Action-Reward-State-Action (Etat-Action-Récompense-Etat-Action en français), SARSA ($0/\lambda$) sont basés sur une représentation tabulaire à forte intensité de mémoire (c. un état spécifique s (la valeur Q de la paire état-action, alias $Q(s, a)$). Ces algorithmes tabulaires entravent la RL dans des applications réalistes à grande échelle en raison des quantités énormes d’états ou d’actions impliquées. L’expression tabulaire non seulement ne permet pas d’enregistrer tous les $Q(s,a)$ dans ces applications, mais montre également une mauvaise généralisation dans l’environnement avec incertitude. Les réseaux de neurones profonds (en anglais Deep Neural Networks, DNN) sont une autre technique d’apprentissage automatique largement appliquée pour faire face à des problèmes à grande échelle et ont récemment été combinés de manière innovante avec le RL pour évoluer vers des algorithmes DRL (Deep Reinforcement Learning). Deep-Q-network (DQN) est un algorithme DRL développé par [131] en 2015 en tant que premier agent artificiel capable d’apprendre des politiques directement à partir d’entrées sensorielles de grande dimension et d’interactions agent-environnement. Il s’agit d’un algorithme RL proposé basé sur Q-learning, l’un des algorithmes RL sans modèle et basés sur des valeurs les plus utilisés.

L’agent Q-learning apprend en estimant la somme des récompenses r pour chaque état S_t lorsqu’une politique particulière π est exécutée. Il utilise une représentation tabulaire de la valeur $Q^\pi(S_t, A_t)$ pour attribuer la récompense future actualisée r de la paire état-action au pas de temps t dans Q-table. L’objectif de l’agent est de maximiser les récompenses futures accumulées pour renforcer le bon comportement et optimiser les résultats. Dans l’algorithme de Q-learning, le maximum atteignable $Q^\pi(S_t, A_t)$ obéit à l’équation de Bellman sur la base d’une intuition : si la valeur optimale $Q^\pi(S_{t+1}, A_{t+1})$ de toutes les actions réalisables A_{t+1} sur l’état S_{t+1} au prochain pas de temps est connu, alors la stratégie optimale est de sélectionner l’action A_{t+1} maximisant la valeur attendue de $r + \gamma \cdot \max_{A_{t+1}} Q^\pi(S_{t+1}, A_{t+1})$.

$$Q^\pi(S_t, A_t) = r + \gamma \cdot \max_{A_{t+1}} Q^\pi(S_{t+1}, A_{t+1}) \quad (3.10)$$

Selon l’équation de Bellman, la valeur Q du correspondant la cellule de Q-table est mise à jour de manière itérative par :

$$Q^\pi(S_t, A_t) \leftarrow Q^\pi(S_t, A_t) + \alpha \left[r + \gamma \cdot \max_{A_{t+1}} Q^\pi(S_{t+1}, A_{t+1}) - Q^\pi(S_t, A_t) \right] \quad (3.11)$$

où S_t et A_t sont respectivement l’état et l’action actuels, tandis que S_{t+1} est l’état atteint lors de l’exécution de A_{t+1} dans l’ensemble de S et A dans un MDP donné tuples de $\{S, A, T, R\}$. $\alpha \in [0, 1]$ est le taux d’apprentissage, qui indique combien l’agent a appris de la nouvelle expérience de prise de décision ($Q^\pi(S_{t+1}, A_{t+1})$) écraserait l’ancienne mémoire ($Q^\pi(S_t, A_t)$). r est la récompense immédiate, $\gamma \in [0, 1]$ est le facteur de remise déterminant l’horizon de l’agent.

L’agent agit sur un état de l’environnement et l’environnement transmet de manière interactive l’agent à un nouvel état avec un retour de signal de récompense. Le principe de base de l’algorithme Q-learning repose essentiellement sur un processus d’essais et

d’erreurs, mais différent des humains et des autres animaux qui abordent la complexité du monde réel avec une combinaison harmonieuse de systèmes de traitement sensoriel RF et hiérarchiques, la représentation tabulaire de Q-learning n’est pas efficace pour présenter un environnement à partir d’entrées de grande dimension pour généraliser l’expérience passée à de nouvelles situations [131].

Q-table enregistre la valeur Q de chaque état couplée à toutes ses actions réalisables dans un environnement donné, tandis que la complexité croissante du problème de nos jours indique que les états et les actions dans un environnement RL pourraient être innombrables (comme le jeu de Go). À cet égard, DQN applique des DNN au lieu de Q-table pour approximer la fonction de valeur d’action optimale. Les DNN alimentés par l’état pour approximer le vecteur de valeur Q de toutes les actions potentielles, par exemple, sont entraînés et mis à jour par la différence entre la valeur Q dérivée de l’expérience précédente et la récompense actualisée obtenue à partir de l’état actuel. Plus important encore, pour résoudre l’instabilité de RL représentant la valeur Q à l’aide d’un approximateur de fonction non linéaire [132], DQN a proposé de manière innovante deux idées appelées répétition d’expérience [133] et Q-cible fixe (en anglais fixed Q-target). Comme on sait que Q-learning est un RL hors politique, il peut apprendre des états actuels et antérieurs. La relecture d’expérience de DQN est un mécanisme d’inspiration biologique qui apprend à partir de données historiques prises au hasard pour une mise à jour à chaque pas de temps, ce qui supprimerait donc la corrélation dans la séquence d’observation et lisserait les changements dans la distribution des données. Le Q-cible fixe remplit une fonction similaire, mais différemment, elle réduit les corrélations entre la valeur Q et la cible en utilisant une mise à jour itérative qui ajuste périodiquement la valeur Q vers les valeurs cibles.

Plus précisément, les DNN approximent la fonction de valeur Q en termes de $Q(s, a; \theta_i)$ avec les paramètres θ_i qui désignent les poids de Q-networks à l’itération i . L’implémentation du replay d’expérience consiste à stocker les expériences de l’agent $e_t = (S_t, A_t, r_t, S_{t+1})$ à chaque pas de temps t dans un jeu de données $D_t = \{e_1, \dots, e_t\}$. Les mises à jour de Q-learning ont été utilisées pendant l’apprentissage d’échantillons d’expérience, $(S, A, r, S') \sim U(D)$, tirés uniformément au hasard dans le pool d’échantillons stockés. La fonction de perte de la mise à jour de Q-networks à l’itération i est :

$$L_i(\theta_i) = \mathbf{E}_{(S,A,r,S') \sim U(D)} \left[\left(r + \gamma \cdot \max_{A'} Q(S', A'; \theta_i^-) - Q(S, A, \theta_i) \right)^2 \right] \quad (3.12)$$

où θ_i^- sont les poids du réseau d’une itération précédente. Les cibles ici dépendent des poids du réseau ; ils sont fixés avant le début de l’apprentissage. Plus précisément, les paramètres θ_i^- de l’itération précédente sont fixés comme optimisant la fonction de perte i_{th} $L_i(\theta_i)$ à chaque étape et ne sont mis à jour qu’avec θ_i tous les F étapes. Pour implémenter ce mécanisme, DQN utilise deux réseaux structurellement identiques mais paramétriquement différentiels, l’un prédit $Q(S, A; \theta_i)$ en utilisant les nouveaux paramètres θ_i , le reste prédit $r + \gamma \cdot \max_{A'} Q(S', A'; \theta_i^-)$ en utilisant les paramètres précédents θ_i^- . Toutes les étapes F , le réseau Q serait cloné pour obtenir un réseau cible \hat{Q} , puis \hat{Q} serait utilisé pour générer la cible Q-learning $r + \gamma \cdot \max_{A'} Q(S', A'; \theta_i^-)$ pour les mises à jour F suivantes du réseau

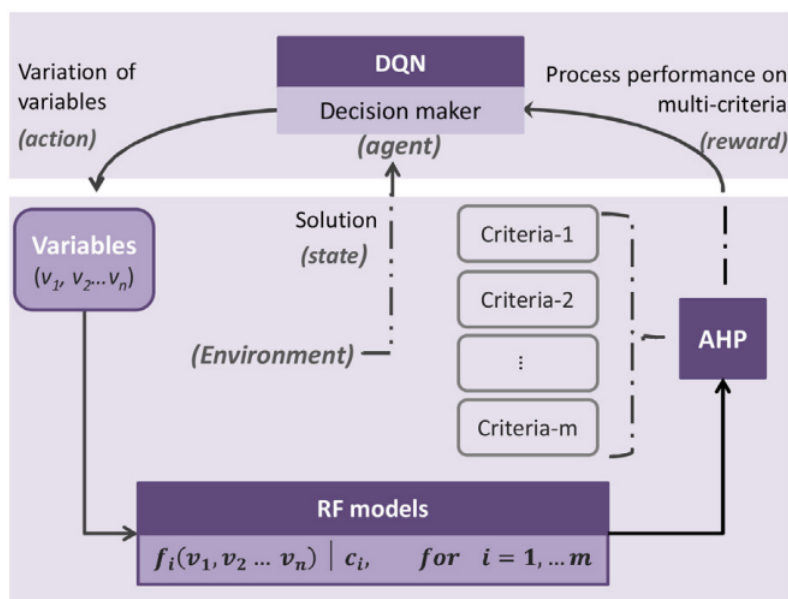


FIGURE 3.1 – La structure MDP de l'optimisation multicritère du processus de fabrication de produits chimiques textiles dans le cadre proposé [2].

Q .

3.2.3 Cadre du système

Figure 3.1 illustre le problème d'optimisation du processus de fabrication de produits chimiques textiles dans le paradigme de RL, où le décideur joue le rôle d'agent pour parcourir et explorer l'espace d'état, l'environnement comprend toutes les variables des paramètres de processus ciblés, l'ajustement des variables de paramètre indique l'action, la solution combinée de toutes les variables de paramètre représente l'état et la fonction objectif indique la récompense. L'objectif du système d'aide à la décision développé est d'optimiser le processus textile en ce qui concerne ses variables de paramètres sur la base de la fonction objectif multicritère qui a été fondamentalement formulée dans l'équation. (3.3). Par conséquent, ici, le retour d'information de l'environnement dépendant d'une fonction de récompense est conforme à la fonction objectif.

La exécution épisodique au sein de l'algorithme est représentée graphiquement dans la Figure 3.2. Outre les paramètres susmentionnés, il est également nécessaire de fournir un ensemble de données d'expérience (D_e) concernant la modélisation du processus textile et les cibles de performance ou d'optimisation attendues du processus (P) à la construction du système. Afin d'équilibrer l'exploration et l'exploitation des états à la période d'apprentissage et à la période d'optimisation respectivement, nous initialisons le premier état de chaque épisode de manière aléatoire à partir de chaque sous-état $s_t^{v_i}$ où les variables de paramètres $v_j \in V_j$, et plus important encore, appliquez une politique croissante de ϵ -greedy en même temps.

En fait, l'algorithme donné ci-dessus peut fonctionner sans épisodes, car la cible d'un agent formé RL est de trouver la solution optimisée, en termes d'état dans l'environnement

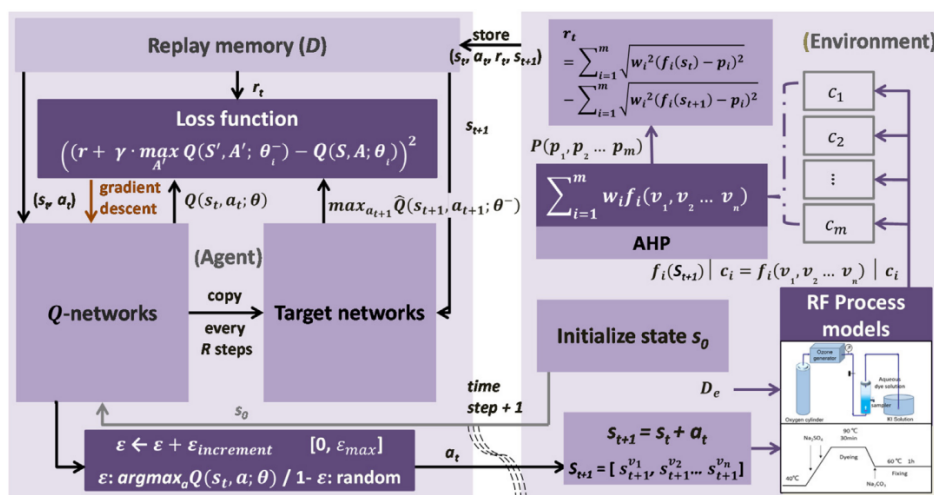


FIGURE 3.2 – Organigramme de l'algorithme mettant en œuvre le système d'aide à la décision multicritère basé sur l'apprentissage par renforcement en profondeur proposé pour l'optimisation du processus de fabrication de produits chimiques textiles [2].

avec un minimum d'erreur testé par les modèles RF et les évaluations AHP, cependant, le manque de l'exploration de l'agent dans un environnement peut provoquer un optimum local en une seule exécution. Nous initialisons donc le premier état de manière aléatoire et introduisons un processus d'apprentissage épisodique à l'agent pour élargir l'exploration et empêcher l'optimum local. D'un autre côté, nous appliquons également la politique croissante de ϵ -greedy. La politique ϵ -greedy aide l'agent à trouver la meilleure action (valeur Q maximale) dans l'état actuel pour passer à l'état suivant avec une possibilité de ϵ qui peut également choisir au hasard une action avec une possibilité de $1 - \epsilon$ pour obtenir un état suivant aléatoire. Tandis que, l'augmentation de ϵ -greedy est utilisée avec un incrément donné à chaque pas de temps de 0 jusqu'à ce qu'il soit égal à ϵ_{max} . Cela profite à l'agent pour explorer les états inexplorés sans rester dans l'exploitation des états déjà expérimentés de Q-networks, et les exploiter abondamment lorsque les états sont suffisamment parcourus.

3.2.4 Étude de cas

L'application du système d'aide à la décision établi à un processus d'ozonation de la décoloration des textiles a été réalisée pour évaluer la performance du cadre proposé. La décoloration est un processus de finition textile essentiel pour des produits textiles spécifiques tels que le denim afin d'obtenir un style de mode usé ([107]), mais il a été classiquement obtenu par des méthodes chimiques qui ont un coût et une consommation d'eau élevés, ainsi qu'un impact négatif important sur l'environnement. Au lieu de cela, le traitement à l'ozone est un processus de finition avancé utilisant du gaz ozone pour obtenir un denim décoloré sans bain-marie, ce qui entraîne par conséquent moins de problèmes environnementaux. Les complexités de ce processus ont été étudiées dans nos travaux précédents ([134, 135, 136]), et selon les données d'expérience avec 129 échantillons que nous avons collectés à partir de cette application, la configuration du cadre proposé serait tenté de résoudre un problème d'optimisation à 4 cibles du processus d'ozonation par décoloration.

En ce qui concerne l’ensemble de données d’expérience utilisé pour entraîner et tester les modèles RF, il comprend 4 paramètres de processus (teneur en eau, température, pH et temps) du processus et 4 indices de performance de processus connus sous le nom de k/s , L^* , a^* et b^* des tissus traités. Où la valeur k/s indique la profondeur de couleur, tandis que L^* , a^* et b^* illustrent la variation de couleur en trois dimensions (luminosité, composante chromatique du vert au rouge et du bleu au jaune respectivement). Normalement, la couleur du produit textile final en fonction de k/s , L^* , a^* et b^* spécifiques est dans la tolérance acceptable du consommateur.

TABLEAU 3.1 – Le résultat du réglage des hyperparamètres des modèles RF et les résultats de test du modèle optimisé [2]

	Bootstrap	n_estimators	Min_samples_leaf	Min_samples_split	Max_depth	Max_features	R^2	MAE	MAPE
k/s	True	2000	1	2	30	'auto'	0.996	0.28	12.36
L^*	False	2000	1	2	none	'sqrt'	0.954	0.77	8.99
a^*	False	2000	2	2	none	'auto'	0.937	2.29	15.43
b^*	True	2000	1	5	100	'auto'	0.965	2.87	11.62

TABLEAU 3.2 – Matrice de comparaison par paire de k/s , L^* , a^* et b^* par rapport à la performance globale des couleurs [2].

	k/s	L^*	a^*	b^*	GM	w
k/s	1	3	5	5	2.9428	0.556
L^*	1/3	1	3	3	1.3161	0.249
a^*	1/5	1/3	1	2	0.6043	0.114
b^*	1/5	1/3	1/2	1	0.4273	0.081

3.2.4.1 Modélisation du processus d’ozonation par décoloration à l’aide de la forêt aléatoire

En termes de construction du modèle RF, 75 % des données ont été divisés dans le groupe d’apprentissage et les 25 % restants ont été utilisés pour tester les modèles. Afin de diminuer le biais et de favoriser la généralisation des modèles RF appliqués dans le système, nous avons formé 4 modèles distincts pour prédire 4 sorties (k/s , L^* , a^* et b^*) respectivement . Les résultats du réglage des hyperparamètres sont affichés dans le Tableau 3.1, et les modèles optimisés finaux sont testés (25 % avec des données invisibles) qui peuvent bien prédire les performances du processus avec des précisions (R-carré) de 0.996, 0.954, 0.937 et 0.965 respectivement.

3.2.4.2 Détermination des pondérations des critères à l’aide du processus de hiérarchie analytique

En combinant le jugement d’experts avec notre expérience, une matrice de comparaison par paires des 4 critères de décision concernant la performance globale de la couleur du produit textile traité par ozonation est fournie dans le Tableau 3.2. λ_{max} de cette matrice de comparaison est de 4.1042 et on sait que le problème de critères RCI pour 4 est de 0.90, par conséquent, le CR calculé est de $0.0386 \leq 0.08$ ce qui implique que l’évaluation dans la matrice est acceptable.

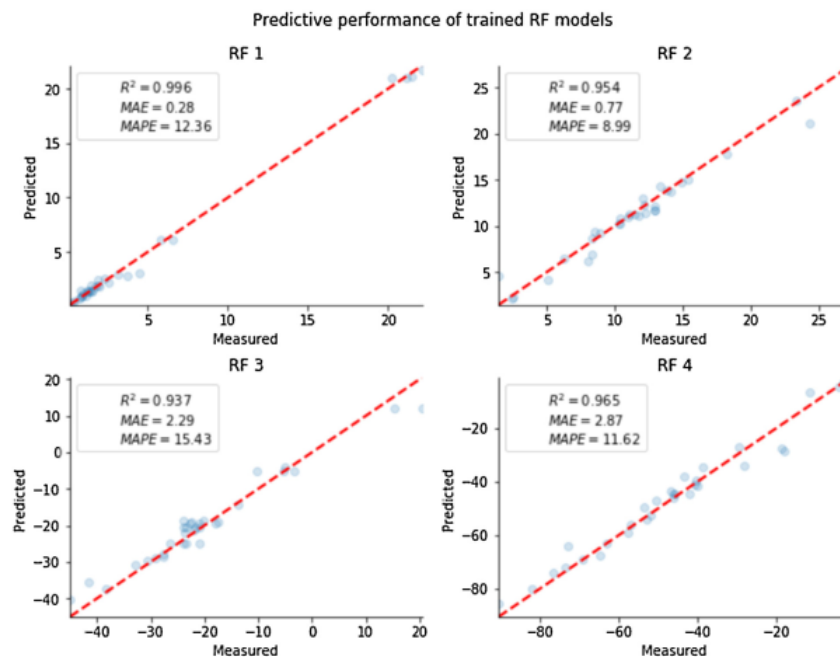


FIGURE 3.3 – Performances prédictives des modèles RF entraînés dans l'étude de cas pour aider à la prise de décision dans le processus d'ozonation des couleurs textiles [2]

3.2.4.3 Q-networks profonds pour une prise de décision optimale

Nous optimisons les performances de couleur en termes de $k/s, L^*, a^*$ et b^* du textile dans le processus d'ozonation en trouvant une solution incluant les variables de paramètres appropriées de teneur en eau, température, pH et un temps de traitement qui minimise la différence entre un tel produit textile traité par un procédé spécifique et l'échantillon ciblé. Par conséquent, l'espace d'état ψ dans ce cas est composé des solutions avec quatre paramètres (teneur en eau, température, pH et temps de traitement) en termes de $S_t = [s_t^{v_1}, s_t^{v_2}, s_t^{v_3}, s_t^{v_4}]$. Dans un pas de temps t , les unités ajustables de ces variables de paramètres sont respectivement 50, 10, 1 et 1 dans la plage de $[0, 150]$, $[0, 100]$, ([83]; [104]; et [90]) respectivement. Comme l'action d'une seule variable v_j peut être conservée (0) ou modifiée vers le haut (+) / vers le bas (-) dans la plage donnée avec l'unité spécifique u , il y a donc $3^4 = 81$ actions totalement dans l'espace d'action et le vecteur d'action au pas de temps t est $A_t = [a_t^{v_1}, a_t^{v_2}, a_t^{v_3}, a_t^{v_4}]$, où $a_t^{v_1} \in \{-50, 0, +50\}$, $v_1 \in [0, 150]$; $a_t^{v_2} \in \{-10, 0, +10\}$, $v_2 \in [0, 100]$; $a_t^{v_3} \in \{-1, 0, +1\}$, $v_3 \in [1, 14]$; $a_t^{v_4} \in \{-1, 0, +1\}$, $v_4 \in [1, 60]$.

La probabilité de transition est de 1 pour les états dans la plage donnée d'espace d'état ci-dessus, mais de 0 pour les états hors de celui-ci. La récompense r au pas de temps t devrait être en ligne avec la distance à laquelle l'agent se rapproche de notre cible, et comme l'importance relative de ces quatre critères de performance (0.556, 0.249, 0.114 et 0.081, respectivement) est analysé dans AHP, nous pourrions mettre en place la fonction de récompense comme illustré ci-dessous pour inciter l'agent à se rapprocher de nos résultats d'optimisation :

$$r_t = \sum_{i=1}^m \sqrt{w_i^2 (f_i(s_t) - p_i)^2} - \sum_{i=1}^m \sqrt{w_i^2 (f_i(s_{t+1}) - p_i)^2} \quad (3.13)$$

Des cibles d’optimisation du processus d’ozonation des textiles sont nécessaires pour faire fonctionner le système (p_1, p_2, p_3, p_4 , les performances de couleur de l’ozonation en termes de $k/s, L^*, a^*$ et b^*), ces cibles dans la présente étude de cas seraient échantillonnées par des experts. En plus des cibles, les paramètres de DQN tels que l’étape R pour la mise à jour de Q-networks et la taille de la mémoire de relecture D , ainsi que le taux d’apprentissage α et le taux d’actualisation γ pour la perte de mise à jour fonction, etc., sont répertoriés dans le Tableau 3.3. En particulier, l’étape R pour la mise à jour de DQN indique ici qu’après des étapes de 100, le Q-networks seraient mis à jour à des étapes de 5.

TABLEAU 3.3 – Paramétrage de l’algorithme DQN dans l’étude de cas du processus d’ozonation textile

R	D	α	γ	$\epsilon_{increment}$	ϵ_{max}	E	N
5 (> 100)	2000	0.01	0.9	0.001	0.9	5	5000

3.2.5 Résultats et discussion

Comme mentionné, il existe quatre modèles RF entraînés pour prédire p_1, p_2, p_3, p_4 des performances de couleur du processus d’ozonation en termes de $k/s, L^*, a^*$ et b^* , respectivement. Les performances prédictives de ces modèles affichées sur la Figure 3.3 indiquent clairement que les modèles fonctionnent régulièrement dans l’algorithme de la présente étude de cas, car il s’avère que les valeurs prédites par les modèles sont généralement conformes aux valeurs réelles mesurées. par les erreurs prédictives de différents modèles variaient légèrement à différents niveaux. Cette découverte reflète en outre que l’approche RF est capable de modéliser le processus de fabrication de produits chimiques textiles et joue un rôle important dans notre système d’aide à la décision proposé. Il convient de noter que les valeurs MAPE des modèles oscillent entre 8 et 15% ce qui en moyenne est légèrement supérieur à 10% (Table 3.1). Ceci est dû au fait que MAPE donne l’écart entre les valeurs prédites et expérimentales pour effectuer la sensibilité des modèles mais les cibles dans ces modèles, c’est-à-dire $k/s, L^*, a^*$ et b^* , sont les valeurs colorimétriques allant de -120 à 120, les données d’échantillons appliquées sont proches de 0 et la plupart sont négatives, ce qui pourrait exagérer l’évaluation de MAPE dans ce numéro ([137]; [138]). Un tel phénomène est également accessible dans les travaux de ([139]; [86]), cela signifie que les modèles entraînés étaient acceptables pour l’effort d’optimisation car les résultats R^2 et MAE étaient plausibles ce qui implique que les modèles ont été capables de capturer les rôles de divers paramètres d’entrée sur les sorties.

En particulier, le Q-networks se compose de deux couches avec respectivement 50 et 34 nœuds cachés, où la dernière couche correspond aux actions. Comme le montre le Tableau 3.4, il y a 5 cibles expérimentales échantillonnées par des experts qui ont été utilisées dans la présente étude de cas. La Figure 3.4 montre la fonction de perte de Q-networks cibles pour chaque scénario. On constate qu’il a convergé rapidement




FIGURE 3.4 – La fonction de perte des réseaux cibles pour chaque scénario avec des cibles différentes [2]




FIGURE 3.5 – Le nombre d'états explorés par l'agent DQN dans chaque épisode pour différents scénarios [2]




FIGURE 3.6 – L'erreur minimale des solutions que l'agent DQN a atteint avec les pas de temps [2]

TABLEAU 3.4 – Les cibles expérimentales échantillonnées par des experts que nous avons utilisées dans l’application de l’étude de cas du système d’aide à la décision proposé [2]

	1	2	3	4	5
k/s	0.81	1.00	2.45	1.84	0.41
L^*	15.76	11.63	8.2	9.72	21.6
a^*	-20.84	-24.08	-18.73	-21.09	-36.48
b^*	-70.79	-54.1	-38.17	-42.78	-59.95




FIGURE 3.7 – Résultats simulés de solutions avec un minimum d’erreurs obtenus respectivement à partir de cadres basés sur DQN et basés sur Q-learning[2]

pour être stable après l’entraînement par les valeurs d’action en retour obtenues de l’environnement aux premiers pas de temps, ce qui dénote que la représentation de la valeur Q dans ce Q-networks est stable et précise. En ce qui concerne les chutes dramatiques au début des étapes de chaque scénario, cela est dû à la politique croissante ϵ -greedy employée dans l’algorithme qui conduit l’agent à choisir une action au hasard avec une probabilité élevée dans une plage de pas de temps de début, mais choisissent de plus en plus l’action avec une valeur élevée après cela. D’autre part, en termes des 5 épisodes que nous avons employés dans chaque scénario, on trouve le maximum d’états non répétés qu’un agent DQN a été exploré qui se sont tous produits dans le premier épisode dans tous les scénarios (Figure 3.5). Cela reflète également que l’augmentation de ϵ a équilibré le processus d’exploration et d’exploitation des états dans l’environnement, et les épisodes de repos bénéficieraient de l’expérience acquise auparavant.

Cette étude de cas a mis en œuvre 5 pistes épisodiques pour chaque scénario avec des cibles différentes dans le cadre proposé. Nous collectons l’erreur minimale des solutions (états) évaluées par RF-AHP lors de l’interaction de l’agent DQN avec les pas de temps de l’environnement. Alors que l’état initial est donné au hasard dans notre système proposé pour éviter l’optimum local, seuls ceux avec les meilleurs résultats sont spécifiquement illustrés sur la Figure 3.6 en ce qui concerne les pas de temps. On constate que la fonction de récompense peut guider efficacement l’agent pour trouver l’optimum dans l’environnement, et les pas de temps pris en 3000 semblent suffisants pour l’optimisation. Cependant, il convient de noter que l’efficacité de la fonction de récompense dans notre système d’aide à la décision proposé n’est toujours pas pleinement illustrée par cette étude de cas. L’une des principales raisons à cela vient des données

limitées sur les processus de fabrication de produits chimiques textiles et de la puissance de calcul coûteuse qui, espérons-le, serait résolue à l’ère de l’industrie 4.0.

Afin de montrer l’avantage et l’efficacité de DQN dans notre système d’aide à la décision proposé, une comparaison avec Q-learning basée sur le même cadre développé est effectuée, et les performances de couleur simulées des résultats en termes de solutions avec un minimum d’erreurs obtenues à partir de deux méthodes sont comparativement démontrées dans la Figure 3.7 avec les cibles. Ici, l’erreur est calculée par l’équation. (3.14), qui sont 1.06, 0.50, 0.88, 0.29, 0.22 et 1.13, 0.54, 0.91, 1.28, 1.76 dans le système d’aide à la décision basé sur DQN et Q-learning pour les scénarios de 1 à 5 respectivement.

$$error = \sqrt{0.556^2(k/s_s - k/s_t)^2 + 0.249^2(L_s^* - L_t^*)^2 + 0.114^2(a_s^* - a_t^*)^2 + 0.081^2(b_s^* - b_t^*)^2} \quad (3.14)$$

Où $k/s_s, L_s^*, a_s^*, b_s^*$ sont les propriétés des performances de couleur simulées de la solution obtenues à partir du système d’aide à la décision, et $k/s_t, L_t^*, a_t^*, b_t^*$ sont les performances de couleur ciblées.

3.3 Optimisation multiobjectif de la production à l’aide d’un apprentissage par renforcement multi-agent basé sur un réseau Q profond avec l’application en industrie textile

Sur la base de l’algorithme d’apprentissage par renforcement profond, le cadre proposé dans la section précédente a été appliqué pour traiter les problèmes d’optimisation multi-objectifs dans le processus de fabrication du textile. Cette section étendrait en outre l’étude de l’algorithme d’apprentissage par renforcement à combiner avec la théorie des jeux en termes de système multi-agents pour faire face aux problèmes d’optimisation multi-objectifs du processus de fabrication de textile formulé. Il est connu que les problèmes d’optimisation multi-objectifs ont été transformés en modèles de théorie des jeux pour être bien résolus, et les développements récents d’un système multi-agents pour optimiser plusieurs objectifs sur la base de la théorie des jeux ont montré son extrême capacité à traiter des fonctions. ayant un espace de grande dimension[140, 141]. D’autre part, l’apprentissage par renforcement multi-agents (en anglais Multi-agent RL, MARL) a été proposé dans de nombreuses contributions pour le contrôle distribué en robotique, les télécommunications, le contrôle des feux de circulation et l’optimisation de la répartition, etc. [142, 143, 144], mais les algorithmes MARL traditionnels peuvent généralement difficilement gérer le problème à grande échelle, son applicabilité était donc très limitée. Alors que ces dernières années, le développement du DRL a obtenu de nombreux résultats exceptionnels, ce qui incite à un nombre croissant d’efforts de recherche portant sur les investigations d’algorithmes et d’applications de DRL dans l’environnement MARL [145]. Bien que des études aient signalé l’utilisation de MARL et DRL pour optimiser la planification des flux de travail, les enchères électroniques et les problèmes de contrôle du trafic avec des objectifs multiples[145], des travaux très limités ont résolu un problème

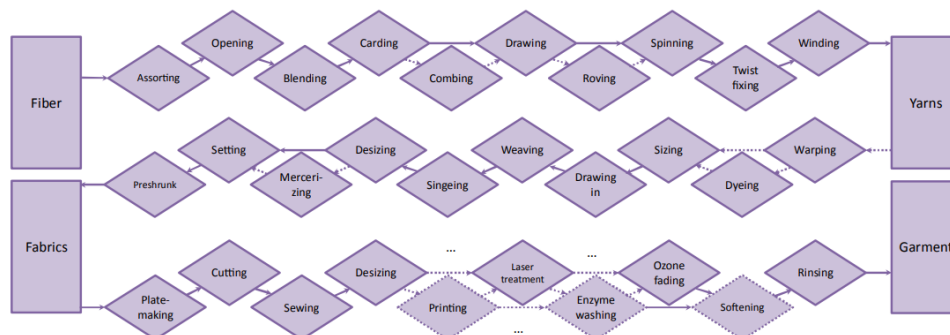


FIGURE 3.8 – Une illustration générale des procédés de fabrication textile de la fibre au vêtement [3]

de production complexe, en particulier dans l'industrie textile. Sur quoi, cette section formule les problèmes d'optimisation multi-objectifs du processus de fabrication textile dans un paradigme de jeu de Markov et applique de manière collaborative le MARL basé sur le DQN au lieu des méthodes actuelles pour optimiser le processus textile en termes de objectifs multiples [3].

1. Construction d'un système d'optimisation multi-objectifs basé sur l'apprentissage automatique pour le processus de fabrication textile.
2. Formulation d'un problème d'optimisation de processus de fabrication textile en tant que processus décisionnel de Markov, et le résoudre par apprentissage par renforcement.
3. Transformer les problèmes d'optimisation multi-objectifs de la fabrication textile dans le modèle de la théorie des jeux et introduire le multi-agent pour rechercher les solutions de processus optimales.
4. L'application de DQN est étendue au système d'apprentissage par renforcement multi-agents, qui est plus applicable et préféré pour faire face au problème réaliste compliqué de l'industrie textile.

3.3.1 Revue de littérature

Il y a eu une variété de travaux sur l'optimisation multi-objectifs des processus textiles au cours des dernières décennies. [146, 88, 147, 148, 149, 150, 151, 152, 153, 154, 155, 156, 157, 158, 89, 159, 160, 161, 162]. Cependant, malgré les efforts mentionnés ci-dessus sur l'optimisation du processus de fabrication du textile, ils restent encore plusieurs limitations importantes. Au cours des dernières années, avec l'évolution rapide de l'intelligence artificielle, de plus en plus d'algorithmes d'apprentissage automatique ont fait preuve de plus en plus de polyvalence et de puissance dans l'application pratique des problèmes d'optimisation dans l'industrie [118, 163, 108, 120, 121, 164, 102, 92, 93, 94]. Cependant, la plupart de ces études RL précédentes se concentraient uniquement sur des problèmes à objectif unique.

Il est également remarqué que les problèmes d'optimisation multi-objectifs pourraient être transformés en modèles de théorie des jeux pour être bien résolus [140, 141], et les développements récents de systèmes multi-agents pour optimiser plusieurs objectifs

sur la base de la théorie des jeux a montré son extrême capacité à traiter des fonctions ayant un espace de grande dimension [142, 143]. Le MARL, d'autre part, a été proposé par de nombreuses contributions pour le contrôle distribué en robotique, les télécommunications, le contrôle des feux de circulation et l'optimisation de la répartition, etc. [144, 165, 145, 166]. Cependant, les algorithmes MARL traditionnels peuvent généralement difficilement gérer le problème à grande échelle, son applicabilité était donc très limitée [167]. Pourtant, les algorithmes d'apprentissage par DRL, qui ont été rapidement développés ces dernières années, peuvent faire la différence. DQN est l'un des algorithmes DRL qui utilisent des outils d'apprentissage en profondeur (en anglais Deep Learning, DL) et des stratégies de relecture d'expérience [133] et un Q-cible fixe faisant face aux problèmes à grande échelle, a récemment été bien évalué dans de nombreuses applications de DRL [168, 169]. Il a été constaté que la haute réalisation de DRL a été illustrée dans de nombreuses applications dans l'environnement MARL [170, 171, 172]. Par exemple, [173] Wang et al. ont optimisés la planification des flux de travail avec l'algorithme MARL basé sur DQN. [166] a examiné l'application de MARL à un problème d'optimisation de répartition dynamique multi-objectifs. [174] Zhang et al. ont formulés le scénario de trafic urbain à grande échelle dans un environnement MARL. Cependant, bien qu'il y ait eu plusieurs exemples réussis illustrant l'efficacité du MARL basé sur DQN dans les problèmes d'optimisation, des travaux très limités ont résolu un problème de production complexe, en particulier dans l'industrie textile. Ainsi, pour combler l'écart de recherche susmentionné, un nouveau cadre d'optimisation multi-objectifs du processus de fabrication textile utilisant DQN dans l'environnement MARL est présenté dans cet article.

3.3.2 Formulation du problème

Considérant que la solution d'un processus de fabrication de textile P est composée et déterminée par un ensemble de variables de paramètres $\{v_1, v_2, \dots, v_n\}$, les impacts de ces variables sur la performance du processus pourraient varier considérablement de n différents égards avec l'incertitude, car le nombre de processus et les variables associées dans l'industrie textile sont énormes et les influences de ces variables sur les performances d'optimisation ciblées ne sont pas claires. Par exemple, la durée plus longue d'un processus textile entraînerait généralement une augmentation des coûts de production, et une légère augmentation de la température utilisée dans le processus de production textile pourrait augmenter considérablement la consommation d'énergie, mais parfois la température accrue peut favoriser le processus. efficacité afin de diminuer le coût de production à terme. Par conséquent, il est nécessaire d'étudier les effets interdépendants des variables de processus sur les performances du processus. Du point de vue de l'ingénierie, il est important de trouver une solution dans le processus de fabrication du textile qui puisse atteindre une bonne qualité et éviter les temps morts, les déchets et les pollutions en même temps. Des modèles qui incorporent les informations du processus simulant la variation de performances objectives multiples à partir du changement de variable dans les solutions sont plutôt essentiels.

Supposons qu'il existe des modèles qui peuvent mapper les variables v_1, v_2, \dots, v_n de la solution de processus P à ses performances conformément à m objectifs, les performances

d’une solution spécifique pourraient être simulées par :

$$f_i(P) = f_i(v_1, v_2, \dots, v_n) \text{ pour } i = 1, \dots, n \quad (3.15)$$

Lorsqu’un décideur qui veut trouver une solution qui satisfasse les m objectifs des performances du processus que les objectifs ne sont pas commensurables et aucune préférence des objectifs liés les uns aux autres arrive avec le décideur. Le problème multi-objectif pourrait être défini comme donnant le vecteur variable de dimension n $P = \{v_1, v_2, \dots, v_n\}$ dans l’espace des solutions, trouvant un vecteur de p^* qui optimise un ensemble donné de n fonctions objectifs :

$$f(p^*) = \{f_1(p^*), f_2(p^*), \dots, f_n(p^*)\} \quad (3.16)$$

L’espace des solutions est généralement restreint par une série de contraintes, lorsque le domaine de $v_j \in V_j$ pour $j = 1, \dots, n$ est connu, et représentant les n objectifs par M , l’objectif du problème est de trouver (3) :

$$\operatorname{argmax}_{v_j \in V_j} [f(v_1, v_2, \dots, v_n) | M] \text{ pour } j = 1, \dots, n \quad (3.17)$$

Équation (3.17) vise à rechercher la solution optimale des paramètres variables, alors qu’il y a toujours des objectifs contradictoires qui satisfont une seule cible mais conduisent à des résultats inacceptables pour les autres. Une solution multi-objectifs parfaite qui optimise simultanément chaque fonction objectif est presque impossible.

À cette fin, ce chapitre propose un cadre MARL auto-adaptatif basé sur DQN où les m objectifs d’optimisation sont formulés comme m agents DQN qui se sont entraînés via un processus auto-adaptatif construit sur un jeu de Markov.

3.3.3 Méthodologie

3.3.3.1 Optimisation multiobjectif du processus de fabrication textile comme jeu de Markov

Nous commençons par formuler le problème d’optimisation des processus textiles à objectif unique comme un processus de décision de Markov en termes d’un tuple : $\{S, A, T, R\}$, où S est un ensemble d’états d’environnement, A est un ensemble d’actions, T est la fonction de probabilité de transition d’état, R est un ensemble de récompenses ou de pertes. Un agent dans un environnement MDP apprendrait à agir à partir de A en observant l’environnement avec des états à partir de S , selon la probabilité de transition correspondante T et la récompense R obtenue à partir de l’interaction. La propriété de Markov indique que les transitions d’état ne dépendent que de l’état actuel et que l’action actuelle est entreprise, mais indépendante de tous les états et actions antérieurs [130]. Alors que dans le cas d’un système multi-agents, les actions conjointes sont le résultat d’agents multiples, le MDP est généralisé au jeu stochastique de Markov de $\{S, A^1, \dots, A^m, T, R^1, \dots, R^m\}$, où S et T sont similaires au MDP qui sont respectivement l’ensemble fini des états de l’environnement et la fonction de probabilité de transition d’état dans un jeu de Markov, alors que différemment, m est le nombre d’agents, A^i for $i = 1, \dots, m$ sont les ensembles finis d’actions disponibles pour l’agent i , R^i text for

$i = 1, \dots, m$ sont les fonctions de récompense de l'agent i .

Comme on sait que la solution d'un processus de fabrication textile est affectée par un certain nombre de variables telles que $P\{v_1, v_2, \dots, v_n\}$, si la valeur possible de v_j est $h(v_j)$, les valeurs réalisables du paramètre dans le processus peuvent définir l'espace d'environnement S de $\prod_{j=1}^n h(v_j)$, $v_j \in V_j$ impactant la performance du processus textile en ce qui concerne la k objectifs. Ces variables de paramètres sont indépendantes les unes des autres et obéissent à un processus de Markov qui modélise les transitions stochastiques d'un état S_t au pas de temps t à l'état suivant S_{t+1} , où l'état de l'environnement au pas de temps t est :

$$S_t = [s_t^{v_1}, s_t^{v_2} \dots] \in S \quad (3.18)$$

L'algorithme RL entraîne un agent à agir de manière optimale dans un environnement multi-agents donné sur la base de l'observation des états et d'autres agents ainsi que de la rétroaction dérivée des interactions, en acquérant des récompenses et en maximisant les récompenses futures accumulées au fil du temps à partir de l'interaction [130]. Dans notre cas, les agents apprennent dans l'interaction avec l'environnement et les autres agents en agissant sur les variables paramètres $\in P\{v_1, v_2, \dots, v_n\}$, au pas de temps t . Plus précisément, l'action d'un agent dans un pas de temps t d'optimisation d'un processus de fabrication de textile dans le jeu de Markov, pourrait être d'ajuster la variable v_j pour garder (0) ou changer pour monter (+) et descendre (-) avec une unité spécifique u_j soumise à la contrainte. En conséquence, il y a 3^n actions au total dans l'espace d'action conjointe A et, pour simplifier, le vecteur d'action A_t au pas de temps t pourrait être :

$$A_t = [a_t^{v_1}, a_t^{v_2}, \dots, a_t^{v_n}], \text{ where } a_t^{v_j} \in \{-u_j, 0, +u_j\}, v_j \in V_j \text{ for } j = 1, \dots, n \quad (3.19)$$

Nous définissons $A = \prod_{i \in m, s \in S} A^i(s)$ pour l'action commune globalement les agents, où $A^i(s)$ est l'ensemble fini d'actions pures de l'agent i à l'état s . Il est également défini $A(s) \equiv \prod_{i \in I} A_i(s)$ and $A_{-i} = \prod_{j \neq i} A_j(s)$, donc, $A(s) = A_{-i}(s) \times A_i(s)$; afin de distinguer le joueur i , nous définissons $a = (a_{-i}, a_i) \in A(s)$ avec $a_i \in A_i(s)$ et $a_{-i} \in A_{-i}(s)$; Il est également défini que $\mathcal{A} = \cup_{s \in S} \cup_{a \in A(s)} \{(s, a)\}$, l'ensemble des paires état-action.

Les m objectifs d'optimisation du processus de fabrication textile sont assignés aux m agents dans ce jeu de Markov. Les agents sont les principaux éléments de ce système proposé. Considérant les objectifs de gestion optimaux et le jeu de Markov formulé du problème d'optimisation des processus de fabrication textile dans un cas spécifique, et l'architecture MARL pourrait être illustrée sur la Figure 3.9, où les objectifs d'optimisation sont abstraits en tant qu'agents RL. Compte tenu des retours des modèles RF intégrés à l'environnement de jeu de Markov avec un espace d'état formulé dans l'équation. (3.18) qui se composent de toutes les variables de paramètres du processus textile simulé, les agents sont capables d'évaluer les valeurs de ses actions pour ajuster les variables de paramètres par rapport à l'état (solution) et par conséquent améliorer son politique dans l'environnement à optimiser objectivement progressivement.

Comme on le sait, outre les avantages dérivés de la nature distribuée du système multi-agents tels que le calcul parallèle, le partage d'expérience de différents agents améliore également considérablement les performances des algorithmes. Par conséquent, il est supposé que chaque agent peut observer les actions et les récompenses de l'autre. Ensuite,

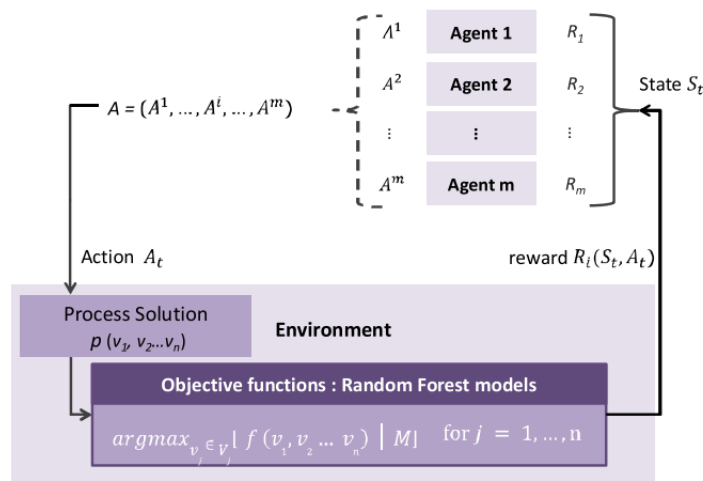


FIGURE 3.9 – Le jeu de Markov pour l’optimisation multi-objectif des processus de fabrication textile dans le cadre proposé [3]

ils sélectionnent le joint distribution (la combinaison des choix de tous les agents) qui est déterminée par les actions sélectionnées de chaque agent $(A_1, \dots, A_i, \dots, A_m)$.

Lorsque les agents de renforcement effectuent une action conjointe Au pas de temps t pour détourner le système de S_t à l’état suivant S_{t+1} avec une probabilité de transition T , chaque agent gagnerait une récompense $R_i(S_t, A_t)$ de (3) des fonctions objectifs. Cette procédure serait répétée à nouveau au temps $t + 1$, et finalement, convergeraient les comportements des agents vers une politique stationnaire. Selon une étude précédente [90], le modèle prédictif de forêt aléatoire, construit à l’aide de la forêt aléatoire multivariée (MRF) [175], est appliqué pour simuler le processus textile dans ce cadre proposé et mettre en œuvre l’objectif fonctions (3) pour gagner les récompenses des agents.

Les jeux stochastiques ne sont ni totalement coopératifs ni totalement compétitifs [144]. La performance de l’optimisation multi-objectifs de notre cas dans un jeu de Markov stochastique est déterminée par la capacité des agents à collecter des informations sur le comportement des autres agents et les fonctions de récompense de l’interaction pour prendre une décision plus éclairée par la suite. Nous considérons que chaque agent DQN observe toutes les actions et récompenses des autres agents et sélectionne sa propre action de distribution conjointe ainsi que les mises à jour de l’environnement. Les scénarios de processus textiles qui en résultent sont générés par auto-apprentissage et auto-optimisation. Les mécanismes de récompense ainsi que l’interaction entre les agents remplissent une fonction importante à cet égard, de sorte que le système proposé, similaire à l’étude de [173], utilise un mécanisme de sélection utilitaire $h = \operatorname{argmax}_{A \in \Delta(A(S))} \sum_{i \in M} Q_i(s, a)$ qui maximisent la somme des récompenses de tous les agents dans chaque état pour éviter l’interruption des équilibres multiples. La convergence vers les équilibres est une exigence de stabilité de base de MARL, et l’équilibre de Nash est un concept de solution bien connu pour le jeu stochastique selon lequel une stratégie conjointe menant à un statut sans agent est une incitation à changer de stratégie. Mais un équilibre corrélé avec une généralité accrue au lieu de l’équilibre de Nash est pris en considération dans ce problème car il permet aux stratégies des agents d’être interdépendantes. Il s’agit d’une répartition conjointe d’actions dont aucun des agents n’a de motivation pour s’écarter unilatéralement. Par conséquent, les solutions

du problème d'optimisation multi-objectif du processus de fabrication textile sont des équilibres corrélés.

Formellement, étant donné un jeu de Markov, une politique stationnaire conjointe Π conduit à un équilibre corrélé lorsque :

$$\forall_i \in M, s \in S \mid \sum_{a \in A^{-i}(s)} \pi_s Q_i^\pi(s, a) \geq \sum_{a \in A^{-i}(s)} \pi_s Q_i^\pi(s, a') \quad (3.20)$$

où $A^{-i}(s)$ est l'ensemble des vecteurs d'action dans l'état s excluant ceux des agents. L'inégalité ci-dessus indique que dans l'état s , lorsqu'il est recommandé à l'agent i de jouer a , il préfère jouer a , car l'utilité attendue de a est supérieure ou égale à l'espérance utilitaire de a' , pour tout a' .

3.3.3.2 MARL basé sur DQN pour une optimisation multiobjectif du processus de fabrication textile

La seule exécution épisodique de l'algorithme du framework MARL basé sur DQN est représentée graphiquement sur la Figure 3.10. Il est montré que, sur la base des mises à jour locales des valeurs Q et de la politique à chaque état, les agents DQN interagissent avec l'environnement (solution textile) et d'autres agents de manière itérative pour apprendre une stratégie d'équilibre corrélée. Le RF construit approximent les performances objectives du processus textile dans le cadre et la rétroaction aux agents Pour atteindre un équilibre corrélé, chaque agent DQN apprend la stratégie d'équilibre corrélé π^t , où $\pi^{t+1} \in f(Q^{t+1}(s))$ long avec des mécanismes de récompense appropriés conçus (dans ce système, la récompense d'un agent est donnée par l'amélioration de la performance objective du dernier l'état à l'état actuel), la convergence de l'algorithme basé sur DQN dans les paramètres multi-agents peut être garantie. Pour une description plus détaillée de la stratégie d'équilibre corrélé, nous renvoyons le lecteur à la référence de [176].

Outre les paramètres susmentionnés, il est également nécessaire de fournir les performances de processus ou les cibles d'optimisation attendues (P), les étapes itératives de mise à jour de la valeur Q et la taille de l'ensemble de données d'expérience (D) dans l'initialisation du système. Le détail du DQN appliqué suit son mécanisme introduit dans la section 3.2.2.4. L'algorithme donné peut fonctionner sans épisodes car la cible des agents est de trouver la solution optimisée en ce qui concerne l'état de l'environnement satisfaisant les multiples objectifs du processus textile. Cependant, le manque d'exploration de l'agent dans un environnement peut provoquer un optimum local en une seule exécution. Nous initialisons donc le premier état de manière aléatoire à partir de chaque sous-état $s_t^{v_i}$ (où les variables de paramètre $v_j \in V_j$), et introduisons un processus d'apprentissage épisodique à l'agent pour élargir l'exploration et empêcher l'optimum local. Une politique ε -greedy croissante est appliquée en plus pour équilibrer l'exploration et l'exploitation des états à la période d'apprentissage et à la période d'optimisation respectivement.

L'augmentation de ε -greedy est utilisée avec un incrément donné à chaque pas de temps de 0 jusqu'à ce qu'il soit égal à ε_{max} Cela aide les agents à trouver les meilleures actions dans l'état actuel pour passer à l'état suivant avec une possibilité de ε qui peut aussi choisir aléatoirement une action avec une possibilité de $1 - \varepsilon$ pour obtenir un

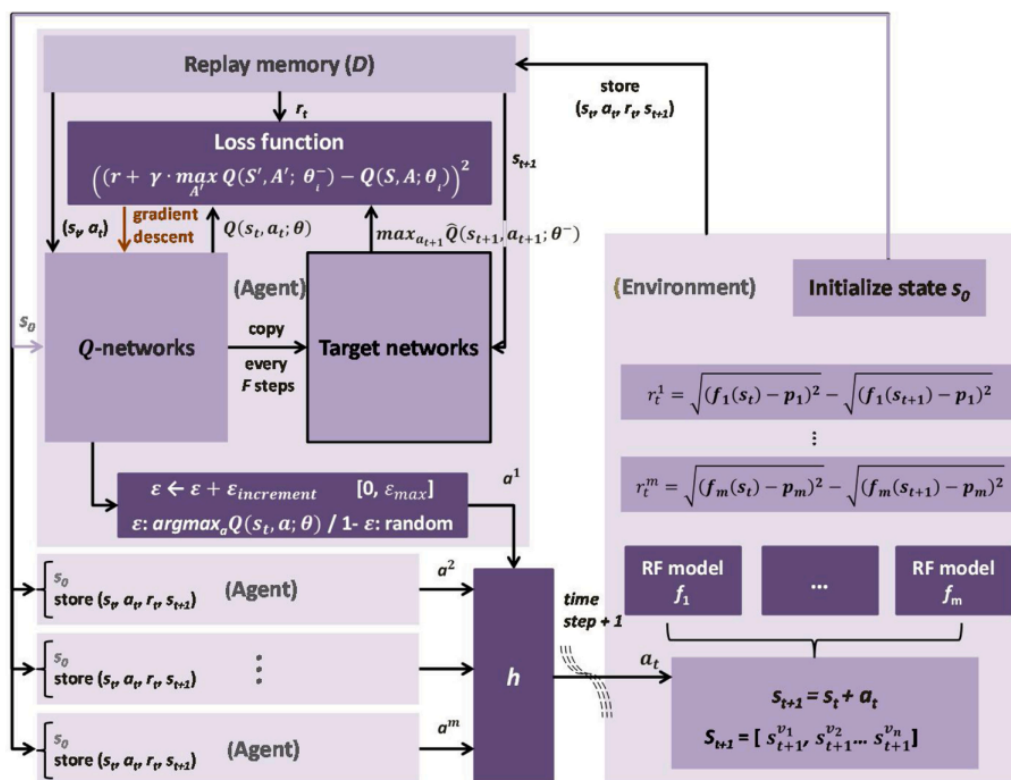


FIGURE 3.10 – Organigramme de l'algorithme mettant en œuvre le système multi-agent basé sur DQN proposé pour optimiser le processus de fabrication de textiles avec des objectifs multiples [3]

état suivant aléatoire. A cet égard, les agents peuvent explorer les états inexplorés sans rester dans l'exploitation des états déjà expérimentés de Q-networks, et les exploiter abondamment lorsque les états sont suffisamment parcourus.

3.3.4 Étude de cas

La décoloration est un processus de finition essentiel pour des produits textiles spécifiques tels que le denim pour obtenir un effet usé et un style de mode vintage [107]. Mais cet effet était classiquement obtenu par des procédés chimiques qui ont un coût élevé, et consomment fortement de l'eau et de l'électricité, entraînant de lourds impacts négatifs sur l'environnement. Au lieu de cela, le traitement à l'ozone est un processus de finition avancé utilisant de l'ozone gazeux pour obtenir des effets de décoloration sur les produits textiles sans bain-marie, ce qui permet d'économiser de l'énergie et de l'eau et de causer moins de problèmes environnementaux. Les influences interdépendantes de ce processus sur ses performances de processus ont été étudiées dans nos travaux précédents [134, 136, 135, 177, 178], et selon les données d'expérience avec 129 échantillons que nous avons collectés à partir de ces études expérimentales, quatre modèles prédictifs RF ont été construits pour simuler les 4 performances du processus d'ozonation par décoloration. La présente étude de cas tentera de résoudre les problèmes d'optimisation du processus d'ozonation par décoloration en ce qui concerne les performances du processus 4 en utilisant le système MARL basé sur DQN.

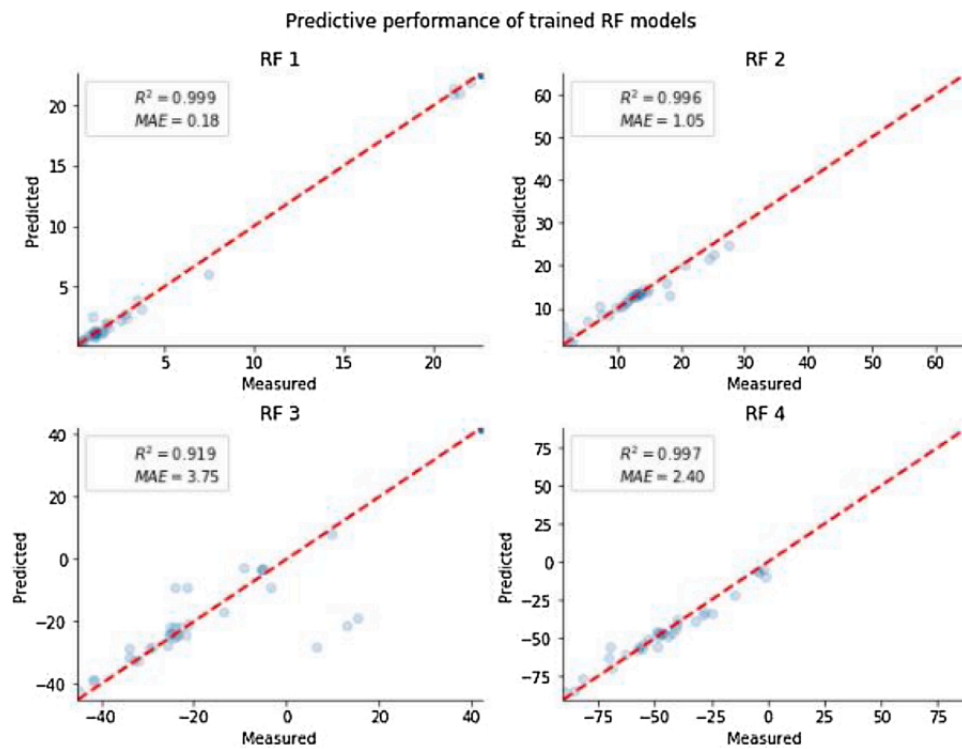


FIGURE 3.11 – Performances prédictives des modèles RF entraînés dans l'étude de cas [3]




FIGURE 3.12 – Augmentation de la politique ϵ -greedy pour le choix de l'action [3]




FIGURE 3.13 – La fonction de perte de DQN pour quatre agents dans le jeu de Markov [3]

Les modèles RF sont entrés par quatre paramètres de processus d’ozonation (teneur en eau, température, pH et temps de traitement) pour prédire quatre performances objectives de décoloration en termes d’indices de couleur connus sous le nom de k/s , L^* , a^* , et b^* des tissus traités avec la précision de $R^2 = 0.999$, 0.996 , 0.919 et 0.997 respectivement. Les performances prédictives de ces modèles RF peuvent être observées à partir de la Figure 3.11. La valeur k/s indique la profondeur de couleur, tandis que L^* , a^* , and b^* sont les index de couleur d’une norme internationale largement utilisée illustrant la variation de couleur dans trois dimensions (luminosité de 0 à 100, composante chromatique du vert au rouge et du bleu au jaune de -120 à 120 respectivement) [179]

TABLEAU 3.5 – Paramétrage de l’algorithme DQN dans l’étude de cas du processus d’ozonation textile [3]

F	D	α	γ	$\varepsilon_{increment}$	a_{max}	E	N
5(> 100)	2000	0.01	0.9	0.001	0.9	1	5000

TABLEAU 3.6 – Comparaison des algorithmes de base et du cadre proposé du résultat optimisé.

	Cibles	MARL	MOPSO	NSGA-II
k/s	0.81	1.10	0.61	0.33
L^*	15.76	14.08	20.08	25.08
a^*	-20.84	-25.06	-37.06	-43.06
b^*	-70.79	-70.7	-78.7	-85.7
R^2	-	0.999	0.986	0.979
$TempsCPU(s)$	-	13.1	17.4	52.3

Normalement, la couleur du produit textile final conforme aux k/s , L^* , a^* , et b^* se situe dans la tolérance acceptable du consommateur. Nous optimisons les performances

de couleur en termes de $k/s, L^*, a^*$, and b^* du textile dans le processus d'ozonation en trouvant une solution incluant les variables de paramètres appropriées de l'eau -contenu, température, pH et temps de traitement qui minimisent la différence entre un tel produit textile traité par un processus spécifique et l'échantillon ciblé. Par conséquent, il y a quatre agents dans le jeu stochastique de Markov, et l'espace d'état φ de celui-ci est composé par les solutions contenant quatre paramètres (teneur en eau, température pH et temps de traitement) en termes de $S_t = [s_t^{v_1}, s_t^{v_2}, s_t^{v_3}, s_t^{v_4}]$ Dans un pas de temps t , étant donné les unités ajustables de ces variables paramètres $u = 50, 10, 1, 1$ en ce qui concerne les plages de contraintes de $[0, 150], [0,100], [1, 14]$ et $[1, 60]$ respectivement, car l'action d'une seule variable v_j pourrait être conservée (0) ou modifiée haut (+) / bas (-) dans la plage donnée avec l'unité spécifique u , donc il y a $3^4 = 81$ actions totalement dans l'espace d'action et le vecteur d'action chaque agent au pas de temps t est $A_t = [a_t^{v_1}, a_t^{v_2}, a_t^{v_3}, a_t^{v_4}]$, où $a_t^{v_1} \in \{-50, 0, +50\}$, $v_1 \in [0, 150]$; $a_t^{v_2} \in \{-10, 0, +10\}$, $v_2 \in [0, 100]$; $a_t^{v_3} \in \{-1, 0, +1\}$, $v_3 \in [1, 14]$, $a_t^{v_4} \in \{-1, 0, +1\}$, $v_4 \in [1, 60]$.

La probabilité de transition est de 1 pour les états dans la plage donnée de l'espace d'état ci-dessus, mais de 0 pour les états hors de celui-ci. La récompense r d'un agent au pas de temps t devrait correspondre à la proximité de l'agent à sa cible représentant la fonction objectif associée. Nous avons mis en place la fonction de récompense comme illustré ci-dessous pour inciter les agents à approcher les résultats des objectifs d'optimisation correspondants :

$$r_t = \sqrt{(f_i(s_t) - p_i)^2} - \sqrt{(f_i(s_{t+1}) - p_i)^2} \text{ for } i = 1, ..m \quad (3.21)$$

Les performances de couleur attendues des échantillons traités par le processus d'ozonation (p_1, p_2, p_3, p_4 , en termes de $k/s, L^*, a^*$, et b^*) sont échantillonnés par des experts comme 0,81, 15,76, -20,84 et -70,79 respectivement pour faire fonctionner le système dans la présente étude de cas. Par conséquent, il y a quatre agents dans ce cas par rapport à leurs cibles d'optimisation correspondantes. En plus des cibles, les paramètres des agents DQN tels que l'étape F pour la mise à jour de Q-networks et la taille de la mémoire de relecture D , ainsi que le taux d'apprentissage α et le taux d'actualisation γ pour la mise à jour de la fonction de perte, etc., sont répertoriés dans le Tableau 3.5. En particulier, l'étape F pour la mise à jour du DQN indique ici qu'après 100 étapes, le Q-networks serait mis à jour toutes les 5 étapes.

Les réseaux de neurones implémentés par [180] sont utilisés dans notre étude de cas pour réaliser de Q-networks, et plus précisément, les réseaux se composent de deux couches avec respectivement 50 et 3^4 de nœuds cachés, où la dernière couche correspond au Actions. En raison de la popularité de l'optimisation des essaims de particules multi-objectifs (en anglais Multiple Objective Particle Swarm Optimization, MOPSO) [181] et NSGAI [182] dans l'application du processus textile, ils sont considérés comme les algorithmes de base dans cette étude de cas pour montrer l'efficacité et l'efficience du système MARL basé sur DQN proposé pour l'optimisation multi-objectifs du processus de fabrication textile.




FIGURE 3.14 – L'erreur minimale des agents DQN réglés et leur valeur totale en fonction des pas de temps [3]

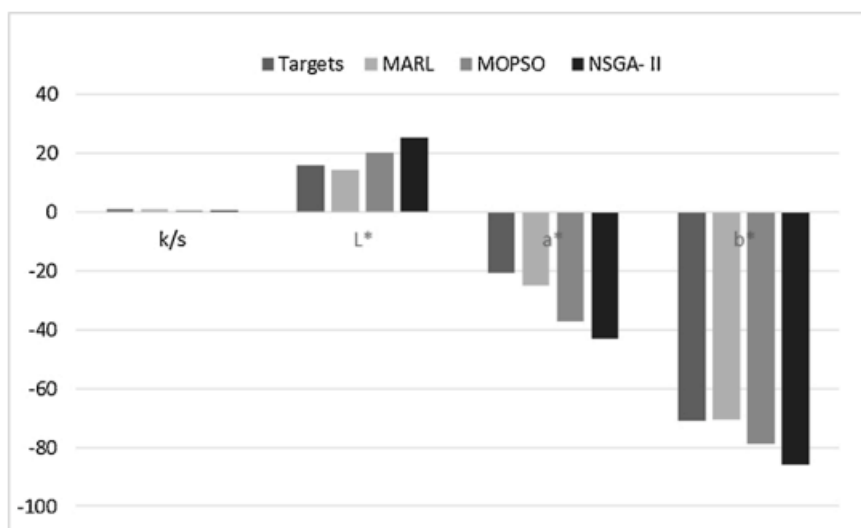


FIGURE 3.15 – Comparaison du cadre MARL proposé avec les algorithmes de base en ce qui concerne les résultats numériques [3]



FIGURE 3.16 – Comparaison du cadre MARL proposé avec les algorithmes de base en ce qui concerne les échantillons simulés [3]

3.3.5 Résultats et discussion

Dans l’étude de cas, nous avons formé quatre agents sur la base de l’algorithme DQN dans un jeu de Markov pour optimiser un processus textile à l’ozone avec des objectifs multiples. Comme le montre la Figure 3.12, la politique croissante γ -greedy a été utilisée par les agents pour équilibrer l’exploration et l’exploitation des états. Elle affecte de manière significative le temps d’apprentissage et la qualité des politiques apprises des agents. Dans cette politique, l’exploration décroît dans les 900 premières étapes. Comme les agents manquent initialement d’informations et de politiques pour exploiter les actions possibles. Mais de plus en plus, ils peuvent suivre sa politique en exploitant les informations disponibles en agissant sur le mécanisme de sélection h , plutôt que d’agir au hasard. Les effets de celui-ci pourraient être clairement illustrés sur les convergences des agents DQN donnés dans la Figure 3.13 (pour les commodités de l’illustration, 200, 400 et 600 unités de perte sont données en plus à l’agent 2, l’agent 3 et l’agent 4 respectivement). Où les pertes de quatre Q-networks profonds par rapport à quatre agents ont considérablement diminué après 900 étapes d’exploration de l’environnement par les agents et sont restées stables à partir des 900 étapes. Cela dénote que le Q-networks profonds s’adaptent avec succès à l’environnement stochastique que la représentation de la valeur Q dans ce Q-networks profonds pour les agents est stable et précise et que les agents agissent de manière déterministe après 900 étapes lorsque le γ -greedy a augmenté au maximum.

Les agents visant à optimiser la solution d’un procédé à l’ozone textile pour approcher les performances de couleur du tissu de 0,81, 15,76, -20,84 et -70,79 par rapport à k/s , L^* , a^* , and b^* Pendant les agents DQN interagis dans le jeu de Markov avec 5000 pas, les erreurs minimales de chaque agent et la somme totale des erreurs minimales de quatre agents réétés par les modèles RF sont collectées et affichées dans la Figure 3.14. La convergence de l’erreur minimale vérifie l’efficacité et l’efficience de la fonction de récompense conçue dans notre système MARL, et il semble que la solution avec une erreur plus faible puisse être obtenue potentiellement avec des pas de temps croissants.

La comparaison du cadre construit avec des approches de base sur les résultats optimisés est illustrée dans le Tableau 3.6. Et la comparaison du résultat numérique est présentée sur la Figure 3.15. Il est illustré que le scénario optimal dérivé du cadre MARL proposé peut atteindre la couleur souhaitée dans le processus d’ozonation textile, en termes de valeurs colorimétriques de k/s , L^* , a^* , and b^* , qui sont très proches des objectifs d’optimisation. Les performances de couleur simulées des scénarios obtenus à partir de différents algorithmes sont présentées sur la Figure 3.16. Il peut être observé directement et clairement sur les effets de traitement de la couleur du processus d’ozonation des textiles dans différents modèles de système. Cela implique que le MARL proposé a dominé les méthodes de base de MOPSO et NSGA-II (en anglais Non-dominated Sorting Genetic Algorithm-II) dans notre étude de cas pour optimiser efficacement la solution de processus d’ozonation et obtenir la couleur souhaitée sur les tissus traités. Le temps de calcul relativement plus court et les performances plus élevées du système MARL pourraient être attribués au fait que plusieurs hommes peuvent travailler en mode parallèle et qu’ils partagent leur expérience dans le processus. D’un autre côté, il a été rapporté que les algorithmes métaheuristiques de MOPSO et NSGA-2 pourraient ne pas fonctionner

avec des ensembles de données plus petits [183] et prendre un temps incroyablement long en itération [184]. Et plus important encore, bien qu’ils soient efficaces pour traiter les problèmes d’optimisation multi-objectifs de faible dimension, le stress accru de la sélection de la dimension croissante du problème diminuerait considérablement les effets lorsque les objectifs sont supérieurs à trois.

3.4 Conclusions

Les systèmes d’aide à la décision proposés sont clairement applicables dans le secteur de la fabrication de textiles, qui a été testé dans l’étude de cas mise en œuvre. Il convient de mentionner que ce système peut également être appliqué dans la pratique avec différentes fonctions objectives telles que l’optimisation énergétique, l’optimisation des matériaux, etc. Cependant, il convient de noter que certaines fonctionnalités du cadre avec AHP peuvent entraver sa promotion et ses applications massives. L’AHP a été implémenté avec succès dans les problèmes MCDM ([122];[185]). Cependant, il repose fortement sur l’estimation d’experts, ce qui peut limiter son application dans certains domaines, surtout lorsqu’il existe un grand nombre d’alternatives et que les scores alternatifs correspondant à chaque critère de décision sont connus objectivement ([186]). Dans ce chapitre, nous avons également proposé une méthodologie d’apprentissage par renforcement multi-agents (MARL) pour faire face aux problèmes d’optimisation multi-objectifs de plus en plus complexes dans le processus de fabrication textile. L’optimisation multi-objectifs des solutions de processus textiles est modélisée comme un jeu de Markov stochastique et plusieurs agents intelligents basés sur de Q-networks profonds (DQN) sont développés pour atteindre les solutions optimales d’équilibre corrélées du processus d’optimisation. Le jeu stochastique de Markov n’est ni totalement coopératif ni totalement compétitif, de sorte que les agents emploient un mécanisme de sélection utilitaire qui maximise la somme de toutes les récompenses des agents (obéissant à l’augmentation de la γ -greedy) dans chaque état pour éviter l’interruption de plusieurs équilibres. Alors que l’application des techniques d’intelligence artificielle se développe dans l’industrie de la fabrication de textiles, de telles préoccupations pourraient être correctement traitées à l’ère de l’industrie 4.0, lorsqu’elle sera en mesure de tirer pleinement parti de l’environnement de l’Internet des objets (IoT). Après le développement, le système peut être alimenté en continu avec de nouvelles données et scénarios pour apprendre le processus dans l’environnement en ligne, ou des modèles de simulation plus détaillés qui peuvent mieux représenter les interrelations complexes des variables du processus textile sont développés pour recycler les agents RL, donc que de maintenir à jour le système avec le développement de l’industrie textile pour l’optimisation des processus et même le contrôle adaptatif des paramètres en ligne. Les systèmes proposés entraînent l’agent hors ligne dans un simulateur de processus pour obtenir une connaissance générale du processus et aider à la prise de décision, tandis que son utilisation future pourrait être étendue à l’optimisation en ligne et au contrôle optimal en ligne du processus de fabrication textile pour éviter de longs calculs en ligne. fois. Les résultats ont montré que les systèmes développés sont capables d’apprendre à maîtriser les tâches de prise de décision difficiles et fonctionnent mieux que les méthodes traditionnelles. Ce chapitre est écrit principalement sur les travaux de la thèse soutenu de M. Zhenglei He ([90], [187],[188], [177], [3], [82]) et 1 post-doctorant M. Huu Du Nguyen ([79]). Cette direction de recherche se poursuivra avec 2 doctorants (M. Moussab Orabi et

Mme. Léa Catteau). Ce sujet de recherche est également publié dans un livre édité [189] pour souligner son importance, discuter de nouvelles directions de recherche et encourager l'application d'apprentissage automatique et de modèles graphiques probabilistes pour les systèmes d'aide à la décision.

Chapitre 4 :

Contributions à la prévision et la détection d'anomalies dans la gestion de la chaîne d'approvisionnement avec des techniques d'apprentissage automatique

4.1 Introduction

Dans l'économie mondialement concurrentielle d'aujourd'hui, prendre de bonnes décisions est un facteur clé du succès de toute entreprise; une bonne décision est susceptible de générer de la valeur pour l'entreprise [190]. De ce fait, la problématique de l'aide à la décision en gestion de la chaîne d'approvisionnement (en anglais Supply Chain Management, SCM) est une préoccupation majeure dans un grand nombre d'études [191, 192, 193, 194, 195]. Parmi les facteurs qui conduisent à des approches de prise de décision appropriées, la prévision et la détection d'anomalies dans le SCM sont deux tâches très importantes. Une bonne méthode de prévision permet d'équilibrer l'offre et la demande, puis d'éviter le sous-stock ou le surstock dans la planification des stocks de détail. En conséquence, d'autres opérations de l'ensemble de la chaîne d'approvisionnement, telles que la gestion des échéances, la planification de la production, la tarification et l'obtention de niveaux de service client élevés, peuvent être mieux exécutées. Pendant ce temps, une énorme quantité de données générées à chaque étape du SCM conduit à une surcharge de données et à la difficulté de discerner les signaux utiles, qui permettent de prendre des décisions significatives à partir de celles qui n'en ont pas. Les approches de détection d'anomalies permettent de déterminer rapidement des anomalies ou des schémas inattendus pour prendre des décisions plus efficaces. Dans la littérature, de nombreuses études ont été menées pour fournir des solutions efficaces traitant de ces deux tâches importantes.

Liées à l'utilisation d'algorithmes d'apprentissage automatique dans la détection d'anomalies, la plupart des études actuelles ne prennent pas en compte les événements précédents ou récents dans la détection de la nouvelle valeur aberrante entrante, c'est-à-dire qu'elles sont basées uniquement sur l'apprentissage des comportements normaux et anormaux [196]. Récemment, LSTM (en anglais Long Short Term Memory) apparaît comme une technique puissante pour apprendre les dépendances à long terme et représenter efficacement la relation entre les événements actuels et les événements précédents. [197] a suggéré d'utiliser des réseaux LSTM empilés pour la détection d'anomalies dans les séries temporelles. Ensuite, une méthode de détection d'anomalies multi-capteurs basée sur Autoencodeur LSTM est étendue dans [198]. Un inconvénient de ces deux études est que les auteurs ont utilisé une hypothèse de distribution gaussienne multivariée pour les vecteurs d'erreur, ce qui peut ne pas être vrai en pratique. Pour éviter cette hypothèse, [9] a appliqué une méthode basée sur des cartes de contrôle en utilisant un estimateur de quantile à noyau. Les auteurs ont également souligné que leur méthode basée sur LSTM surpasse la méthode basée sur l'apprentissage automatique dans [199]. Cependant, cette méthode peut ne pas toujours être efficace pour les données de séries chronologiques multivariées car une seule valeur de la caractéristique d'intérêt est sortie du réseau. De ces points de vue, l'objectif de ce chapitre est (1) de fournir une méthode basée sur le LSTM pour la prévision de données de séries chronologiques multivariées et (2) de présenter une méthode efficace pour détecter les anomalies à partir de données de séries chronologiques multivariées sans utiliser aucune hypothèse pour la distribution des erreurs de prédiction. En particulier, nous suggérons d'utiliser un algorithme de machine à vecteur de support à une classe (en anglais One-Class Support Vector Machines, OCSVM) pour séparer les anomalies des données générées sur la base du Autoencodeur LSTM. Afin d'évaluer la pertinence de notre méthode proposée, une étude de cas réel basée sur la

chaîne d'approvisionnement de la vente au détail de mode est considérée. La vente au détail de mode, et plus particulièrement la chaîne d'approvisionnement en aval, est un domaine très difficile qui nécessite des techniques intelligentes avancées [4]. Le scénario envisagé est décrit plus précisément dans la section suivante.

4.2 Travaux connexes

Comme mentionné ci-dessus, la prévision et la détection d'anomalies à partir de données de séries chronologiques multivariées sont des tâches essentielles dans SCM. Une bonne exécution de ces problèmes permet aux gestionnaires de prendre de meilleures décisions dans leur travail. Cependant, les applications de prévision et de détection d'anomalies à partir de données de séries chronologiques multivariées ne se limitent pas au SCM. On pourrait voir les applications de ces deux problèmes importants dans de nombreux domaines tels que la finance, la banque, l'assurance, la fabrication industrielle, etc. En conséquence, les références qui leur sont consacrées sont abondantes dans la littérature.

Pour le problème de détection d'anomalies, Zhao et al. [200] ont améliorés l'algorithme de détection rapide des valeurs aberrantes en regroupant en fonction des flux de données appliqués à la logistique de la chaîne du froid. Roesch and Van [201] ont suggéré une approche de contrôle qualité pour détecter les anomalies dans l'analyse des données d'inventaire annuel. Deux techniques de détection d'anomalies, y compris une approche statistique et une approche basée sur le regroupement, ont été utilisées pour détecter les valeurs aberrantes dans les données des capteurs pour les systèmes de surveillance en temps réel de la chaîne d'approvisionnement des denrées périssables dans [202]. Un certain nombre d'études axées sur la détection d'événements anormaux dans la chaîne d'approvisionnement basée sur la technologie d'identification par radiofréquence (en anglais Radio-identification, RFID) peuvent être consultées dans [203, 204]. [205] Habeeb et al. ont fournis une enquête complète sur le traitement des mégadonnées en temps réel pour la détection d'anomalies. Les auteurs ont également proposé une taxonomie pour classer la littérature existante dans un ensemble de catégories impliquant des techniques de détection d'anomalies, puis ont analysé les solutions existantes sur la base de la taxonomie proposée. Une enquête complète sur les approches d'apprentissage en profondeur pour la détection d'anomalies est menée à [206]. Un grand nombre de références ont été étudiées pour fournir une vue d'ensemble du problème. Les modèles de détection d'anomalies basés sur l'apprentissage en profondeur sont divisés en types, impliquant des réseaux de neurones non supervisés, semi-supervisés, hybrides et à une classe. L'idée des modèles hybrides profonds est d'utiliser des réseaux de neurones profonds principalement des auto-encodeurs comme extracteurs de caractéristiques. Après avoir appris dans les représentations cachées des autoencodeurs, ces fonctionnalités sont transmises aux algorithmes de détection d'anomalies traditionnels tels que OCSVM et SVDD (en anglais Support Vector Data Description, SVDD) pour détecter les anomalies. Ce type de modèle d'apprentissage en profondeur a été appliqué dans plusieurs situations avec un grand succès. Cependant, la structure de ces modèles hybrides profonds pour la détection d'anomalies n'est qu'une combinaison de certains réseaux profonds séparés comme réseau neuronal convolutif (en anglais Convolutional neural network, CNN) et

LSTM, avec OCSVM ou SVDD. De plus, ce type de modèle hybride profond n'a pas encore été appliqué aux séries chronologiques multivariées.

Pour le problème de prévision, le modèle de moyenne mobile intégrée auto-régressive (en anglais Autoregressive Integrated Moving Average, ARIMA) est couramment utilisé comme méthodologie pour les données de séries chronologiques linéaires, cependant, il ne convient pas à l'analyse de données non linéaires [207]. Les modèles d'apprentissage automatique tels que la régression vectorielle de support et le régresseur de forêt aléatoire sont ensuite développés pour traiter des données non linéaires [208, 209, 210]. En utilisant des fonctions d'activation non linéaires, les réseaux de neurones récurrents (en anglais Recurrent Neural Network, RNN) sont essentiellement un modèle de série chronologique non linéaire, où la non-linéarité est apprise à partir des données. Une comparaison des réseaux ARIMA et à LSTM dans la prévision des séries chronologiques menée à [211] a montré que le modèle LSTM surpasse le modèle ARIMA car la réduction moyenne des taux d'erreur obtenue par LSTM était d'environ 80% par rapport à ARIMA. Les méthodes de prévision de séries temporelles avec apprentissage en profondeur sont largement revues dans [212]. Les structures complexes formées à partir de combinaisons de réseaux d'apprentissage en profondeur pour traiter des séries temporelles multivariées pour la prévision [213, 214, 215]. Il semble que l'on doive utiliser des structures plus complexes pour les modèles d'apprentissage en profondeur afin d'obtenir de meilleures performances, et l'utilisation de réseaux d'apprentissage en profondeur plus simples pour résoudre le problème de prévision ne prête plus beaucoup d'attention. L'objectif de cette étude est alors de considérer les lacunes de la littérature évoquées ci-dessus.

4.3 Scénarios

Dans le commerce de détail, et plus particulièrement dans le commerce de détail de mode, l'optimisation de la chaîne d'approvisionnement est cruciale pour contrôler les coûts, augmenter la satisfaction des clients, gérer les stocks et enfin améliorer les bénéfices. Les trois principaux facteurs qui rendent le commerce de mode très spécifique sont [216] :

- la variété de produits est très élevée,
- la demande des consommateurs est très fluctuante et sensible aux tendances de la mode, à la météo et aux prix,
- la supply chain des produits de mode est très complexe et particulièrement longue par rapport à la courte durée de vie des produits.

Pour faire face à ces spécificités, les enseignes de mode ont développé une supply chain management en deux parties [217] comme illustré sur la Figure 4.1, incluant (1) en amont des fournisseurs jusqu'à l'entrepôt, une supply chain orientée coût avec des achats en gros basés sur des prévisions à long terme, et (2) en aval de l'entrepôt vers les magasins locaux, une chaîne d'approvisionnement réactive avec un réapprovisionnement fréquent des magasins principalement basé sur des données de point de vente (en anglais Point Of Sales, POS) à court terme.

Dans cette étude, nous nous concentrons sur la chaîne d'approvisionnement en aval des détaillants de mode. Comme mentionné précédemment, la demande des consommateurs est très fluctuante. Lorsque la variété des produits est élevée, la répartition des stocks devient très difficile pour un vaste réseau de magasins. Ainsi, les entreprises s'appuient

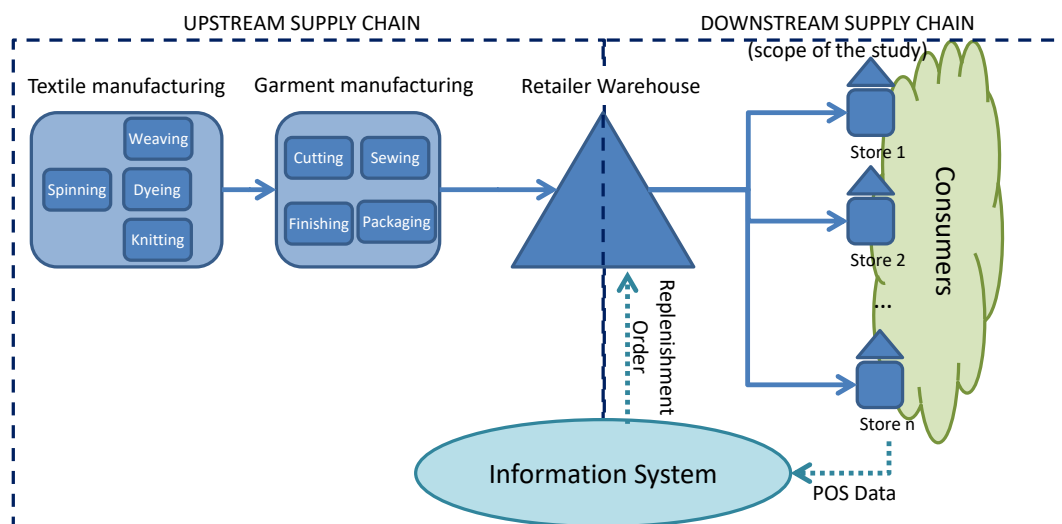


FIGURE 4.1 – Une illustration d'une gestion de la chaîne d'approvisionnement en deux parties [4]

sur des systèmes d'information efficaces et réactifs pour surveiller les données des points de vente et calculer le réapprovisionnement de chaque magasin pour le lendemain ou les deux jours suivants. Combiné à une logistique de transport et de distribution efficace, ce processus permet aux entreprises de gérer leurs stocks locaux dans la plupart des situations. Cependant, la grande sensibilité de la demande aux effets de prix et aux conditions météorologiques implique fréquemment des fluctuations brusques et immédiates qui ne peuvent être prédites par le système de réapprovisionnement basé sur les données des points de vente. Compte tenu des différentes contraintes telles que les petites surfaces des magasins, les effectifs limités pour gérer la réception des produits, les rayonnages et la force de vente, ces fortes fluctuations génèrent des pertes de profit importantes. Par conséquent, un système de prévision des ventes à court terme devrait être développé pour faire face à ce problème. Différents modèles ont été proposés dans la littérature pour cette tâche ([218]). Cependant, la variété des produits et l'étendue du réseau de magasins génèrent un grand nombre de situations qui sont autant de sources d'erreurs de prévision. Pour faire face à ces problématiques, l'approche qui combine les nouvelles avancées de la prévision avec le réseau LSTM, l'Autoencodeur LSTM et OCSVM. Dans ce contexte, l'objectif de notre méthode n'est pas seulement de prédire les ventes exactes par unité de stock (en anglais Stock Keeping Unit, SKU) et magasin mais également de détecter et d'anticiper les ventes exceptionnelles afin de permettre aux praticiens de prendre une décision appropriée et d'ajuster leur réapprovisionnement pour les SKU/magasins mis en évidence en conséquence.

4.4 Approches proposées

4.4.1 Prévision de séries chronologiques multivariées à l'aide de LSTM

Les séries chronologiques multivariées font référence à une série chronologique qui a plus d'une variable dépendante du temps. Cela signifie que chaque variable dépend non seulement de ses valeurs passées, mais a également une certaine dépendance vis-à-vis d'autres variables. Cette dépendance des séries chronologiques multivariées est pratique pour modéliser des interdépendances intéressantes et prévoir les valeurs futures. Cependant, en raison de sa nature, il peut être difficile de construire des modèles précis pour la prévision de séries chronologiques multivariées, une tâche importante dans de nombreuses applications pratiques. Dans la littérature, plusieurs modèles prédictifs de séries chronologiques multivariées ont été proposés tels que le modèle vectoriel auto-régressif (en anglais Vector autoregression, VAR) et le modèle bayésien VAR. Un résumé des approches avancées de prévision de séries chronologiques multivariées basées sur des modèles statistiques peut être consulté dans [219]. Récemment, les développements rapides des réseaux de neurones artificiels ont fourni un outil puissant pour gérer une grande variété de problèmes qui étaient soit hors de portée, soit difficiles à résoudre avec les approches prédictives classiques des séries chronologiques. Par exemple, une méthode de prévision de séries chronologiques multivariées utilisant LSTM a été suggérée pour prévoir la qualité de l'air à [220].

Soit $\mathbf{x}_t = \{x_t^{(1)}, x_t^{(2)}, \dots, x_t^{(k)}\}$, $t = 1, 2, \dots$ désigne une série chronologique multivariée à l'instant t où k est le nombre de variables. Dans une chaîne d'approvisionnement, \mathbf{x}_t peut être la valeur de certaines caractéristiques spécifiques telles que les ventes, la température, l'humidité et le prix du produit. Le réseau LSTM est formé sur la base d'une séquence de données observées $\{\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_N\}$, où N est le nombre d'échantillons, comme suit. Premièrement, les observations individuelles sont mises à l'échelle à l'aide de la fonction MinMaxScaler par la formule

$$x_{scaled}^{(i)} = \frac{x^{(i)} - x_{min}^{(i)}}{x_{max}^{(i)} - x_{min}^{(i)}}, i = 1, \dots, k, \quad (4.1)$$

où $x_{max}^{(i)}$ et $x_{min}^{(i)}$ sont les valeurs maximale et minimale de $x^{(i)}$ dans l'ensemble de données, respectivement. Pour simplifier les notations, nous écrivons $x^{(i)}$ pour $x_{scaled}^{(i)}$ et comprenons qu'il s'agit de données mises à l'échelle. Ensuite, dans le processus d'apprentissage, nous mettons en place une fenêtre glissante de taille m , $m < N$. C'est-à-dire que m de variables multivariées consécutives sont transmises au LSTM en même temps. Nous utiliserons ces $m * k$ entrées pour prédire la prochaine valeur de la caractéristique d'intérêt, disons $x_*^{(1)}$. Par exemple, dans la première fenêtre, la séquence $\{\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_m\}$ dans l'ensemble de données d'entraînement est prise pour alimenter le LSTM et le réseau peuvent prédire la valeur $\hat{x}_{m+1}^{(1)}$. Dans le second, basé sur la séquence $\{\mathbf{x}_2, \mathbf{x}_3, \dots, \mathbf{x}_{m+1}\}$, le LSTM peut prédire la valeur $\hat{x}_{m+2}^{(1)}$. Ce processus se poursuit jusqu'à ce que les fenêtres glissent jusqu'à la fin de l'ensemble de données d'apprentissage. Les poids du réseau LSTM sont entraînés

pour minimiser la fonction de perte de prédiction d'erreur :

$$L = \sum_{i=m+1}^N e_i, \quad (4.2)$$

where $e_i = \|\hat{x}_i^{(1)} - x_i^{(1)}\|$. Les performances du réseau LSTM sont évaluées à l'aide de l'erreur quadratique moyenne (en anglais Root Mean Squared Error, RSME) de la métrique de perte :

$$RMSE = \sqrt{\frac{1}{N - m - 1} \sum_{i=m+1}^N (\hat{x}_i^{(1)} - x_i^{(1)})^2}. \quad (4.3)$$

Après la formation, le réseau est utilisé pour la prévision. En particulier, la valeur $\hat{x}_{N+1}^{(1)}$ peut être prédite à partir du LSTM sur la base de l'entrée $\{\mathbf{x}_{N-m+1}, \mathbf{x}_{N-m+2}, \dots, \mathbf{x}_N\}$. En pratique, certains des paramètres du modèle doivent être optimisés en fonction des données d'entrée pour obtenir les meilleures performances. Dans notre étude, le taux d'apprentissage, le nombre de cellules et le décrochage seront optimisés. Le choix de la fenêtre coulissante est aussi une question dans certaines situations. Cependant, il faut considérer la capacité d'apprendre la longue dépendance temporelle du LSTM. Cette capacité fait que LSTM n'a pas besoin de prédéterminer une fenêtre de temps spécifiée : il peut trouver lui-même le nombre de rétrospective optimal. C'est-à-dire que nous pouvons essayer des valeurs spécifiques pour la taille de la fenêtre glissante et laisser LSTM apprendre des données. Si l'on veut essayer une autre valeur pour la taille de la fenêtre glissante, d'autres paramètres doivent être ré-optimisés et cela peut prendre plus de temps. Dans cette étude, nous attribuerons une valeur particulière à la taille de la fenêtre glissante en fonction de notre connaissance des données.

4.4.2 Détection d'anomalies dans les séries chronologiques multivariées à l'aide d'Autoencodeur LSTM and OCSVM

La méthode basée sur le LSTM présentée dans la section précédente permet de prévoir une variable spécifique dans une série chronologique multivariée. Cette valeur peut être utilisée pour détecter une anomalie comme proposé dans [9]. Cependant, utiliser uniquement cette valeur pour la détection d'anomalies peut être inefficace dans plusieurs situations car la dépendance de ces valeurs prédites par rapport aux valeurs prédites d'autres variables est ignorée. Dans cette section, nous proposons une alternative pour la détection d'anomalies à l'aide de l'Autoencodeur LSTM et OCSVM. La méthode proposée est la suivante.

Supposons que l'autoencodeur LSTM a été entraîné à partir d'une séquence normale $\{\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_N\}$, où N est le nombre d'échantillons et $\mathbf{x}_t = \{x_t^{(1)}, x_t^{(2)}, \dots, x_t^{(k)}\}$, $t = 1, 2, \dots$ est la valeur de la série chronologique multivariée à l'instant t avec k nombre de variables (ces notations proviennent de la section précédente). En utilisant une fenêtre glissante de taille m , l'autoencodeur entraîné LSTM peut lire la séquence d'entrée $\mathbf{X}_i = \mathbf{x}_t, \dots, \mathbf{x}_{t-m+1}$, encodez-le et recréez-le dans la sortie $\hat{\mathbf{X}}_i = (\hat{\mathbf{x}}_t, \dots, \hat{\mathbf{x}}_{t-m+1})$, avec $i = m + 1, \dots, N$. La Figure 4.2 présente une illustration du fonctionnement du réseau autoencodeur LSTM pour la fenêtre glissante de taille 2. Puisque ces valeurs ont été observées à partir des données, on peut calculer le vecteur d'erreur de prédiction $\mathbf{e}_i = \hat{\mathbf{X}}_i - \mathbf{X}_i$, $i = m + 1, \dots, N$.

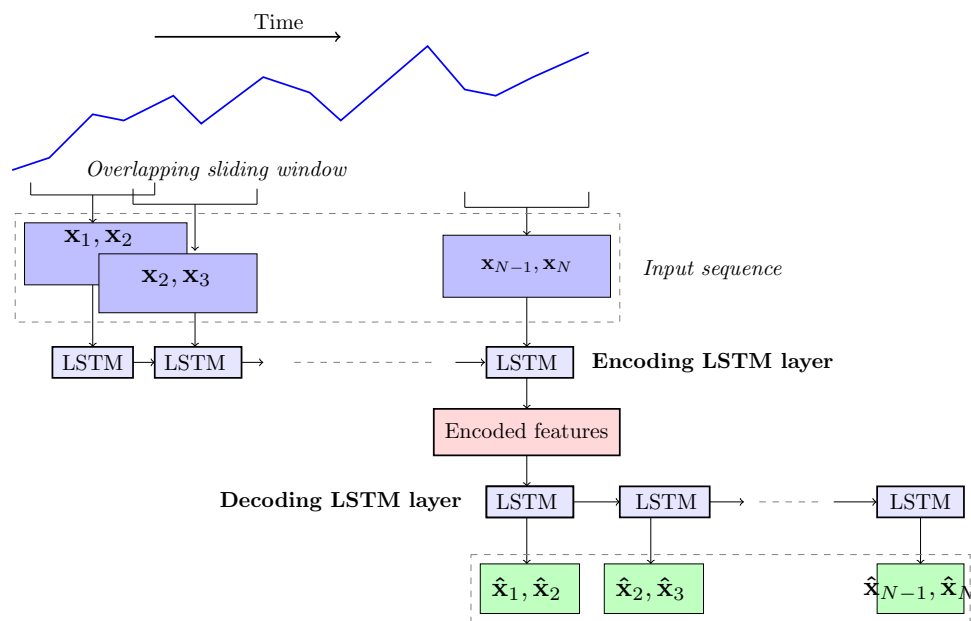


FIGURE 4.2 – Une illustration du fonctionnement du réseau autoencodeur LSTM pour la fenêtre glissante de taille 2 [4]

La détection d'anomalie est alors basée sur ces vecteurs d'erreur de prédiction. Dans [198], les auteurs ont supposé que ces vecteurs d'erreur suivent une distribution gaussienne et ont ensuite utilisé la méthode d'estimation du maximum de vraisemblance pour estimer les paramètres de cette distribution. Cette méthode est similaire à celle suggérée dans [197]. Cependant, on peut soutenir que l'hypothèse d'une distribution gaussienne pour les vecteurs d'erreur peut ne pas être vraie en pratique. Nous surmontons l'inconvénient de cette méthode en utilisant des algorithmes d'apprentissage automatique qui ne nécessitent aucune hypothèse spécifique de données. Parmi les algorithmes d'apprentissage automatique, OCSVM est un algorithme très efficace qui peut être utilisé pour détecter l'anomalie. Puisque la dépendance dans la série temporelle multivariée est éliminée en utilisant l'autoencodeur LSTM, les vecteurs d'erreur $e_i, i = m + 1, \dots, N$ peuvent être considérés comme indépendants. A partir de ces vecteurs, l'OCSVM peut définir un hyperplan pour séparer les observations anormales des échantillons normaux. Une autre méthode possible pour éviter l'hypothèse de distribution gaussienne consiste à utiliser la méthode d'estimation des quantiles à noyau (en anglais Kernel Quantile Estimation, KQE) telle qu'appliquée dans [9]. Par rapport à la méthode de détection d'anomalies suggérée dans [9], la méthode proposée dans cette étude présente plus d'avantages. L'autoencodeur LSTM utilisé dans cette étude permet d'extraire plus efficacement des caractéristiques importantes des séries temporelles multivariées. De plus, en produisant un vecteur plutôt qu'un composant du vecteur, la dépendance entre les composants du vecteur prédit est maintenue. En conséquence, cela rend les algorithmes d'apprentissage automatique pour la classification ou la détection d'anomalies plus efficaces. Semblable à la section précédente, le taux d'apprentissage et le nombre de cellules seront optimisés en fonction des données d'entrée plutôt que d'être prédéterminés pour obtenir de meilleures performances du modèle.

4.5 Expérience et résultats

4.5.1 Analyse comparative des ensembles de données

Dans cette section, nous vérifions les performances de nos méthodes proposées sur la base de deux jeux de données simulés : les jeux de données C-MAPSS pour la prévision et les jeux de données générés pour détecter une anomalie.

4.5.1.1 C-MAPSS ensembles de données utilisés pour la prévision

C-MAPSS (en anglais Commercial Modular AeroPropulsion System Simulation) est un ensemble de données simulées de dégradation de turboréacteur produit et fourni par la NASA et il est largement utilisé dans l’étude de la prévision de la durée de vie utile restante [221]. Afin d’évaluer les performances de la méthode basée sur LSTM pour la prévision de données de séries chronologiques multivariées, similaire à [213], nous évaluons la méthode basée sur le premier jeu de données de C-MAPSS, c’est-à-dire le jeu de données FD001. Le C-MAPSS FD001 est divisé en un ensemble d’apprentissage et un ensemble de test de plusieurs séries chronologiques multivariées. L’ensemble d’apprentissage contient le flux de données de surveillance des conditions de fonctionnement jusqu’à la défaillance pour 100 moteurs du même type, tandis que l’ensemble de test contient les données de même type de moteurs qui se terminent quelque temps avant la défaillance. La longueur des données de maintenance conditionnelle est incohérente d’un moteur à l’autre et est contaminée par le bruit des capteurs, ce qui rend difficile la prédiction de la durée de vie utile restante (en anglais Remaining Useful Life, RUL) [213]. L’objectif est de prédire la véritable RUL de chaque moteur de l’ensemble de test en utilisant les données de l’ensemble d’apprentissage. C’est-à-dire que les données de l’ensemble d’apprentissage sont fournies pour former le modèle et le modèle formé est utilisé pour prédire le RUL des moteurs de test. Dans la littérature, l’ensemble de données C-MAPSS FD001 a été largement étudié pour vérifier un modèle pronostique RUL et de nombreuses études connexes ont été publiées. Le Tableau 4.1 compare les performances pronostiques de notre modèle proposé avec un autre modèle récent basé sur la métrique RMSE. On peut voir à partir du Tableau 4.1 que bien que la structure de notre modèle basé sur LSTM soit plus simple que d’autres modèles d’ensemble ou hybrides, il conduit toujours au plus petit RMSE. C’est-à-dire que nous pouvons dire que la méthode proposée a une performance supérieure dans la prévision des données de séries chronologiques multivariées.

Méthode & Réfs.	RMSE
MTW-BLSTM ensemble [213]	12.61
LSTM- FW-CatBoost [214]	15.8
RBM-LSTM-FNN [215]	12.56
Méthode proposée	9.71

TABLEAU 4.1 – Comparaison RMSE avec la littérature sur le jeu de données C-MAPSS FD001 [4]

Méthode	DR(Recall)	Precision	Accuracy	F-score
Méthode dans [9]	0.9815	0.9465	0.9384	0.8805
LSTM Autoencodeur avec KQE	0.9807	0.9583	0.9484	0.9029
LSTM Autoencodeur avec OCSVM	0.9959	0.9845	0.9836	0.9698

TABLEAU 4.2 – Comparaison des performances de notre méthode proposée[4] et la méthode suggérée dans [9]

4.5.1.2 Données générées utilisées pour détecter une anomalie

Pour évaluer les performances de la méthode basée sur l'autoencodeur LSTM-OCSVM dans la détection d'anomalies à partir de séries chronologiques multivariées, nous simulons un ensemble de données d'apprentissage de 6988 échantillons normaux et un ensemble de données de validation de 1398 échantillons normaux représentant les ventes normales. Une fonction de génération de données a été présentée dans [4]. Nous comparons les performances de la méthode basée sur LSTM-KQE appliquée dans [9], la méthode basée sur Autoencodeur LSTM-KQE et la méthode basée sur LSTM Autoencodeur-OCSVM proposée dans cette étude à travers 2989 échantillons normaux et anormaux d'un ensemble de données de test simulé. Dans cet ensemble de données de test, nous simulons un petit passage d'un échantillon de 999 à un échantillon de 1499. La comparaison est faite en utilisant les mesures suivantes :

$$\begin{aligned}
 \bullet \text{ Accuracy} &= \frac{TP+TN}{TP+FP+TN+FN} & \bullet \text{ Recall} &= \frac{TP}{TP+FN} \\
 \bullet \text{ Precision} &= \frac{TP}{TP+FP} & \bullet \text{ F-score} &= 2 \times \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}}
 \end{aligned}$$

où TP (True Positive) représente le nombre d'anomalies correctement diagnostiquées comme anomalies, TN (True Negative) représente le nombre d'événements normaux correctement diagnostiqués comme normaux, FP (False Positive) représente le nombre d'événements normaux incorrectement diagnostiqués comme anomalies, et FN (False Negative) représente le nombre d'anomalies diagnostiquées à tort comme des événements normaux. Par leur définition, la précision est utilisée pour évaluer la précision du résultat et le rappel est utilisé pour évaluer la complétude du résultat. En outre, le score F est utilisé pour rechercher un équilibre entre la précision et le rappel.

Les résultats obtenus sont donnés dans le Tableau 4.2. Comme on peut le voir dans ce Tableau, la méthode basée sur l'autoencodeur LSTM conduit à de meilleures performances par rapport à la méthode basée sur LSTM dans [9]. En particulier, la Précision, la Précision et le F-score correspondant à l'Autoencodeur LSTM (dans la deuxième rangée et la troisième rangée) sont significativement plus grands que ceux correspondant au LSTM (dans la première rangée). De plus, l'utilisation de l'algorithme OCSVM pour la classification apporte les meilleurs résultats avec une précision de 98,36 %, une précision de 98,45 % et un score F de 96,98 % et un rappel de 99,59 % . C'est-à-dire que notre méthode proposée d'utilisation de l'autoencodeur LSTM combiné à OCSVM surpasse les autres méthodes, assurant une détection plus précise des anomalies dans les ventes. Par conséquent, cette méthode sera appliquée dans la section suivante pour la détection d'anomalies dans un ensemble de données de vente au détail de mode réel.

4.5.2 Données réelles sur la vente au détail de mode

Les données sont collectées auprès d'un magasin au centre d'une ville en France du 01/01/2015 au 18/11/2019. Ils sont considérés comme une série temporelle multivariée à cinq variables, impliquant la quantité vendue (des tee-shirts), la remise de prix, la température, la pluie (précipitations en mm) et le prix initial (sans remise). La Figure 4.3 présente la distribution des variables à partir des données collectées.

La Figure 4.3 illustre les données historiques qui sont collectées. Les ventes quotidiennes (Figure 4.3 (a)) montrent différents effets saisonniers :

- une saisonnalité annuelle liée à la typologie du produit (T-Shirt) avec des ventes plus élevées durant l'été,
- une saisonnalité hebdomadaire liée au comportement des consommateurs, courante dans les activités de vente au détail, avec des ventes plus élevées le samedi.

Une tendance globale à la baisse peut également être détectée puisque le nombre de ventes semble baisser chaque année. Ces caractéristiques sont généralement bien traitées avec les modèles de séries chronologiques. Cependant, des pics et des poussées brutales surviennent souvent dans les ventes. Ces variations sont produites par différents facteurs. Les ventes de produits de mode sont généralement considérées comme très sensibles aux remises de prix et aux données météo [216, 217]. Les impacts de ces variables explicatives sur les ventes sont souvent complexes, non linéaires, dépendants de la période et corrélés entre eux. Par conséquent, l'analyse de ces impacts nécessite un modèle de séries chronologiques multivariées. Les chiffres 4.3b et 4.3c indiquent les taux de remise et le prix d'origine (moyen) des T-Shirts. L'augmentation des ventes peut être identifiée pendant les périodes de remise. Cependant, il apparaît que des taux d'actualisation similaires ont des impacts très différents sur les ventes. Ainsi, le prix d'origine est également pris en compte pour compléter l'information sur le taux d'actualisation. Les données météorologiques, la température (Figure 4.3d) et les précipitations (Figure 4.3e) donnent des informations complémentaires pour expliquer les pics de ventes. Il est difficile de mesurer visuellement les impacts de ces variables car elles sont généralement très brèves. Le modèle de prévision proposé a pour objectif de traiter les combinaisons de tous ces facteurs (caractéristiques de vente, remises, données météorologiques) pour fournir une prévision aussi précise que possible. Néanmoins, des variations inattendues, visibles sur la Figure 4.3a et identifiées plus précisément sur la Figure 4.6, ne peuvent être prises en compte par le modèle de prévision. Pour cette raison, le modèle de détection d'anomalies proposé vise à détecter ces variations pour permettre aux décideurs de modifier et d'adapter la stratégie de réapprovisionnement en conséquence. Les données totales de 1441 jours sont divisées en trois parties : 56% (807 jours de ventes) des données sont pour la formation, 14% des données (202 jours de ventes) sont pour la validation, et le reste de 30% des données (432 jours de ventes) est à des fins de test. Pour le choix de la base de test, nous avons pris comme test les ventes d'un exercice fiscal (01/04 2018 - 31/03/2019) et nous avons pris une semaine pour chaque période de vente (8 semaines). De plus, nous avons essayé différents ratios qui sont assez populaires dans la littérature et avons retenu ce ratio car il donnait les meilleures performances. Cependant, il faut considérer que le résultat obtenu dépend également de chaque ensemble de données et que les performances de la méthode proposée varieraient en fonction des portions de la formation.




FIGURE 4.3 – La distribution des variables pour les données de séries chronologiques multivariées [4]

4.5.2.1 Prévision des ventes

À partir de l'ensemble de données collectées, nous utilisons une fenêtre glissante de la taille 30, c'est-à-dire que nous prenons les données de 30 jours consécutifs pour prédire les ventes du jour suivant. De plus, nous appliquons le réseau LSTM avec des hyperparamètres de 50 cellules LSTM, 10 époques ; le décrochage est de 0,1 et le taux d'apprentissage est de 0,001. Le choix de ces hyperparamètres est basé sur la méthode des hyperparamètres de recherche de grille pour les modèles LSTM.

Après avoir entraîné le modèle, nous l'utilisons pour prédire les ventes sur l'ensemble de données de test. La Figure 4.4 montre une comparaison entre les ventes réelles et les ventes prévues à l'aide de LSTM. À partir de cette Figure, on peut voir que les valeurs prédites capturent la tendance changeante des ventes réelles. De plus, l'erreur quadratique moyenne correspondant aux données mises à l'échelle est $MSE = 0,05$. Cette valeur est convertie en un MSE réel de 95.204. Nous calculons également l'erreur moyenne de prévision (en anglais Mean Forecast Error, MFE) par la formule

$$MFE = \frac{1}{1441 - 30} \sum_i \frac{(x_i - \hat{x}_i)}{x_i} \quad (4.4)$$

où x_i et \hat{x}_i représentent les ventes réelles et les ventes prévues au moment i . Le résultat obtenu est de 12,47%. Ces résultats montrent que le modèle de prévision basé sur LSTM conduit à une bonne prédiction et qu'il peut être appliqué pour prédire les ventes dans la pratique. Pour des recherches plus approfondies, davantage de fonctionnalités/variables pouvant affecter les ventes, telles que la couleur des produits, la taille et le magasin, pourraient être prises en compte dans la série chronologique multivariée pour améliorer les performances du modèle.

4.5.2.2 Détection d'anomalies dans les données de vente au détail de mode

Le réseau Autoencodeur LSTM et OCSVM sont entraînés sur la base du même ensemble de données d'entraînement que pour la prévision dans la section précédente. Ensuite, une détection d'anomalie est effectuée sur la base de l'ensemble de test. Comme indiqué ci-dessus, l'autoencodeur LSTM transforme les données d'entrée de différentes manières à l'aide d'un ensemble d'opérations mathématiques jusqu'à ce qu'il apprenne les paramètres essentiels et les règles de formatage des données d'entrée pour reconstruire des données fermées. Pour illustrer la différence entre la représentation apprise et la série temporelle d'origine, nous considérons les vecteurs d'erreur de prédiction \mathbf{e} pour la phase de test, nous utilisons la méthode d'analyse en composantes principales (en anglais Principal Component Analysis, PCA). Dans la Figure 4.5, nous affichons la sortie de Autoencodeur LSTM réduite dans un plan de coordonnées à deux dimensions. Les caractéristiques extraites des données d'anomalie ont tendance à être divisées en un cluster et elles sont différentes de celles extraites des données normales. C'est-à-dire que Autoencodeur LSTM a bien fait dans sa mission d'extraire les attributs de l'entrée. Ensuite, l'OCSVM peut classer avec précision les anomalies à partir de ces représentations et les colorer.

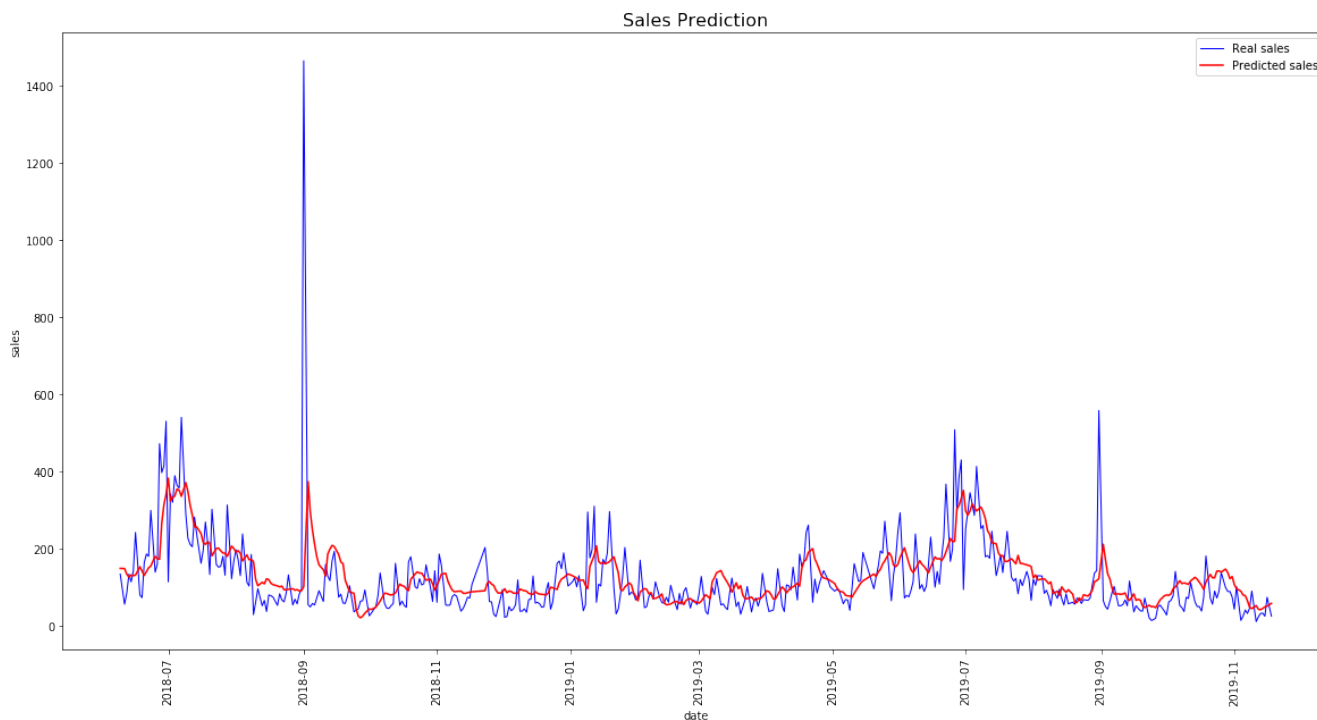


FIGURE 4.4 – Une comparaison entre les ventes réelles et les ventes prévues à l'aide de LSTM [4]

La Figure 4.6 montre les points d'anomalie (points rouges) qui sont différents du comportement normal. Par exemple, nous pouvons voir les valeurs inhabituellement élevées en septembre 2018 et il y a des moments où les ventes sont anormalement basses comme en septembre 2019. L'entreprise doit découvrir les facteurs qui conduisent à ces anomalies. Il peut s'agir de nouvelles politiques de vente, d'un nouveau personnel de vente et de nouveaux produits de style qui conduisent à une meilleure qualité des ventes ; ou ils pourraient également être les facteurs qui conduisent à une baisse de la qualité des ventes. Souligner ces anomalies de vente peut être très utile pour les entreprises afin de prendre de meilleures décisions pour la gestion future.

4.6 Discussion

Les contributions et les implications pratiques des méthodes proposées dans cette étude sont discutées dans cette section.

4.6.1 Apport théorique

La contribution théorique de cette étude comprend deux parties. Dans un premier temps, nous développons un modèle de prévision de séries chronologiques multivariées basé sur LSTM avec l'application en prévision des ventes. Afin de vérifier les performances du modèle de prévision proposé, nous avons utilisé un ensemble de données bien connu (c'est-à-dire l'ensemble de données C-MAPSS FD001 fourni par la NASA) avec un grand nombre d'échantillons, dont 20631 échantillons pour la formation et 13096 échantillons

Anomaly detection using combination of LSTM Autoencoder and OCSVM




FIGURE 4.5 – Illustration de la représentation apprise de l'autoencodeur LSTM à partir de la série chronologique multivariée d'origine à l'aide de la méthode PCA [4]

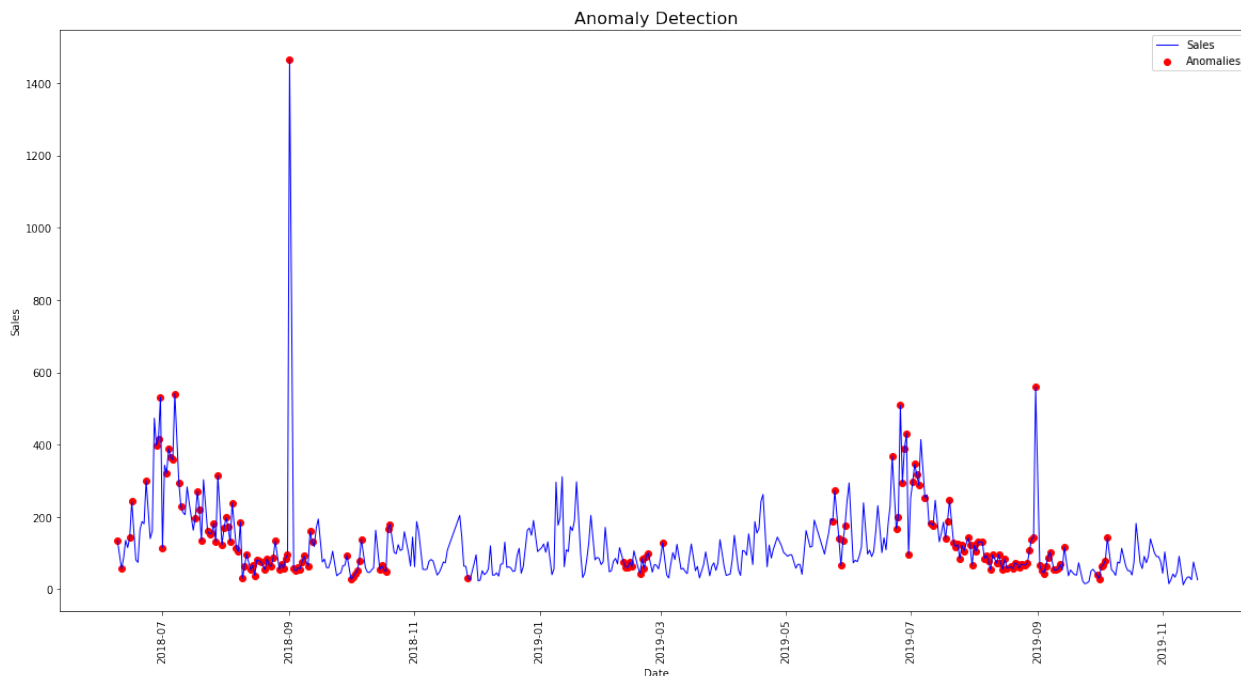


FIGURE 4.6 – La détection d'anomalies pour les données réelles basée sur le réseau Autoencodeur LSTM et l'algorithme OCSVM [4]

pour les tests. Dans la littérature, cet ensemble de données a été largement utilisé pour évaluer l'efficacité de nombreux modèles complexes d'apprentissage en profondeur tels que CNN-FNN, LSTM-FNN, CNN-BLSTM et RBM-LSTM-FNN. Notre modèle proposé, qui est simplement un modèle basé sur LSTM, est évidemment plus simple que ces modèles. Cependant, en envisageant d'optimiser les paramètres, cette découverte pourrait être très utile pour d'autres auteurs dans la conception de leur modèle d'apprentissage en profondeur dans un but spécifique de prévision traitant non seulement des séries chronologiques multivariées, mais également d'autres types de données. C'est-à-dire qu'ils peuvent envisager une structure plus simple et optimiser ses paramètres au lieu de choisir des combinaisons plus complexes. En appliquant notre modèle proposé pour une situation réelle dans SCM, nous avons suggéré d'utiliser des variables météorologiques (c'est-à-dire la température, la pluie - les précipitations en mm) à intégrer dans le modèle avec des variables traditionnelles comme le prix initial et la remise de prix pour prédire les ventes. C'est peut-être la première fois qu'un modèle de prévision des ventes en SCM prenant en compte ces attributs météorologiques est suggéré. L'utilisation de ces variables contribuera à améliorer les performances du modèle de prévision. Deuxièmement, nous avons développé un nouveau modèle hybride profond pour la détection d'anomalies. L'autoencodeur LSTM est utilisé comme extracteur de caractéristiques pour extraire des représentations importantes de l'entrée de séries temporelles multivariées, puis ces caractéristiques sont entrées dans OCSVM pour détecter les anomalies. Ce modèle se traduit par de meilleures performances par rapport aux performances de plusieurs études précédentes. Nous envisageons également d'optimiser les hyperparamètres de l'autoencodeur LSTM. À notre connaissance, l'idée d'utiliser l'autoencodeur LSTM avec des hyperparamètres optimisés et OCSVM pour la détection d'anomalies n'a pas été suggérée dans la littérature. Le modèle proposé a été appliqué pour détecter des anomalies dans les ventes à partir d'un ensemble de données réel d'une entreprise de mode en France.

4.6.2 Implications pour la pratique

Comme indiqué dans la section expérimentation, les modèles proposés peuvent être appliqués pour la prévision et la détection d'anomalies dans les ventes. Une prévision précise des ventes dans un avenir proche peut aider les responsables à avoir un bon plan de stockage, d'amélioration de l'efficacité économique et d'optimisation des activités de l'entreprise. Dans cette étude, seules cinq variables sont considérées. Cependant, plus de facteurs qui peuvent avoir un effet significatif sur les ventes peuvent être impliqués dans la pratique. La précision de la méthode proposée pourrait être remarquablement améliorée une fois que ces facteurs sont inclus dans l'entrée. On devrait consulter des experts ou du personnel expérimenté pour les découvrir. Parallèlement, la détection précise des anomalies de vente permet à l'entreprise d'avoir une vision globale de ses stratégies opérationnelles et marketing. Une anomalie négative des ventes peut correspondre à de mauvaises stratégies marketing, entraînant une baisse des ventes. Les stratégies doivent être revues et ajustées. En revanche, une fois qu'une anomalie positive est détectée dans le modèle, il pourrait être utile d'enquêter et d'expliquer la raison, augmentant ainsi les ventes et ayant des stratégies appropriées pour l'avenir. De plus, il faut considérer que l'application de nos modèles proposés ne se limite pas au SCM. En fait, ils peuvent être appliqués à tous les scénarios liés aux séries chronologiques multivariées. Par exemple, le modèle de prévision basé sur LSTM peut être utilisé pour la prévision des stocks, la

prévision de la consommation d'énergie, la prévision de la pollution de l'air, la prévision RUL, etc. Le modèle de détection d'anomalie peut être utilisé pour la détection de fraude, la détection de cyber-intrusion, la détection d'anomalie médicale, détection des dommages industriels, etc.

4.7 Conclusions

Dans cette étude, nous nous sommes concentrés sur deux problèmes importants dans la gestion de la chaîne d'approvisionnement, impliquant la prévision des ventes et la détection d'une anomalie dans les ventes. La méthode basée sur LSTM pour les séries chronologiques multivariées a été suggérée pour la prévision tandis que l'autoencodeur LSTM combiné à l'OCSVM a été utilisé pour la détection d'anomalies. Nous avons appliqué nos approches proposées aux données générées et aux données réelles de la vente au détail de mode. Les résultats obtenus ont montré que ces méthodes fonctionnaient bien sur les deux types de données. Sur les données générées, la méthode basée sur l'autoencodeur LSTM OCSVM surpasse la méthode basée sur LSTM suggérée dans [9] pour la détection d'anomalies. Le modèle de prévision basé sur LSTM fonctionne également mieux avec certains autres modèles complexes de prévision RUL à partir de l'ensemble de données C-MAPSS FD001 fourni par la NASA. Sur des données réelles, la tendance des ventes réelles peut être bien prédite avec un petit MSE . Les contributions théoriques incluent l'utilisation proposée de sources de données externes et internes d'entreprise combinées pour améliorer la prévisibilité du modèle LSTM tout en optimisant les hyperparamètres du modèle LSTM basés sur des données pour nous aider à atteindre des performances plus élevées que les méthodes proposées précédemment sur l'analyse comparative et les ensembles de données réels. De même, les performances du nouvel algorithme irrégulier proposé sont également améliorées en optimisant les hyperparamètres du modèle.

De plus, les algorithmes proposés dans cette étude peuvent être appliqués à tout domaine ayant des besoins anormaux de prévision et de détection. Dans les études futures, nous espérons pouvoir encore améliorer les performances de ce modèle de prévision en utilisant des sources de données externes supplémentaires telles que le PIB (Produit Intérieur Brut), le taux de chômage, les données des réseaux sociaux, etc. De plus, en combinant le modèle prédictif et le modèle de détection d'anomalies concevoir un algorithme capable de prédire de futures anomalies dans les ventes peut être une direction de recherche intéressante. Enfin, la fabrication axée sur la demande (en anglais Demand-Driven Manufacturing, DDM) est la solution vers laquelle la plupart des entreprises se dirigent de nos jours. Bien que cette stratégie consiste à produire des biens en fonction de la demande des consommateurs, les entreprises doivent également s'appuyer sur des systèmes de prévision précis pour préparer leur chaîne de production à une telle opération en fournissant suffisamment de matière première, en augmentant la capacité de production pour répondre à la demande souhaitée, etc... Cependant, étant donné que la plupart des entreprises s'appuient sur une production massive, la plupart des systèmes de prévision des ventes généralement utilisés reposent sur les données de vente des années précédentes qui, non seulement contiennent la demande réelle, mais prennent également en considération les effets de la stratégie marketing comme les promotions massives. Par conséquent, les

prévisions qui en résultent ne reflètent pas principalement la demande des consommateurs. Pour cette raison, un passage à la prévision de la demande, au lieu de la prévision des ventes, est essentiel pour assurer une bonne transition vers DDM. Dans notre étude récente [222], nous avons proposé un système de prévision de la demande basé sur l'intelligence artificielle qui vise à déterminer les "ventes potentielles", reflétant principalement la demande des consommateurs, en corrigeant les données de vente historiques des effets de variables externes. Une comparaison avec d'autres modèles de prévision des ventes est réalisée et validée sur des données réelles d'une enseigne de mode française. Les résultats montrent que le système proposé est à la fois robuste et précis, et qu'il surpasse tous les autres modèles en termes d'erreurs de prévision. Ce chapitre est écrit principalement sur les travaux de post-doctorat de M. Huu Du Nguyen([9] and [4]) et de la thèse en cours de Mme. Rita Sleiman ([222]). Cette direction de recherche se poursuivra avec la thèse en cours de Mme. Rita Sleiman.

Chapitre 5 :

Contributions à la cybersécurité assurée à travers la détection d'anomalies avec des techniques d'apprentissage automatique

5.1 Introduction

L'industrie 4.0 se caractérise par des systèmes interconnectés qui sont également connectés d'une manière ou d'une autre à Internet. Les systèmes industriels ont commencé à fusionner avec l'Internet des objets (en anglais Internet of Things, IoT) grâce à l'introduction de la capacité de détection dans les appareils frontaux connectés à Internet pour fournir des services. Ainsi, l'IoT donne accès à une énorme quantité de données, collectées par les appareils frontaux sur Internet. Cependant, concevoir une infrastructure IoT robuste et sécurisée est un défi, car la nature hétérogène et distribuée de l'infrastructure IoT permet de nombreuses attaques telles que le phishing, les logiciels espions, le DoS (en anglais Denial-of-Service), le DDoS (en anglais Distributed Denial-Of-Service), etc. Dans ce contexte, la sécurité informatique devient un enjeu majeur pour le monde industriel puisque les systèmes industriels combinés à la technologie IoT pourraient constituer une voie ouverte pour les attaquants. Par conséquent, un système IoT fiable doit répondre à de nombreuses exigences de sécurité telles que l'authentification et le contrôle d'accès au niveau de la couche périphérique et la détection des attaques au niveau de la couche réseau [223]. En tant que système spécifique des systèmes industriels, nous avons observé le déploiement croissant des réseaux de capteurs sans fil industriels (en anglais Industrial Wireless Sensor Network, IWSN) dans une variété d'applications différentes puisque le réseau de capteurs sans fil (en anglais Wireless Sensor Network, WSN) constitue l'une des technologies les plus prometteuses du troisième millénaire pouvant servir un large éventail d'applications dans notre vie environnante. L'intégration récente des WSNs avec une capacité d'accès Internet dans les nœuds de capteurs a ouvert de nouveaux défis de sécurité, en particulier s'ils sont commandés pour des tâches critiques telles que des tâches militaires tactiques (par exemple, les pertes pour les forces amies sur un champ de bataille) ou des applications de soins de santé (par exemple, exposition de données de santé confidentielles).

En tant qu'étude de cas spécifique et émergente des systèmes basés sur l'IoT, la fabrication intelligente (en anglais Smart Manufacturing, SM) est une fabrication industrielle qui a été profondément touchée en raison du développement rapide et de la large application de technologies de pointe. Un système SM est surveillé par des capteurs, contrôlant les opérations basées sur des technologies informatiques intelligentes pour améliorer les performances du système, la qualité du produit ainsi que pour minimiser les coûts [224, 225]. De tels systèmes de contrôle industriel (en anglais Industrial Control System, ICS) modernes sont essentiels au fonctionnement des installations nationales telles que les gazoducs ou les réseaux électriques... Cependant, le fait qu'un ICS moderne ne soit plus un système isolé, mais qu'il soit connecté à Internet résulte en dans une conséquence grave si le réseau est accédé par des pirates. Des données critiques pourraient être volées ou le système d'exploitation d'une usine pourrait être envahi et détruit. Les systèmes de contrôle des installations industrielles et des systèmes cyber-physiques (en anglais Cyber-Physical System, CPS) peuvent être sujets à des erreurs ou des pannes de fonctionnement, qui peuvent entraîner diverses pertes d'exploitation importantes, par exemple, l'arrêt d'une usine ou la mise hors service des systèmes de sécurité,...Aujourd'hui, les systèmes de fabrication basés sur l'IoT industriel (en anglais Industrial IoT, IIoT) sont désormais l'une des principales industries ciblées par diverses attaques. De nombreuses attaques contre les systèmes SM ont été signalées dans [226].

Par conséquent, le problème de la protection des systèmes IIoT contre les cyber-attaques devient de plus en plus indispensable et le besoin de comprendre une architecture efficace de détection des cyberattaques dans les systèmes de contrôle industriel(en anglais Industrial Control Systems, ICS) s'est imposé.

Pour mettre en œuvre des solutions de détection de cybersécurité pertinentes, les administrateurs industriels doivent avoir une compréhension claire des systèmes informatiques, des réseaux de communication et des systèmes de contrôle. Ils doivent également avoir une certaine connaissance des données générées par des clients inoffensifs et par des attaquants, et des solutions de sécurité disponibles. Pour la détection des cyberattaques, nous pouvons compter une variété de techniques bien connues telles que le pare-feu, l'antivirus ou les systèmes de détection d'intrusion (en anglais Intrusion Detection System, IDS). Cependant, à mesure que les cybermenaces deviennent de plus en plus sophistiquées, il devient nécessaire d'avoir un système de détection d'anomalies capable de détecter les anomalies ou les attaques avec précision et en temps voulu tout en étant suffisamment léger pour fonctionner efficacement sur les appareils IoT avec des puissances de calcul limitées dans les environnements industriels. Finalement, il est plus difficile pour les administrateurs réseau de développer des fonctions de sécurité dynamiques avec une faible complexité afin de permettre une réponse du système en temps réel [227]. Le problème de la détection des cyberattaques a été abordé sous différents angles : (1) algorithmes efficaces basés sur l'apprentissage automatique, (2) paradigme de mise en réseau, (3) informatique distribuée ou centralisée.

Pour la direction de l'algorithme de détection basé sur l'apprentissage automatique, nous pouvons trouver un certain nombre de recherches [228, 229, 230, 231, 232, 233, 234]. Dans la conception, une méthode d'exploration de processus [228] est conçue sur la base des données de journal des périphériques du système pour rendre la détection d'anomalies plus efficace en raison de la riche source de fichiers journaux d'informations. Cependant, ces conceptions n'ont pas pris en compte le problème de la détection en temps réel, lorsque la tâche de détection des attaques dans les ICS nécessite une détection rapide, précise et en temps réel. Pour la direction d'un nouveau paradigme de mise en réseau, outre les efforts visant à trouver un algorithme de détection efficace, la cyberattaque et la détection d'anomalies ont également été abordées dans une nouvelle perspective de paradigme de mise en réseau - le réseau défini par logiciel (en anglais Software-Defined Networking, SDN). Avec la séparation d'un réseau traditionnel dans le plan de données et le plan de contrôle, SDN offre un moyen flexible d'administrer le système [235]. Une architecture basée sur le SDN a été étudiée dans les travaux [235, 236] pour résoudre la cybersécurité dans l'IIoT et les ICS. Avec le paradigme de mise en réseau SDN, toutes les décisions sont prises de manière centralisée par le contrôleur SDN, ce qui peut entraîner des problèmes de latence de réponse du système plus lents et imposer la charge de traitement sur le contrôleur. De plus, dans la tâche de détection d'anomalies, nous devons connaître de nombreuses fonctionnalités, y compris des fonctionnalités statistiques supplémentaires des données d'entrée. Malheureusement, il est impossible d'obtenir cette connaissance complète dans l'environnement SDN. Par conséquent, une autre architecture distribuée devrait être étudiée pour résoudre ces limitations : et un système distribué avec un modèle de détection à la périphérie pourrait être un bon candidat.

Pour la direction de l'informatique distribuée/centralisée, depuis le début du développement de l'IoT, le cloud computing central a toujours été une méthode informatique populaire pour le contrôle et l'analyse centralisée des données collectées à partir d'une variété d'appareils omniprésents. Le cloud offre une capacité de calcul puissante et un stockage important pour traiter le Big data. Cependant, le déchargement de tâches de calcul intensives vers un cloud peut ralentir la réponse du système en raison du délai nécessaire pour transmettre et traiter les données de ces périphériques frontaux vers le cloud. Pour surmonter cette limitation, l'informatique Edge (ou distribuée) est entrée en jeu pour effectuer des tâches de calcul directement à la périphérie du réseau de manière distribuée. Surtout, dans le cadre de la cybersécurité, des tâches telles que la détection d'anomalies ou d'attaques ont été de plus en plus préférées pour être réalisées directement à la périphérie, à proximité des anomalies ou des sources d'attaques. Le premier avantage du déploiement du module de détection d'anomalie directement à la périphérie est qu'il peut évidemment réduire le temps de communication de l'envoi de toutes les Big Data vers le Cloud pour une analyse plus approfondie. La détection d'anomalie basé sur l'informatique de périphérie peut apporter une réponse plus rapide du système en cas d'anomalie ou d'attaque en raison de sa proximité avec les périphériques finaux (c'est-à-dire les sources d'attaques). Par exemple, dans les types de botnet DDoS et Mirai, les sources d'attaques proviennent principalement de terminaux compromis. Le deuxième avantage est qu'il réduit également la charge de travail du Cloud, ce qui est critique pour les applications IoT qui impliquent un grand nombre d'utilisateurs simultanés. Pour le troisième avantage, en tant que concepteurs de réseaux nous-mêmes, nous privilégions le traitement local pour envoyer toutes les données brutes directement vers le Cloud, du point de vue de la confidentialité. Dans ce chapitre, nous présentons nos contributions dans ce domaine à partir des nouvelles conceptions et méthodes pour protéger les systèmes industriels, les systèmes basés sur l'IoT, IWSN. Et tout au plus, nous nous concentrons sur l'élaboration de solutions conçues pour le problème de la cyberattaque dans les ICS.

5.2 Détection d'anomalies basée sur l'apprentissage automatique pour les applications de cybersécurité

Dans le monde des systèmes distribués d'aujourd'hui, la gestion et la surveillance des performances du système est un enjeu nécessaire. Avec des milliers d'éléments à surveiller, la détection d'anomalies peut aider à identifier où une erreur se produit, améliorant l'analyse des causes premières et obtenant rapidement une assistance technique sur le problème. Dans l'informatique d'entreprise, la détection d'anomalies est couramment utilisée pour le nettoyage des données, la détection d'intrusions, la détection de fraudes, la surveillance de la santé des systèmes, la détection d'événements dans les réseaux de capteurs, les perturbations des écosystèmes. Le défi de la détection d'anomalies est qu'il y a quelques inconvénients à l'intérieur : Les systèmes de détection d'anomalies sont soit construits manuellement par des experts définissant des seuils sur les données, soit construits automatiquement en apprenant à partir des données disponibles via l'apprentissage automatique. Par conséquent, lorsque les données changent au fil du

temps, comme une fraude, les constructeurs doivent revenir en arrière pour ajouter manuellement des méthodes de sécurité supplémentaires. Et c'est mauvais car cela crée un système qui ne peut pas s'adapter (ou est coûteux et inopportun à adapter). Par conséquent, la détection d'anomalies avec des techniques d'apprentissage automatique peut améliorer le fonctionnement du système, être plus adaptatif et ponctuel, être capable de gérer de grands ensembles de données. Dans les sections suivantes, nous décrirons différentes études de cas dans le domaine de la détection d'anomalies à l'aide de l'apprentissage automatique pour résoudre différents problèmes avec les applications de cybersécurité.

5.2.1 Optimisation des hyperparamètres basée sur les données des machines à vecteurs de support à une classe pour la détection d'anomalies dans les réseaux de capteurs sans fil

Le problème de la détection d'anomalies dans les réseaux de capteurs sans fil peut être reformulé comme un problème de classification à une classe, où seules des données normales sont utilisées dans l'ensemble de données d'apprentissage. En conséquence, la machine à vecteur de support à une classe (en anglais One Class Support Vector Machines, OCSVM) et ses variantes ont été largement adoptés dans la littérature sur la détection des anomalies. Cependant, OCSVM est souvent noyauté par le noyau gaussien, qui dépend de la disponibilité des valeurs aberrantes dans les données [237]. Pour atténuer ce problème, un algorithme d'optimisation d'hyperparamètres basé sur les données et basé sur OCSVM a été proposé par [238] pour la détection d'anomalies dans les réseaux de capteurs sans fil. Nous considérons l'ensemble de données WSN rassemblé par Intel Berkeley Research Laboratory (IBRL) [239] avec des nœuds de capteurs à 54 *Mica2Dot* qui collectent cinq mesures : lumière, température, humidité relative corrigée de la température, tension et informations sur la topologie du réseau à des intervalles de 30 par seconde. L'OCSVM est calculé avec $\nu = 0.0001$, $\sigma = 0.2938$, composé de 9 vecteurs de support, en utilisant la bibliothèque LIBSVM [240]. Il a été montré que la robustesse d'OCSVM (en anglais Nested OCSVM) peut être améliorée en modifiant de manière appropriée le seuil discriminant, c'est-à-dire que le taux de fausses alarmes est réduit avec une valeur appropriée pour δ [238]. Les machines à vecteurs de support imbriquées à une classe ([241]) et la description des données vectorielles de support (en anglais Support vector data description, SVDD) ([242]) pour la détection d'anomalies dans les réseaux de capteurs sans fil ont également été développées et étudiées.

5.2.2 Approches basées sur les données en temps réel pour la détection des fraudes par carte de crédit

Nous examinerons les approches basées sur les données en temps réel pour la détection de fraude par carte de crédit [5] en utilisant OCSVM [199] et la carte de contrôle T^2 [243]. Les deux algorithmes sont déployés dans un scénario pratique comme la détection de fraude par carte de crédit, qui s'attaque au problème de la prise illégale des informations de crédit des détenteurs sans leurs autorisations [244, 245]. Par la suite, les performances

TABLEAU 5.1 – Métriques de performance d'OCSVM et carte de contrôle T^2

Methods	TP	TN	FP	FN	DR(Recall)	FPR	Precision	Accuracy	F-score
OCSVM	200	283	17	0	1.0000	0.0850	1.0000	0.9660	1.0000
T^2 chart	200	268	32	0	1.0000	0.1600	1.0000	0.9360	1.0000

de ces deux approches basées sur les données sont évaluées sur un ensemble de données de transactions de commerce électronique en ligne provenant de titulaires de cartes de crédit européennes[246]. Le schéma détection d'anomalies [5] est montré dans la Figure 5.1.

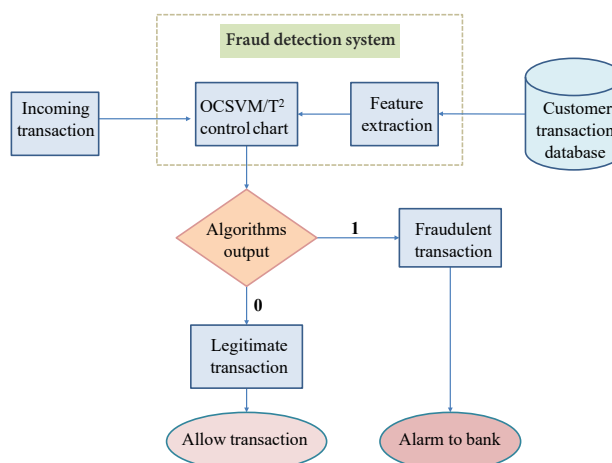


FIGURE 5.1 – Approches basées sur les données proposées pour la détection de la fraude par carte de crédit [5]

Les résultats décrits dans le Tableau 5.1 indiquent que la méthode OCSVM surpasse la carte de contrôle T^2 dans toutes les mesures de comparaison, mais avec un calcul rapide, la carte de contrôle T^2 est toujours efficace pour détecter fraudes. En outre, il est à noter que la précision de détection des deux méthodes est assez élevée (96,6% pour OCSVM, 93,6% pour la carte de contrôle T^2).

5.2.3 Une approche axée sur les données pour la détection et la surveillance des anomalies de réseau basée sur l'espace nul du noyau

Une autre approche pour la détection d'anomalies basée sur des techniques d'apprentissage automatique [247] consiste à utiliser la méthode Kernel Null Space [248] et la méthode basée sur la carte de contrôle - Kernel Quantile Estimator (KQE) [52]. Dans [248, 249], un seuil dur $\theta_{threshold}$ est défini heuristiquement pour la tâche de détection. Cette méthode n'est, dans une certaine mesure, pas optimale, rencontrant des problèmes, en particulier lorsqu'il s'agit de valeurs continues car nous ne pouvons pas essayer toutes les valeurs pour la détermination de seuil. Suivant une approche différente,

TABLEAU 5.2 – Comparaison des performances

$\sigma = 0.5957$	Kernel Null Space			OCSVM	Origin Kernel Null Space avec le seuil=0.05
	$q=0.05$ $\theta_{threshold}=$ 0.0097	$q=0.025$ $\theta_{threshold}=$ 0.0233	$q=0.01$ $\theta_{threshold}=$ 0.0514		
Accuracy	0.9548	0.9598	0.92	0.9445	0.9212
FPR	0.0443	0.018	0.006	0.0433	0.006
Recall	0.954	0.9377	0.846	0.9323	0.8483
AUC	0.9910	0.9910	0.9910	0.9849	0.9910

ce schéma de détection d'anomalies utilise la technique KQE pour obtenir un seuil qui s'adapte à l'ensemble de données en constante évolution appliqué au système, d'où une performance de détection plus élevée. L'ensemble de données NSL-KDD a été utilisé pour évaluer les performances de détection de la solution. Dans le Tableau 5.2, on peut voir qu'avec l'ensemble de données normalisées et prétraité à 41 attributs $\{X_1, X_2, \dots, X_N\}$, le paramètre de noyau optimal estimé est $\sigma^* = 0.5957$. Par la suite, à partir de l'ensemble de données donné des scores de nouveauté $\{NS_1, NS_2, \dots, NS_M\}$, le seuil trouvé est $\theta_{threshold} = 0.0097$, $\theta_{threshold} = 0.0233$, $\theta_{threshold} = 0.0514$ pour $q = 0.05$, $q = 0.025$ et $q = 0.001$ respectivement.

En particulier dans le contexte de la sécurité, la précision est plus importante que le rappel lorsque vous souhaitez avoir moins de faux positifs en échange d'avoir plus de faux négatifs. Par conséquent, $q = 0.025$ apporte les meilleures performances en termes de précision, FPR parmi les 3 valeurs différentes q comme indiqué dans le Tableau 5.2.

5.3 Détection d'anomalies basée sur l'apprentissage fédéré pour les applications de cybersécurité dans le système de contrôle industriel en fabrication intelligente

Apprentissage fédéré (en anglais Federated Learning, FL) est une technique d'apprentissage machine qui entraîne un algorithme d'apprentissage machine à partir de plusieurs échantillons de données locales décentralisées sans les échanger entre les zones distribuées. Normalement, ces données sont collectées à partir de périphériques ou de serveurs de périphérie contenant des échantillons de données locaux dans un système distribué. Ce schéma de calcul fédéré contraste avec les techniques traditionnelles d'apprentissage automatique centralisé (c'est-à-dire le Cloud Computing) dans lesquelles tous les ensembles de données locaux sont envoyés à un serveur cloud central. Ainsi, FL pourrait résoudre des problèmes critiques tels que la confidentialité des données, la sécurité des données et une réponse plus rapide du système puisque le module de détection peut être déployé juste à la périphérie qui se trouve à proximité des sources d'attaque. Ses applications sont réparties sur un certain nombre d'industries. Dans les

sous-sections suivantes, nous décrirons deux études de cas d'architecture de détection d'anomalies utilisant l'architecture FL pour contrôler les systèmes basés sur l'IoT [250] et [6].

Le concept de SM est un paradigme où les processus de production sont complétés par l'intelligence artificielle (IA ou AI en anglais pour Artificial Intelligence) pour une prise de décision plus précise et plus rentable basée sur les données collectées par des capteurs de surveillance, vers un système automatique en temps réel [224, 225]. Ces dispositifs de collecte de données ainsi que les dispositifs de passerelle, les serveurs de contrôle et d'autres actionneurs constituent un ICS, conduisant à la définition de l'Internet industriel des objets ou IIoT. Au fil des ans, ce concept a été adopté dans les industries des pays développés du monde entier. Cependant, cette innovation entraîne également des menaces d'être la cible de cyberattaques pour sabotage, exploitation de systèmes ou, plus dangereusement, d'informations confidentielles. Cette section présente une solution de détection d'anomalies basée sur la technique FL [251], déployée avec des données de séries chronologiques dans un contexte SM afin d'utiliser les ressources informatiques dans les appareils IoT de périphérie et d'obtenir une détection plus rapide d'anomalies et réduire la bande passante de transmission.

5.3.1 Architecture basée sur l'apprentissage fédéré pour la fabrication intelligente

Dans le contexte SM, une nouvelle architecture utilisant FL a été proposée à des fins de détection d'anomalies [6]. Dans cette architecture, la tâche de détection d'anomalies est déployée sur des appareils Edge avec des ressources système limitées mais réalisables, saisissant le concept d'Edge Computing, au lieu de Cloud Server comme dans l'architecture traditionnelle. Chaque périphérique Edge sert d'unité de contrôle local dans une petite zone, surveillant toutes les données collectées et les anomalies dans cette zone ou même exécutant des décisions immédiates si nécessaire. L'approche FL utilisée dans cette architecture permet de partager des données réparties dans différentes zones via un agrégateur de cloud central. Cet agrégateur permet d'améliorer le modèle de détection d'anomalies sur chaque appareil Edge pour obtenir de meilleures performances sur un ensemble de données plus large et plus universel sans avoir besoin de rassembler toutes les données en un seul endroit. De plus, les communications entre les entités de cette architecture sont basées sur le protocole MQTT (en anglais Message Queuing Telemetry Transport) en raison de sa nature de transport de messagerie de publication/abonnement léger mais fiable et de la bande passante minimale requise. En effet, le protocole MQTT est progressivement appliqué dans le domaine SM à des fins de communication.

La Figure 5.2 illustre l'architecture hiérarchique proposée, composée de trois composants fondamentaux comme suit :

- **Serveur Cloud** : le serveur central regroupe tous les modèles reçus des appareils Edge, ce qui donne un nouveau modèle fédéré à mettre à jour pour chaque appareil Edge.
- **Appareils de périphérie** : ce sont les administrateurs locaux du système, chargés de surveiller les données des capteurs dans une zone restreinte prédéfinie et d'exploiter la fonction de détection d'anomalie. Ce composant même de

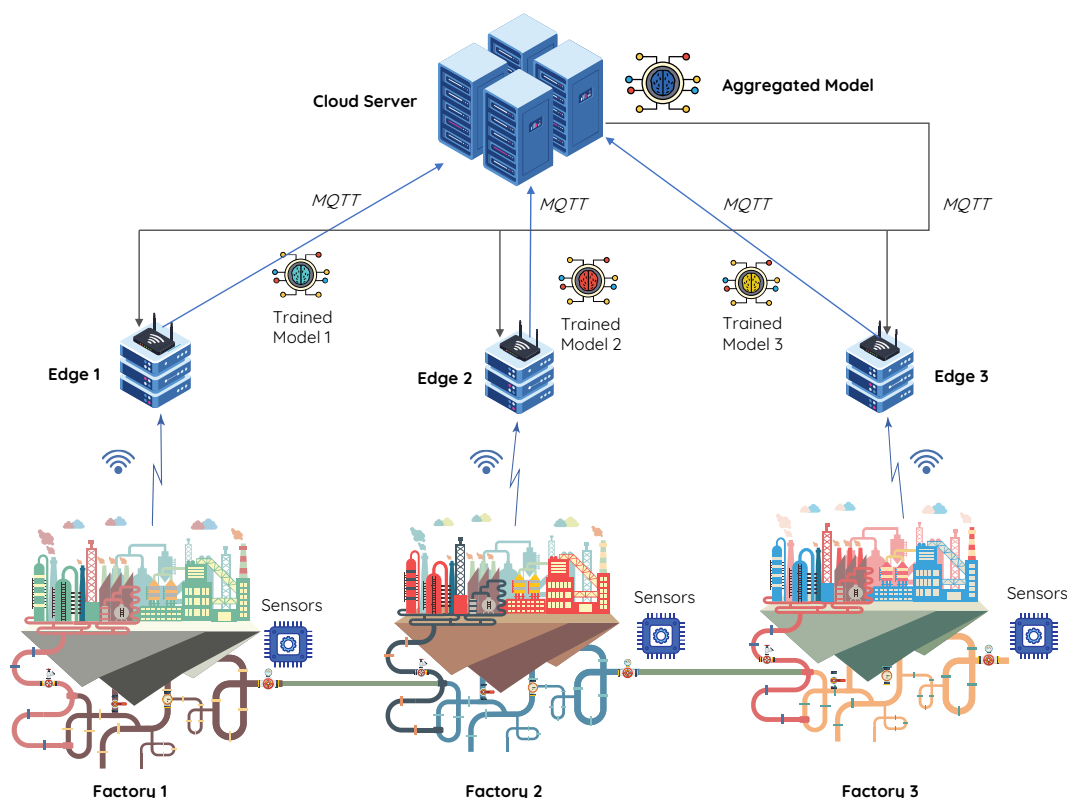


FIGURE 5.2 – Architecture basée sur FL pour la détection d'anomalies dans la fabrication intelligente [6]

l'architecture est la principale différence entre l'architecture traditionnelle et l'architecture basée sur FL. De plus, les appareils Edge envoient uniquement leurs modèles entraînés au serveur Cloud au lieu de toutes les données brutes collectées vers le Cloud pour un traitement ultérieur. Cette modification facilite directement l'inconvénient de retard du modèle traditionnel.

- **Sites d'usine** : les lignes de production sont divisées en sites plus petits, chacun étant sous le contrôle d'un périphérique Edge (serveur Edge), comprenant divers capteurs pour collecter des données et des actionneurs pour exécuter les décisions émises par les serveurs.

5.3.2 Algorithme de détection d'anomalies utilisant le modèle hybride VAE-LSTM sur les appareils Edge

Comme mentionné ci-dessus, la solution de détection d'anomalie proposée a été utilisée avec des données de séries chronologiques en entrée, qui sont le type de données prédominant dans ICS. En général, la tâche de la détection d'anomalie pour les données de séries temporelles s'oppose à un certain nombre de défis : le bruit, la dérive de concept et les informations contextuelles sont quelques-uns qui peuvent être pris en compte. De plus, lorsqu'il est déployé dans un environnement IIoT avec un paradigme Edge Computing, des exigences telles que les contraintes informatiques ainsi que le temps de

détection maximal doivent être respectées. Pour résoudre ces problèmes, dans le système proposé, le modèle hybride AutoEncodeur Variationnel [252] (en anglais Variational Autoencoder, VAE). Un LSTM(en anglais Long Short-Term Memory Networks) [253] est utilisé, ou VAE-LSTM en abrégé. Ce modèle particulier s'est avéré tirer parti de fonctionnalités locales robustes sur de courtes fenêtres de VAE.

Les régularités structurelles des séries temporelles sont capturées sur des fenêtres locales. LSTM estime ensuite la corrélation à long terme dans les séries chronologiques sur les caractéristiques produites par le modèle VAE, conduisant à une tendance à plus long terme modélisée. En raison du mode d'apprentissage non supervisé des modèles VAE et LSTM, ce modèle hybride est efficace pour détecter de nouveaux enregistrements anormaux qu'il n'a jamais rencontrés auparavant. Pour être plus détaillé, dans le déploiement de ce modèle hybride dans l'architecture FL IIoT, le modèle VAE est formé d'un encodeur et d'un décodeur à deux couches denses afin d'obtenir un fonctionnement léger. Cet ajustement rend le modèle VAE plus approprié pour être déployé dans des appareils Edge à capacité de calcul limitée.

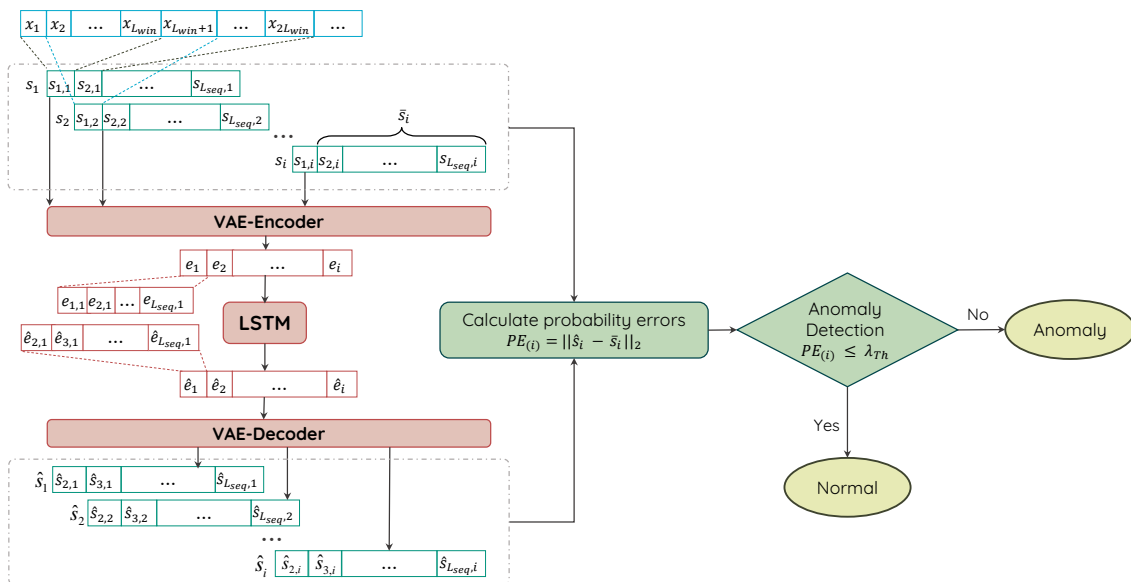


FIGURE 5.3 – Schéma fonctionnel du modèle hybride VAE-LS [6]

La Figure 5.3 décrit le fonctionnement global du modèle VAE-LSTM lors de la détection d'anomalies de données de séries chronologiques. Spécifiquement,

- Premièrement, les données de séries temporelles $\{x_1, x_2, \dots, x_{L_{win}}, x_{L_{win}+1}, \dots\}$ —dans laquelle $x_i \in R^D$ est une donnée multivariée de D -dimensionnel— est découpée en fenêtres mobiles de taille L_{win} . Ces fenêtres roulantes seront utilisées pour former le modèle VAE.

- Une séquence s_i , est construite en concaténant L_{seq} fenêtres non chevauchantes, notées $\{s_{1,i}, s_{2,i}, \dots, s_{L_{seq},i}\}$.
- Après la phase d'apprentissage du modèle VAE, les séquences $\{s_1, s_2, \dots, s_i\}$ sont introduites dans l'encodeur du module VAE, où chaque fenêtre est compressée en un code de dimension inférieure. Une séquence de codes e_i comprend plusieurs codes $\{e_{1,i}, e_{2,i}, \dots, e_{L_{seq},i}\}$. Par la suite, les séquences de code $\{e_1, e_2, \dots, e_i\}$ seront l'entrée du module LSTM.
- Le module LSTM applique les premiers éléments $L_{seq} - 1$ de la séquence de code courante i ($\{e_{1,i}, e_{2,i}, \dots, e_{L_{seq}-1,i}\}$) pour prédire les derniers composants $L_{seq} - 1$: $\hat{e}_i = \{\hat{e}_{2,i}, \hat{e}_{3,i}, \dots, \hat{e}_{L_{seq},i}\}$
- Chaque séquence de code prédite \hat{e}_i est ensuite reconstruite par le décodeur VAE entraîné pour obtenir la valeur de séquence prédite $\hat{s}_i = \{\hat{s}_{2,i}, \hat{s}_{3,i}, \dots, \hat{s}_{L_{seq},i}\}$.
- Chaque séquence prédite \hat{s}_i est ensuite comparée à \bar{s}_i , qui est la séquence d'entrée s_i à l'exclusion du premier élément, donnant une série de probabilités erreurs-erreurs de prédiction.

$$PE_i = \|\hat{s}_i - \bar{s}_i\|_2, \quad (5.1)$$

- Un seuil ζ_{Th} est utilisé sur ces erreurs pour détecter des points de données particuliers. Ce seuil est calculé à l'aide de la méthode KQE [254].

L'étude de cas principale est dans une usine de gazoducs, utilisant un ensemble de données de séries chronologiques réalistes obtenues à partir des systèmes de contrôle de supervision et d'acquisition de données (SCADA) [255]. Cet ensemble de données comprend 274 628 échantillons, et chaque échantillon contient des informations sur le réseau, des informations sur la charge utile, etc.[255]. De plus, d'autres ensembles de données chronologiques rassemblés dans plusieurs domaines différents, tels que les électrocardiogrammes (ECG) [256], la respiration [256], la demande de puissance [256], le geste [256], la navette spatiale [256] et le taxi de NYC [257], sont utilisés pour tester les performances de détection d'anomalie du modèle dans divers contextes industriels. La brève introduction de ces ensembles de données est présentée dans [6].

5.3.3 Évaluation des performances de détection

Expérience 1

Expérience 1, comme indiqué dans le Tableau. 5.3 [6], compare les performances du modèle de détection FL avec les performances du modèle de détection VAE-LSTM basé sur CL sur 7 ensembles de données différents. Dans l'expérience CL, 25 seuils différents répartis uniformément entre la plus petite et la plus grande erreur de reconstruction sont évalués pour déterminer les meilleurs seuils heuristiques pour chacun des 7 ensembles de données [253]. Selon le travail, [6], l'application de VAE avec CNN multicouche n'est pas implémentable sur les appareils Edge en raison de sa complexité de calcul élevée. Ainsi, le modèle de travail VAE [253] est implémenté avec Dense pour réduire le nombre de couches, de fonctionnalités, diminuant ainsi la complexité de calcul et la matrice de poids au bord.

Dans l'expérience FL, l'optimisation de seuil proposée à l'aide de KQE est obtenue en faisant varier 9 valeurs de p allant de 0.1 à 0.9, avec une distance de 0.1, en plus de 2

autres valeurs de 0.95 et 0.99 pour un total de 11 valeurs. Le Tableau 5.3[6] montre que le module hybride VAE-LSTM fonctionne bien sur presque tous les ensembles de données, à l'exception des ensembles de données de respiration et de geste. De plus, l'approche FL avec KQE surpasse la solution CL VAE-LSTM proposée par le travail [253] dans la plupart des ensembles de données malgré le fait que le modèle CL a tendance à mieux fonctionner que leurs homologues FL. Cela démontre qu'un seuil approprié déterminé par la technique KQE peut améliorer considérablement les performances d'un modèle de détection d'anomalie, et KQE est meilleur et plus rapide pour trouver le seuil optimal dans la plupart des cas.

TABLEAU 5.3 – Approche FL par rapport à l'approche CL sur 7 séries de données chronologiques différentes

Base de données	Ensemble de test	Cloud-Centralisé-VAE-LSTM [253]			Notre approche basée sur les FL		
		Precision	Recall	F1	Precision	Recall	F1
Space shuttle	TEK14	0.5792	0.9990	0.7333	0.8623	0.8431	0.8536
	TEK16	0.9636	0.8881	0.9243	1	1	1
	TEK17	0.8961	0.9637	0.9287	0.9650	1	0.9822
Respiration	nprs43	0.6586	0.4952	0.5653	0.9313	0.5530	0.6939
	nprs44	0.9786	0.2799	0.4353	0.5347	0.5027	0.5182
Gesture	gesture	0.3422	0.9989	0.5098	0.5278	1	0.6910
Nyc taxi	nyc_taxi	0.7711	0.7628	0.7669	0.9606	1	0.9799
ECG	Chfdb_chf01_275	1	1	1	0.9175	1	0.9570
	chfdb_chf13_45590	1	1	1	0.9489	1	0.9738
	chfdbf15	0.6484	0.8968	0.7526	0.9458	1	0.9721
	ltstdb_20221_43	0.9607	1	0.9800	1	1	1
	ltstdb_20321_240	1	1	1	1	1	1
	mitdb_100_180	0.9754	1	0.9876	1	1	1
	qtdbsel102	0.5827	1	0.7364	0.9604	1	0.9797
	stdb_308_0	0.7521	1	0.8585	0.6073	0.6373	0.6220
	xmitdb_x108_0	0.6727	1	0.8043	1	0.7628	0.8654
Power demand	Power_demand	0.2728	0.8948	0.4182	0.7355	0.9100	0.8135
SCADA	Scada	0.9315	1	0.9645	0.9609	0.9982	0.9792

Expérience 2

Les approches heuristique et KQE sont testées pour identifier le meilleur seuil en plus des scénarios centralisés (par exemple, l'approche de travail [253]) et FL avec un ensemble de données SCADA pour évaluer l'influence de l'approche FL et KQE optimisation de seuil basée sur les performances de détection séparément. Le Tableau 5.3[6] démontre que la stratégie basée sur KQE offre un meilleur score F1 et une meilleure précision dans les cas centralisés et fédérés, avec juste une petite réduction du rappel dans l'approche FL. Avec la méthode de sélection de seuil basée sur KQE, la méthode centralisée basée sur le cloud proposée par le travail [253] augmente légèrement ses propres performances de détection. Le meilleur p trouvé pour l'ensemble de données SCADA est 0.9. La valeur de l'aire sous la courbe ROC (en anglais Receiver Operating Characteristic curve) et AUC (en anglais Area Under the ROC Curve) est également testée pour les deux scénarios car cette métrique n'est pas affectée par la sélection du seuil [6]. De plus, la valeur AUC de FL est légèrement inférieure à celle du modèle CL, indiquant que la diminution de la qualité du modèle causée par FL est mineure.

TABLEAU 5.4 – Résultats centralisés ou fédérés l'ensemble de données SCADA [6]

Learning Approach	Heuristic-based threshold			KQE-based threshold			AUC	
	Precision	Recall	F1	Best p	Precision	Recall		F1
Centralized	0.9315	1	0.9645	0.9	0.9585	1	0.9788	0.8539
Federated	0.9315	1	0.9645	0.9	0.9609	0.9982	0.9702	0.8500

5.3.4 Évaluation de l'efficacité de l'Edge Computing

Cette section décrit les performances du matériel Edge réel fonctionnant dans l'environnement IoT d'apprentissage fédéré pour estimer l'efficacité d'une architecture de calcul Edge en réalité avec une capacité matérielle limitée. L'efficacité de communication de l'approche FL est comparée à celle de l'architecture CL. Par ailleurs, les préoccupations de ressources de calcul et de consommation d'énergie à chaque Edge sont également abordées. Comme illustré dans la Fig. 5.4 [6], le banc d'essai implique :

- Quatre kits Raspberry-Pi-4-Model-B agissant comme périphériques périphériques ; Raspberry-Pi-4 est doté d'un processeur Cortex-A72 quadricœur ARM à 1,5 GHz et de 4 Go de RAM avec Raspbian OS 32 bits.
- Un poste de travail Dell Precision 3640 Tower servant de serveur cloud ; le poste de travail comprend un processeur Intel Core i7-10700K 3,8 GHz (jusqu'à 5,1 GHz), une RAM de 16 Go, Arch Linux.
- Tous les appareils Edge et Cloud Server sont interconnectés avec un routeur via leurs interfaces Wifi.




FIGURE 5.4 – Configuration du banc d'essai [6]

Les appareils de périphérie et le serveur cloud échangent les poids et les matrices de biais du modèle VAE-LSTM via le protocole MQTT, qui est standardisé pour l'environnement IoT. *EMQ X Broker* [258] est hébergé sur le serveur cloud en tant que courtier MQTT pour de meilleures performances à long terme. La solution globale s'est avérée avoir des performances de détection élevées, tout en offrant l'avantage d'avoir une réponse rapide

puisque la détection d'anomalie est mise en œuvre à proximité des sources d'attaque (c'est-à-dire le bord). L'architecture FL répartit la tâche de surveillance et de détection sur des zones locales plus petites, afin qu'elle puisse mieux gérer les Big Data générées dans une usine intelligente. De plus, il est prouvé que le système proposé réduit la bande passante pour contrôler les données dans la liaison de transmission entre la périphérie et le cloud, tout en garantissant que le matériel de périphérie ne sera pas surchargé en termes d'utilisation du processeur et de la mémoire [6].

5.4 Conclusion

Dans ce chapitre, nous avons discuté de la cybersécurité pour les systèmes industriels basés sur l'IoT, en particulier pour le ICS d'une usine intelligente dans la nouvelle ère numérique. Les algorithmes d'apprentissage automatique se sont révélés être des approches efficaces pour la détection des anomalies tant qu'ils sont choisis, combinés et optimisés correctement pour chaque contexte et caractéristique du système. De plus, pour renforcer ces techniques basées sur l'apprentissage automatique, une architecture globale bien conçue avec un calcul distribué sur différents sites, avec un protocole léger, avec FL pourrait permettre à ces systèmes de détection d'anomalies de fonctionner efficacement en termes de réponse rapide du système, économie de bande passante sur les canaux de communication et confidentialité des données. Avec ces conceptions de pointe de détection d'anomalies, les systèmes industriels modernes basés sur l'IoT ou tout réseau basé sur l'IoT pourraient être plus résilients et fiables pour être déployés pour de nombreuses applications et objectifs s'exécutant dessus. Ce chapitre est écrit sur la base de plusieurs travaux coopératifs avec HUST (Hanoi University of Science & Technology), Vietnam. Les résultats de la recherche sont réalisés principalement par des élèves-ingénieurs (niveau M2) sous la direction du Prof. Thu Huong Truong et moi-même ([238], [242], [5], [250], [6]) et de post-doctorants (M. Quoc Thong Nguyen et M. Huu Du Nguyen [241], [247], [79]). Cette direction de recherche se poursuivra avec une thèse en cours de Mme. Van Nguyen Thi Thuy.

Chapitre 6 :

Contributions à la surveillance pour les systèmes de santé intelligents avec des techniques d'apprentissage fédéré

6.1 Introduction

Avec l'augmentation du nombre d'appareils Internet des objets (Internet of things ou IoT en anglais) utilisés au 21e siècle, une quantité massive de données a été générée [259]. Les appareils IoT sont capables de collecter une énorme quantité de données chaque jour [260]. Cette collecte de données et les ressources de calcul en augmentation exponentielle ont ouvert de nouvelles dimensions dans le secteur des technologies de l'information, en particulier dans l'apprentissage en profondeur (DL) [261]. Bien que l'apprentissage en profondeur soit un concept assez ancien [262], mais en raison des données limitées et des ressources informatiques disponibles dans le passé, son utilisation était limitée. Cependant, grâce à Internet, aux appareils IoT et à la puissance de calcul croissante, nous pouvons aujourd'hui voir l'apprentissage en profondeur révolutionner presque tous les domaines, y compris les soins de santé [263], l'économie [264], la fabrication [12], l'agriculture [265] et militaire [266].

En ce qui concerne les applications de santé, de nombreuses données sont générées à travers le monde et elles ont des propriétés tout à fait uniques. La plupart des données liées aux soins de santé sont multidimensionnelles, ce qui rend l'utilisation de modèles d'apprentissage automatique (en anglais Machine Learning, ML) classiques, par exemple, les arbres de décision et les forêts aléatoires, assez difficile et complexe. Cependant, les modèles d'apprentissage automatique de nouvelle génération, en particulier ceux basés sur l'apprentissage en profondeur, peuvent résoudre les problèmes liés aux données multidimensionnelles en raison de leur capacité d'auto-apprentissage [267]. Dans le secteur de la santé, l'apprentissage en profondeur a joué un rôle essentiel, par exemple, pour aider à diagnostiquer des maladies potentiellement mortelles [268]. Néanmoins, il a quelques limitations [269]. Premièrement, pour former un modèle de deep learning, une grande quantité de données de formation est nécessaire, mais chaque silo (par exemple, un hôpital) peut avoir une quantité de données très limitée, donc une seule source de données peut être insuffisante pour former un bon modèle DL. Une solution consiste à collecter des données à partir de plusieurs sources, puis à entraîner le modèle sur les données collectées. Un problème majeur de cette approche concerne les problèmes de confidentialité [270]. Comme les données médicales sont des données hautement sensibles et privées, certaines sources individuelles peuvent ne pas être disposées à partager leurs données avec un collecteur de données central [271].

En 2016, Google a proposé une idée appelée apprentissage fédéré (en anglais Federated Learning, FL) pour résoudre le conflit entre la disponibilité des données et les problèmes de confidentialité [272]. Comme nous l'avons vu au chapitre 5, l'idée de base derrière l'apprentissage fédéré est d'entraîner en collaboration un modèle d'apprentissage automatique sans données d'entraînement centralisées. L'apprentissage fédéré permet aux appareils périphériques ou aux serveurs dotés d'une puissance de calcul suffisante (par exemple, des ordinateurs personnels, des téléphones portables, des appareils portables et d'autres appareils IoT) d'apprendre en collaboration un modèle d'apprentissage automatique partagé tout en conservant toutes les données de formation sur des appareils locaux, en dissociant la capacité de faire de la machine apprendre de la nécessité de stocker les données de manière centralisée sur un seul serveur ou dans le cloud. Bien que l'apprentissage en profondeur avec un cadre fédéré puisse

résoudre les problèmes mentionnés précédemment, il existe un problème d'explicabilité dans l'apprentissage en profondeur. Étant donné que les modèles d'apprentissage en profondeur sont généralement des modèles de boîte noire, sans explication raisonnable pour une prédiction donnée. Cette ambiguïté entraîne une limitation de l'apprentissage en profondeur dans les soins de santé, car un praticien clinique doit connaître la raison d'une prédiction par un modèle d'apprentissage en profondeur [273]. Pour résoudre le problème de l'explicabilité dans les modèles d'apprentissage profond, les chercheurs ont proposé différentes solutions [274, 275, 276]. Par exemple, Selvaraju a proposé une méthode appelée Gradient-weighted Class Activation Mapping (en anglais Gradient-weighted Class Activation Mapping, Grad-CAM) [277] pour visualiser les régions d'entrée qui sont importantes pour les prédictions. À partir de telles valeurs, nous pouvons avoir une idée de l'endroit où se concentre exactement le modèle d'apprentissage automatique tout en faisant une prédiction et donc la raison. L'explicabilité est importante dans les soins de santé, car pour convaincre un praticien de soins de santé clinique et un patient, nous devons leur donner la raison d'une certaine prédiction pour la saisie de l'échantillon.

En ce qui concerne l'application de l'apprentissage en profondeur dans les soins de santé, la classification des électrocardiogrammes(en anglais Electrocardiography, ECG) est une tâche de routine très importante. De nombreuses solutions basées sur l'apprentissage automatique ont été proposées pour analyser et classer les données ECG [276, 278, 279, 280, 281, 282, 283, 284, 285]. Cependant, la plupart de ces travaux sont basés sur une architecture d'apprentissage automatique centralisée, par la suite ils sont sujets à des problèmes tels que les problèmes de confidentialité et la disponibilité des données. De plus, comme la plupart des données ECG en temps réel sont bruyantes, elles ne peuvent pas bien fonctionner en temps réel car elles sont entraînées sur des données prétraitées (plus propres). De plus, ils ne fournissent pas d'explicabilité/interprétabilité (nous utilisons l'explicabilité et l'interprétabilité de manière interchangeable tout au long de cet article), ce qui est l'une des exigences clés des soins de santé cliniques basés sur l'apprentissage en profondeur. Par conséquent, cela limite leur application en temps réel. Pour relever tous les défis mentionnés ci-dessus, dans ce chapitre, nous proposons un cadre de soins de santé explicable de bout en bout dans un cadre fédéré. Le Framework proposé se compose de trois parties principales : un autoencodeur (en anglais Autoencoder, AE), un classifieur et un module Intelligence Artificielle Explicable (en anglais Explainable Artificial Intelligence, XAI). Tout d'abord, nous proposons un nouvel autoencodeur basé sur un réseaux de neurones convolutifs (en anglais Convolutional Neural Network, CNN), qui est utilisé pour débruiter les signaux ECG bruts du sujet directement. Deuxièmement, nous proposons un nouveau classificateur basé sur CNN, qui utilise l'apprentissage par transfert pour classer les séries temporelles brutes de données ECG. Troisièmement, nous adoptons le modèle Grad-CAM [277] dans le cadre pour expliquer les résultats de la classification dans un modèle nouveau et fiable. De plus, nous proposons une approche personnalisée de réduction des coûts de communication qui réduit les coûts de communication et augmente la protection de la vie privée du cadre [7]. Les principaux apports de ce chapitre sont les suivants :

1. Nous proposons un cadre de bout en bout qui est le premier cadre d'apprentissage par transfert fédéré et basé sur le XAI pour les soins de santé. Il agrège les données de différents appareils périphériques (hôpitaux, utilisateurs) sans compromettre la confidentialité et la sécurité, fournit un apprentissage de modèle relativement

personnalisé grâce au transfert de connaissances et fournit l'interprétabilité des résultats, qui est l'une des exigences clés dans des applications telles que les soins de santé. En plus de l'interprétabilité, le module XAI proposé peut être utilisé pour reconnaître de nouveaux modèles potentiels conduisant à déclencher des arythmies cardiaques.

2. Nous proposons un nouvel autoencodeur 1-dimension basé sur CNN dans un cadre fédéré pour débruiter efficacement la série chronologique brute des données de signal ECG collectées auprès des patients. L'autoencodeur fournit une version débruitée de l'entrée, que nous utilisons pour une classification et une explication plus poussées des prédictions.
3. Avec l'aide de l'apprentissage par transfert, nous utilisons la partie encodeur de l'autoencodeur proposé pour créer un nouveau classificateur monodimensionnel basé sur CNN pour classer des données ECG en cinq classes : battements non-écotiques (N), battements ectopiques supraventriculaires (S), battements ectopiques ventriculaires (V), battements de fusion (F) et battements inconnus (Q).
4. Nous proposons un nouveau module, appelé module XAI pour l'interprétabilité des prédictions du classifieur proposé. Le module XAI proposé est combiné avec le classificateur proposé pour interpréter et expliquer le processus de prise de décision du classificateur. Le module XAI peut être utilisé avec chaque classeur mis à jour localement sur les périphériques de périphérie dans le cadre fédéré, et il ne nécessite aucune formation préalable.
5. Nous proposons une nouvelle méthode de réduction des coûts de communication pour l'apprentissage fédéré dans le cadre proposé, qui non seulement réduit les coûts de communication mais augmente également la confidentialité de la méthode d'apprentissage fédéré classique. De plus, la méthode proposée peut être intégrée aux algorithmes d'optimisation des coûts existants pour améliorer leur rentabilité et leur niveau de protection de la vie privée.
6. Nous avons utilisé la base de données d'arythmie MIT-BIH [286] pour former notre cadre proposé. Il est important de noter que pour rendre les données plus réalistes, nous suréchantillonons d'abord les données pour créer plus d'échantillons de données, puis nous ajoutons 10 – 30% de bruit aléatoire. Le cadre proposé montre d'excellentes performances en fournissant une précision globale de 94,5% en utilisant des données bruitées et une précision globale de 98,9% sur les données propres dans la base de données originale du MIT-BIH. De plus, nous avons évalué les performances du cadre proposé à l'aide de quatre mesures standard : l'exactitude de la classification, la précision, le rappel et le score F1.
7. Le cadre proposé présente en outre des caractéristiques souhaitables : interprétabilité des résultats en utilisant le module XAI proposé et classification efficace de l'ECG. De plus, il offre un niveau amélioré de protection de la vie privée aux utilisateurs en raison du cadre fédéré et de la méthode de réduction des coûts de communication proposée.

6.2 Travaux connexes et antécédents

Les systèmes intelligents nous ont aidés à trouver des solutions efficaces. Divers types de systèmes intelligents, tels que les systèmes intelligents de modélisation des incertitudes par optimisation robuste [287], les parkings intelligents pour véhicules électriques [288], et d'autres larges gammes d'applications [289] ont fait l'objet d'une attention particulière des universités et des industries. Au cours des dernières décennies, les systèmes intelligents basés sur le ML ont été étudiés dans un large éventail d'applications. Par exemple, ses applications ont été étudiées pour la cybersécurité [290], l'économie et l'agriculture [291] et dans les soins de santé [292]. L'utilisation de l'apprentissage automatique dans les soins de santé a été largement étudiée, allant de la détection et du diagnostic de différentes maladies, telles que le mélanome [293, 294] et le cancer [295, 296]. En raison de l'importance de l'apprentissage automatique dans les applications liées aux soins de santé, dans cette section, nous passons en revue la littérature sur l'apprentissage automatique dans les soins de santé, avec un accent particulier sur l'apprentissage automatique pour l'analyse ECG.

6.2.1 Apprentissage automatique dans les soins de santé

Certaines activités de notre corps sont régies par des signaux de certaines maladies cognitives [297]. Par exemple, une démarche changeante peut résulter d'un accident vasculaire cérébral. Un certain nombre de chercheurs ont proposé de surveiller les activités des utilisateurs à l'aide de capteurs portables, à l'aide desquels différentes activités du corps humain peuvent être reconnues [298, 299, 300]. Sur la base du suivi de ces activités, un pronostic précoce des problèmes de santé peut être identifié. À cet égard, il y a eu un développement significatif dans l'utilisation des technologies ML et DL dans les soins de santé. Bien que ces technologies ne remplaceront probablement jamais complètement les praticiens cliniques, elles peuvent transformer le secteur de la santé, profitant à la fois aux patients et aux prestataires [268, 301, 302, 303]. En ce qui concerne l'analyse ECG dans les soins de santé, ML et DL jouent un rôle essentiel. Les chercheurs ont proposé de nombreuses méthodes de classification ECG en types d'arythmie [304, 305, 306, 285, 283]. Rubin et al. [307] ont appliqué l'apprentissage en profondeur à la tâche de l'auscultation cardiaque automatisée, c'est-à-dire la reconnaissance des anomalies des sons cardiaques. Ils ont décrit un algorithme automatisé de classification des bruits cardiaques qui combine l'utilisation de représentations de cartes thermiques temps-fréquence avec un CNN. Leur architecture CNN est entraînée à l'aide d'une fonction de perte modifiée qui optimise directement le compromis entre sensibilité et spécificité. Gjoreski et al. [308] ont présenté une méthode de détection de l'insuffisance cardiaque chronique (en anglais Chronic Heart Failure, CHF) basée sur les bruits cardiaques. La méthode combine des modèles classiques de ML et de DL de bout en bout. Le modèle ML classique apprend à partir de fonctionnalités expertes et le modèle DL apprend à partir d'une représentation spectro-temporelle du signal. De plus, afin de permettre une classification intelligente des arythmies avec une grande précision, Huang et al. [309] ont présenté un classificateur ECG intelligent utilisant les réseaux de neurones convolutifs résiduels à compression rapide (FCResNet).

Bien que les travaux susmentionnés semblent prometteurs, ils peuvent trouver une

applicabilité limitée dans le monde réel car ils utilisent des techniques de collecte de données centralisées. Comme indiqué précédemment, cela peut entraîner des problèmes de confidentialité parmi les utilisateurs et les propriétaires de données. Par la suite, les applications de soins de santé centralisées traditionnelles trouvent une applicabilité limitée en raison de problèmes de confidentialité [310, 311, 312]. Pour résoudre les problèmes de confidentialité dans l'apprentissage automatique, les chercheurs ont travaillé sur l'apprentissage fédéré (FL) et l'apprentissage par transfert (en anglais Transfer Learning, TF). L'apprentissage fédéré (FL) a été introduit par Google [272]. L'idée clé est de former des modèles de ML avec la confidentialité dès la conception au niveau architectural. FL forme un modèle d'apprentissage automatique dans une architecture distribuée, où les appareils périphériques forment leur propre modèle ML sur leurs données locales et un serveur global central agrège tous les modèles formés localement et redistribue le modèle agrégé à tous les nœuds du réseau (plus des détails sur FL peuvent être trouvés dans la section 6.2.2). En raison de ses contraintes de protection de la vie privée et de communication efficace, FL trouve un certain nombre d'applications dans le domaine de la santé [313]. Xu et al. [314] ont résumé les solutions générales aux défis statistiques, aux défis du système et à la confidentialité, et soulignent les implications et les potentiels de l'application de FL dans les soins de santé. Ils montrent que la formation du modèle dans le cadre d'apprentissage fédéré conduit à des performances comparables à celles du cadre d'apprentissage centralisé traditionnel. Le TF vise à transférer les connaissances d'un modèle formé existant vers un nouveau modèle. L'idée clé est de réduire la divergence de distribution entre les différents modèles. À cette fin, il existe principalement deux approches générales : la repondération d'instance [315] et la mise en correspondance de fonctionnalités [316]. Récemment, les méthodes d'apprentissage par transfert en profondeur ont connu un succès considérable dans de nombreux domaines d'application. Chen et al. [281] ont proposé FedHealth, le premier cadre d'apprentissage par transfert fédéré pour les soins de santé portables afin de relever les défis de la confidentialité et de la sécurité. FedHealth effectue l'agrégation de données via un apprentissage fédéré, puis construit des modèles relativement personnalisés par transfert d'apprentissage. FedHealth permet d'effectuer un apprentissage par transfert en profondeur dans le cadre d'apprentissage fédéré sans accéder aux données utilisateur brutes. Cependant, il y a certaines limites à cela. Premièrement, il ne fournit pas l'explicabilité des prédictions, ce qui est souvent requis dans des domaines sensibles comme les soins de santé. Deuxièmement, il ne prend en charge aucun mécanisme de débruitage des signaux bruts, qui contiennent souvent du bruit aléatoire et le traitement du bruit aléatoire est assez difficile. En d'autres termes, en ce qui concerne l'application des soins de santé ML et DL, de nombreux travaux prometteurs ont été réalisés, comme indiqué ci-dessus. Cependant, certaines de ces œuvres sont vulnérables aux problèmes de confidentialité. Des travaux de recherche comme FedHealth tentent de résoudre les problèmes de confidentialité en utilisant l'architecture FL et TL. Néanmoins, des travaux comme FedHealth ont la limitation de l'explicabilité, comme discuté précédemment. Des travaux de recherche sont donc nécessaires pour relever ces défis.

6.2.2 Apprentissage fédéré

L'apprentissage machine fédéré a été proposé pour la première fois par Google [272], un aperçu de FL est présenté dans la Figure 6.1. Dans les paramètres FL, les modèles

d'apprentissage automatique sont formés sur la base d'appareils de périphérie distribués dans le monde entier. L'idée clé est de protéger les données des utilisateurs pendant le processus. FL a la capacité de résoudre les problèmes d'ilotage de données en préservant la confidentialité de la formation du modèle dans le réseau. Cela fonctionne comme ceci : un périphérique (client) de périphérie télécharge le modèle actuel, l'améliore en apprenant des données sur ses données locales, puis résume les modifications sous la forme d'une petite mise à jour ciblée. Seule cette mise à jour du modèle est envoyée au cloud, à l'aide d'une communication cryptée, où elle est agrégée avec d'autres mises à jour utilisateur pour améliorer le modèle global partagé. Toutes les données d'entraînement restent sur les appareils locaux et aucune mise à jour individuelle n'est stockée dans le cloud. L'apprentissage fédéré permet des modèles plus intelligents, une latence plus faible et une consommation d'énergie moindre, tout en garantissant la confidentialité. Cette approche présente un autre avantage : en plus de fournir une mise à jour du modèle global partagé, le modèle amélioré sur l'appareil de périphérie local peut également être utilisé immédiatement, alimentant des expériences personnalisées par l'utilisation d'appareils IoT.




FIGURE 6.1 – Architecture de l'apprentissage fédéré [7]

6.2.3 Apprentissage par transfert

L'apprentissage par transfert vise à transférer les connaissances des domaines existants vers un nouveau domaine. L'idée clé est de réduire la divergence de distribution entre les différents domaines. Voici principalement deux types d'apprentissage par transfert : repondération [315] et fonctionnalité correspondant [316]. Récemment, les méthodes d'apprentissage par transfert en profondeur ont connu un succès considérable dans de nombreux domaines d'application.

6.2.4 Intelligence Artificielle Explicable

L'intelligence artificielle explicable [273] permet aux humains de comprendre et d'expliquer comment un système d'IA a pris une décision. XAI est un ensemble de processus et de méthodes qui permet aux utilisateurs humains de comprendre et de faire confiance aux résultats et aux sorties créés par les algorithmes d'apprentissage automatique. XAI est utilisé pour décrire un modèle d'IA, son impact attendu et les biais potentiels. Il aide à caractériser la précision, l'équité, la transparence et les résultats du modèle dans la prise de décision basée sur l'IA. XAI est crucial pour une organisation pour établir la confiance lors de la mise en production de modèles d'IA. L'explicabilité de l'IA aide également une organisation à adopter une approche responsable du développement de l'IA. Il y a de nombreux avantages à comprendre comment un système basé sur l'IA a conduit à une sortie spécifique. L'explicabilité peut aider les développeurs à s'assurer que le système fonctionne comme prévu, qu'il peut être nécessaire pour répondre aux normes réglementaires ou qu'il peut être important pour permettre aux personnes concernées par une décision de contester ou de modifier ce résultat. Des recherches récentes suggèrent qu'il sera d'une importance clé dans le marketing [317], les soins de santé, la fabrication, les assurances et les automobiles [318].

6.3 Le cadre proposé

Avant de décrire en détail notre cadre proposé, expliquons d'abord le problème de recherche. Étant donné les données sur N différents nœuds périphériques (puisque nous utilisons l'apprentissage fédéré entre silos, chaque nœud périphérique peut représenter une organisation différente, c'est-à-dire un hôpital) représenté par $E = \{E_1, E_2, \dots, E_N\}$ et la donnée de chaque E_i (ici $i = 1, 2, \dots, N$) est donnée par $\{D_1, D_2, \dots, D_i\}$, respectivement. Un modèle d'apprentissage automatique conventionnel, noté ConMOD, peut être entraîné en combinant toutes les données $D = \{D_1, D_2, \dots, D_i\}$. Les données de différents nœuds périphériques ont des distributions différentes. Cependant, dans notre problème, nous voulons collaborer toutes les données pour former un modèle d'apprentissage par transfert fédéré, noté FedMOD, où aucun utilisateur E_i n'expose ses données D_i à d'autres. Supposons que AccFed représente la précision de FedMOD et que AccCon $_i$ représente la précision de chaque modèle formé localement de E_i , alors l'un des objectifs de notre méthode proposée est de s'assurer que la précision de AccFed est proche ou supérieur à chaque AccCon $_i$. Le cadre proposé vise à obtenir des soins de santé personnels précis et efficaces grâce à l'apprentissage par transfert fédéré et au XAI sans compromettre la confidentialité. La Figure 6.2 donne un aperçu de la méthode proposée. La méthode proposée se compose de trois parties principales, l'autoencodeur, le classificateur et le

module XAI, qui sont discutés ci-dessous dans les trois sous-sections suivantes. La dernière sous-section 6.3.4 traite du processus d'apprentissage.

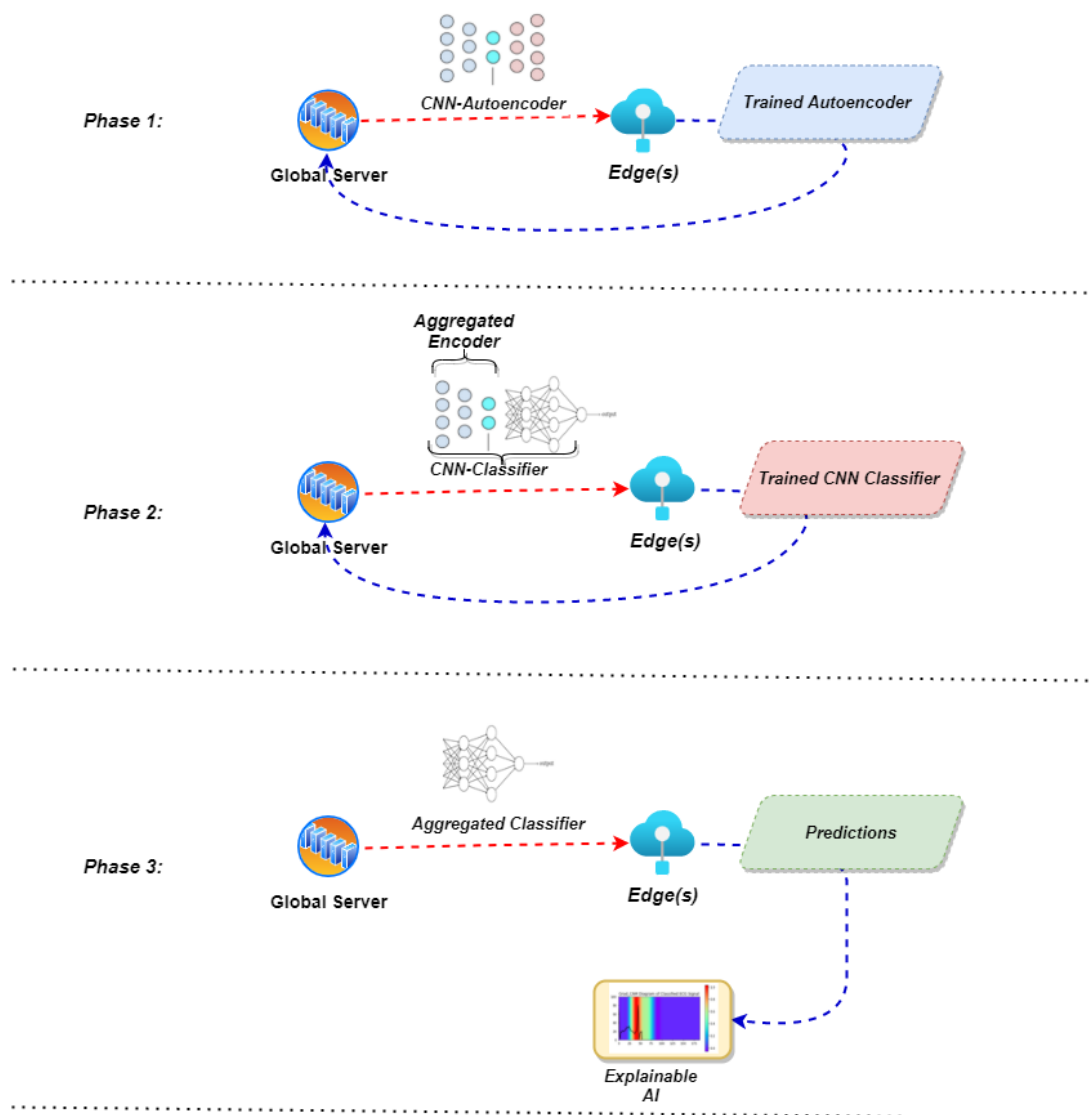


FIGURE 6.2 – Un aperçu du cadre proposé [7]

6.3.1 Autoencodeur CNN

Afin de débruiter le signal d'entrée brut des appareils ECG, nous avons proposé un autoencodeur. L'autoencodeur proposé est illustré à la Figure 6.3. Il se compose d'une couche d'entrée, d'une couche de sortie et de 12 couches cachées. Parmi les couches cachées, il y a 6 couches convolutives, 3 couches de maxpooling et 3 couches de suréchantillonnage. De plus, l'Autoencodeur CNN est virtuellement divisé en deux parties : Encoder et Decoder. L'encodeur se compose de la couche d'entrée, de 3 couches maxpooling et de 3 couches convolutives de manière alternative. D'autre part, le décodeur se compose de 3 couches de suréchantillonnage, de 3 couches convolutives et d'une couche de sortie convolutive. Dans l'autoencodeur proposé, nous utilisons un taux d'apprentissage variable pour maintenir le processus d'apprentissage efficace tout

en maintenant la perte de reconstruction L aussi faible que possible. L'équation (6.1) donne la représentation mathématique du taux d'apprentissage (lr) utilisé.

$$lr = \begin{cases} 0.01, & \text{si époque} \leq 40, \\ lr \times e^{-0.1}, & \text{autrement.} \end{cases} \quad (6.1)$$




FIGURE 6.3 – L'architecture de l'autoencodeur de débruitage proposé [7]

6.3.2 Classificateur basé sur CNN

Le classificateur proposé est composé de 4 couches de convolution, 3 couches de pooling max, 2 couches entièrement connectées et 1 couche softmax pour la classification, comme le montre la Figure 6.4. Le classificateur est conçu pour classer un signal ECG d'entrée dans l'une des cinq classes, comme indiqué dans le Tableau 6.1. Nous utilisons l'apprentissage par transfert pour transférer la partie encodeur de l'autoencodeur entraîné dans le classificateur proposé, car ces couches de convolution visent à éliminer le bruit des données d'entrée brutes et les couches suivantes du classificateur visent à classer le signal ECG d'entrée. Par conséquent, les 3 premières couches convolutives n'ont pas besoin d'être entraînées lors de l'entraînement des classificateurs locaux individuels. En d'autres termes, nous gardons les 3 premières couches convolutives statiques pendant la phase d'apprentissage du classificateur, ce qui signifie qu'aucun paramètre n'est mis à jour lors de la rétropropagation dans les 3 premières couches convolutives. Cela fournit à chaque nœud local E_i les paramètres entraînés pour débruiter le signal tout en entraînant le classificateur, ce qui augmente les performances du classificateur. Quant aux 2 dernières couches de convolution et aux couches entièrement connectées, puisqu'elles sont à un niveau supérieur, elles se concentrent sur l'apprentissage de caractéristiques spécifiques

pour la tâche de classification. Par conséquent, nous mettons à jour leurs paramètres pendant la phase d'apprentissage du classificateur. Le softmax sert de fonction de classification et est donné par l'équation suivante :

$$y_i = \frac{\exp^{z_c}}{\sum_{c=1}^C \exp^{z_c}}, \quad (6.2)$$

où C est le nombre total de classes, z_c désigne la probabilité apprise pour une classe spécifique c et y_i est le résultat de classification final pour un échantillon i . Notre classificateur utilise l'entropie croisée (CE) catégorique comme fonction de perte. Cela donne une probabilité sur les classes C pour chaque échantillon d'entrée, donnée par l'équation (6.3). Où t_c est la vérité terrain pour chaque classe c .

$$CE = - \sum_c^C t_c \log(y_i) \quad (6.3)$$

TABLEAU 6.1 – Les cinq classes de signaux ECG

Description de la classe	symbole à une lettre
Battements non-écotiques (battement normal)	N
Battements ectopiques supraventriculaires	S
Battements ectopiques ventriculaires	V
Battements de fusion	F
Battements inconnus	Q

6.3.3 XAI with Grad-CAM

Inspirés par les travaux de [277] et [319], nous avons décidé d'utiliser le mappage d'activation de classe pondéré par le gradient (Grad-CAM) et l'avons modifié pour les données de séries chronologiques en plus de notre classificateur, qui utilise des informations de gradient pour localiser les régions importantes. Nous combinons ces régions localisées avec une carte de visualisation de séries temporelles existante pour créer une visualisation de carte thermique haute résolution. En utilisant cette visualisation, les praticiens peuvent comprendre la raison d'une certaine prédiction donnée par le classificateur. Le module XAI avec GRAD-CAM est illustré à la Figure 6.5.

La création de cette visualisation de carte thermique comprend les étapes suivantes :

1. Dans la première étape, nous calculons le gradient de y^c (où y^c est le score pour toute classe c) par rapport aux activations de la carte de caractéristiques A^k pour le noyau k de la dernière couche de convolution. Si G_c représente les gradients pour n'importe quelle classe c , il peut être représenté comme suit :

$$G_c = \frac{\partial y^c}{\partial A^k}. \quad (6.4)$$

Toute valeur particulière calculée à cette étape dépend du signal ECG d'entrée (entrée d'échantillon). Les poids du classificateur sont fixés à ce stade. Nous

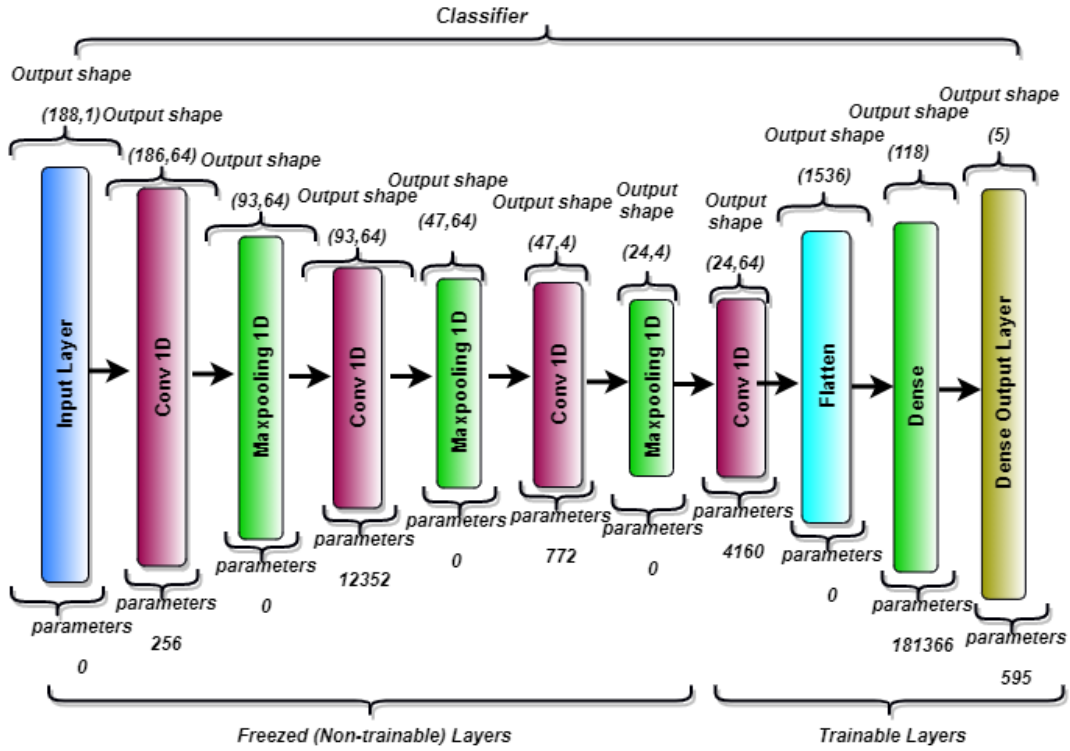


FIGURE 6.4 – Le classifieur proposé basé sur CNN [7]

remodelons d'abord un échantillon d'entrée dans la taille du lot et l'injectons dans le classifieur, puisque l'entrée détermine les cartes de caractéristiques A_k ainsi que y^c .

2. La deuxième étape consiste en une mise en commun globale moyenne des gradients G_c , à la fois le long de la hauteur h et de la largeur w pour obtenir les poids d'importance des neurones α_k^c aussi appelés valeurs alpha, données par l'équation (6.5).

$$\alpha_k^c = \frac{1}{Z} \sum_h \sum_w \frac{\partial y^c}{\partial A^k} \quad (6.5)$$

Ces valeurs alpha pour la classe c et la carte de caractéristiques k seront utilisées plus tard comme poids appliqué à la carte de caractéristiques A^k .

3. La troisième étape consiste en une combinaison linéaire pondérée des activations de la carte de caractéristiques A^k et α_k^c est calculée en utilisant les valeurs alpha, données par l'équation (6.6).

$$\text{Grad_CAM}^c = \text{ReLU}(\sum_k \alpha_k^c A^k) \quad (6.6)$$

Cela nous donne la carte thermique finale Grad-CAM. Une fonction d'unité linéaire de redressement (ReLU) est appliquée pour souligner uniquement les valeurs positives et transformer toutes les valeurs négatives en 0.

4. Les caractéristiques de la dernière couche convolutive du classifieur sont assez

petites, et il est difficile de les visualiser pour l'analyse. Pour résoudre ce problème, nous suréchantillonons la carte thermique à la taille de l'échantillon d'entrée en largeur. De plus, nous transmettons l'échantillon d'entrée à l'encodeur automatique et recevons une version débruitée de l'échantillon d'entrée et le superposons sur la carte thermique. Dans la carte thermique résultante, les régions qui se chevauchent entre la carte thermique et le signal ECG montrent le point de focalisation pendant la prédiction. Cela donne une image détaillée aux praticiens pour comprendre quelle région du signal d'entrée ECG le classificateur regarde tout en faisant une prédiction.

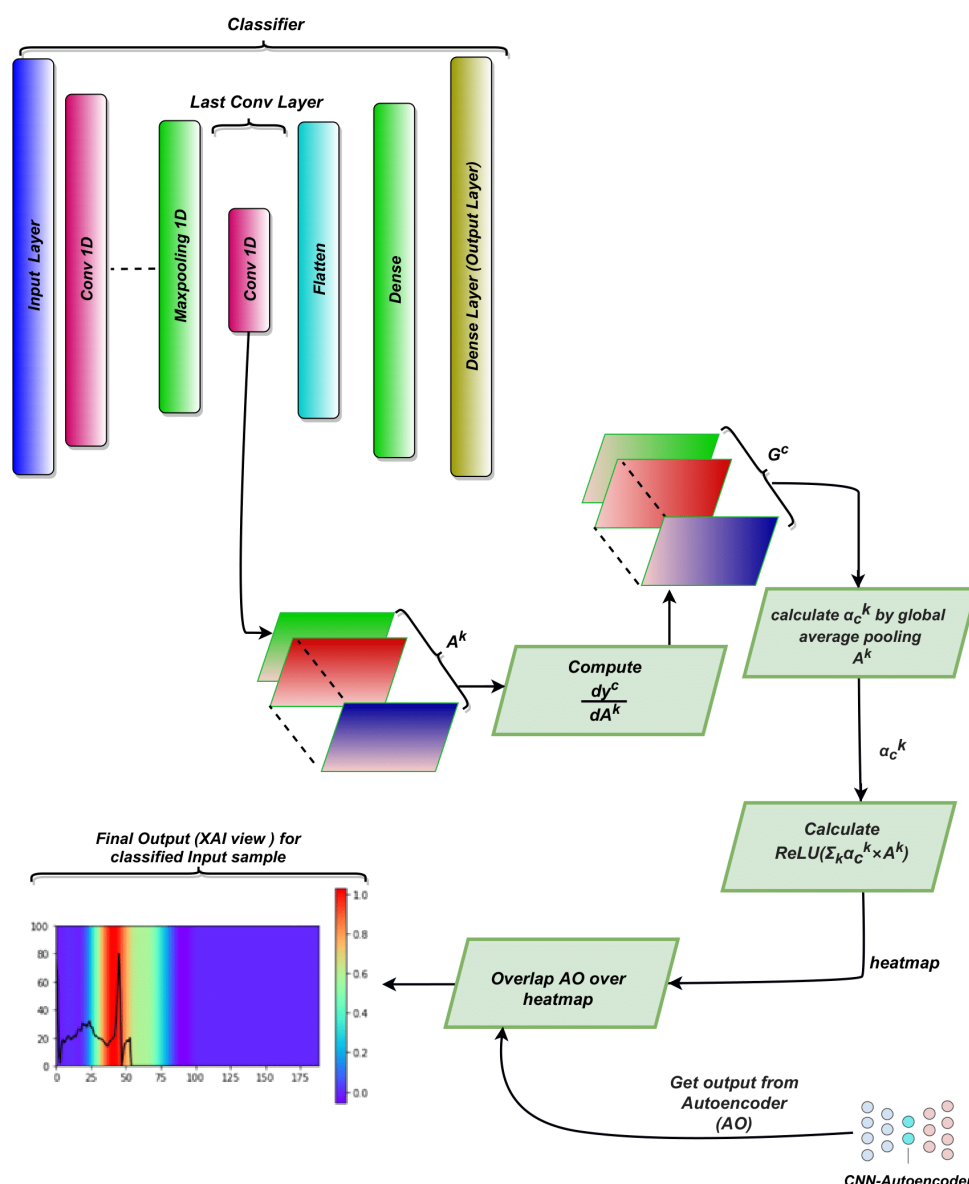


FIGURE 6.5 – Présentation du module XAI proposé dans notre framework [7]

6.3.4 Processus d'apprentissage

Le processus d'apprentissage de la méthode proposée a été décrit dans la Figure 6.2. Il convient de noter que l'algorithme fonctionne en permanence avec de nouvelles

données émergentes. Facultativement, si un E_i veut personnaliser le classificateur C , cela peut être fait en gardant statiques toutes les couches de convolution du classificateur mis à jour final et en entraînant les couches denses pour la personnalisation. En effet, les couches de convolution visent à extraire des caractéristiques de bas niveau sur la reconnaissance d'activité et pour les couches densément connectées, puisqu'elles sont à un niveau supérieur, elles se concentrent sur l'apprentissage de caractéristiques spécifiques pour la tâche et l'utilisateur.

Le serveur global G_s (Aggregation Server) crée un autoencodeur avec des hyper-paramètres prédéfinis. Il est à noter que nous utilisons l'auto-tuner Keras pour obtenir les meilleurs hyper-paramètres possibles. Keras auto-tuner essaie empiriquement de trouver les meilleurs hyper-paramètres possibles. Après avoir créé l'AE, G_s attend la demande des clients. Lorsque les clients demandent G_s , il envoie l'AE au client. Il est à noter que, chaque tour global est divisé en deux niveaux, pour le premier niveau G_s envoie l'AE et pour le deuxième niveau G_s envoie le classificateur C . Ainsi, lors de la demande, chaque client mentionne également le niveau. A la réception de l'autoencodeur, le client E_i entraîne l'autoencodeur sur ses données locales D_i . Une fois l'entraînement terminé, le client renvoie les poids entraînés de l'encodeur automatique au serveur global. Le serveur attend un nombre fixe n de clients pour envoyer les poids de leur AE formé localement. Ici, n peut être décidé par consensus mutuel entre les administrateurs. Lorsque le nombre souhaité de clients envoie leurs poids et est reçu par G_s , il agrège les poids de tous les clients en utilisant la formule d'agrégation donnée par l'équation (6.7) de [320].

$$F(w) = \sum_{k=1}^n \frac{n_k}{n_t} w_{r+1}^k, \text{ où } F_k(w) = \frac{1}{n_k} \sum_{i \in P_k} f_i(w). \quad (6.7)$$

Ici, $F(w)$ sont les poids agrégés, n_t est le nombre d'échantillons de données de tous les participants et n_k est le nombre d'échantillons de k^{th} participant. Pour un problème d'apprentissage automatique, typiquement $f_i(w) = (x_i, y_i; w)$, c'est-à-dire la perte de la prédiction sur l'exemple x_i, y_i fait avec les paramètres du modèle w . Il y a n clients sur lesquels les données sont partitionnées, avec P_k l'ensemble d'index de points de données sur le client k , n est le nombre total de participants à chaque tour et r est le nombre rond global.

Après l'agrégation, G_s crée un nouveau classificateur basé sur CNN C pour la classification. Ici, encore une fois, nous utilisons l'auto-tuner Keras pour les meilleurs hyper-paramètres pour le C nouvellement créé. De plus, nous utilisons la partie encodeur de l'autoencodeur pour l'apprentissage par transfert. Nous transférons les poids de la partie encodeur mise à jour et agrégée de AE à C et définissons les couches transférées sur statiques. Après cela, G_s envoie C à chaque client E_i . A la réception de C , chaque E_i forme le classificateur en utilisant ses données locales et le renvoie à G_s . G_s collecte le poids de n clients et les agrège en utilisant l'équation (6.7). Après l'agrégation, il renvoie les poids agrégés à chaque E_i . Les clients définissent les poids agrégés en tant que nouveaux poids de leur C local, qui peuvent ensuite être utilisés pour les prédictions. Pendant les prédictions, le module XAI exploite les gradients et génère l'explication visuelle.

6.3.5 Réduction des coûts de communication et amélioration de la confidentialité

Dans le cadre de l'apprentissage fédéré, les données de formation restent réparties sur un grand nombre de clients, chacun avec des connexions réseau peu fiables et relativement lentes. Pour les protocoles synchrones en apprentissage fédéré [321], le nombre total de bits de communication requis pendant la communication montante et descendante par chacun des N clients pendant la formation du modèle global est donné par :

$$\tau^{\text{up/down}} \in \mathcal{O}(U \times |w| \times (H(\Delta w^{\text{up/down}}) + \tau)), \quad (6.8)$$

où U est le nombre total de mises à jour par chaque client, $|w|$ est la taille du modèle et $H(\Delta w^{\text{up/down}})$ est l'entropie des poids transmis pendant la communication, τ est la différence entre la taille de mise à jour et la taille de mise à jour minimale, donnée par l'entropie [322]. Généralement, il existe trois façons de réduire les coûts de communication : (1) réduire le nombre de clients N , (2) réduire la taille des mises à jour, (3) réduire le nombre de mises à jour U . Par conséquent, la recherche sur l'apprentissage fédéré efficace en communication peut être divisée en quatre groupes : la compression de modèle, la sélection du client, la réduction des mises à jour et l'apprentissage entre pairs [314]. Afin de fournir un apprentissage fédéré efficace en communication, nous proposons une nouvelle approche pour notre architecture proposée appelée sélection de couche, qui relève du groupe de compression de modèle. De plus, la sélection de couches peut être ajoutée à toutes les approches existantes pour réduire davantage les coûts de communication. La méthode de sélection de couche proposée (réduction des coûts de communication) est illustrée à la Figure 6.6, avec plus de détails ci-dessous.

Supposons que $W1$ et $W2$ représentent les poids de toutes les couches d'encodeur et de décodeur de l'autoencodeur, respectivement, entraînés au niveau des dispositifs périphériques. Comme nous ne nous intéressons qu'à la partie encodeur de l'autoencodeur, les périphériques de bord sélectionnent les poids de la partie encodeur ($W1$) et les envoient au serveur global. Le serveur global agrège les poids reçus pour obtenir les poids globaux, représentés par $AW1$ et envoyés aux bords. Après avoir reçu $AW1$, les périphériques de périphérie utilisent l'apprentissage par transfert pour transférer ces poids globaux vers leur classificateur local et geler les couches transférées, comme mentionné précédemment. Les dispositifs périphériques entraînent le classificateur local à l'aide de leurs données locales. Supposons que $WC1$ et $WC2$ représentent les poids des couches inférieures (convolutionnelles) et supérieures (denses) pouvant être entraînés d'un classificateur local, respectivement. Au fur et à mesure que les couches supérieures apprennent des fonctionnalités spécifiques sur les données sous-jacentes [323], chaque bord envoie uniquement $WC1$ au serveur d'agrégation qui contient des fonctionnalités communes et de bas niveau sur les données d'entraînement. Le serveur d'agrégation effectue une agrégation pondérée de toutes les pondérations $WC1$ reçues pour obtenir $AWC1$, qui sont ensuite envoyées aux périphériques de périphérie. Les appareils périphériques utilisent $AWC1$ avec leur $WC2$ individuel pour une classification plus localisée de l'ECG. Comme nous partageons peu de poids par rapport à la méthode classique, cela allège la communication et réduit les coûts de communication. De plus, étant donné que le cadre FL effectue en permanence une formation globale avec des données émergentes, notre

méthode de réduction des coûts de communication peut réduire considérablement les coûts de communication globaux.

De plus, rappelez-vous que les fonctionnalités des réseaux de neurones profonds sont hautement transférables dans les niveaux inférieurs du réseau, car elles se concentrent sur l'apprentissage de fonctionnalités plus courantes et de bas niveau. Comme les périphériques de périphérie n'envoient que les poids des couches inférieures, la confidentialité des données sous-jacentes à chaque périphérie est améliorée. Pour être plus précis, les poids de la couche inférieure, les poids de la partie encodeur dans l'autoencodeur (WC1), contiennent des caractéristiques plus courantes et de bas niveau sur les données sous-jacentes, tandis que les poids des couches supérieures, les poids de la partie décodeur du autoencodeur (WC2), contient des fonctionnalités plus spécifiques sur les données sous-jacentes. Par conséquent, en ne communiquant pas WC2, nous pouvons augmenter la confidentialité des données locales en partageant uniquement les poids (WC1) qui contiennent des fonctionnalités plus courantes et de bas niveau (c'est-à-dire moins privées).

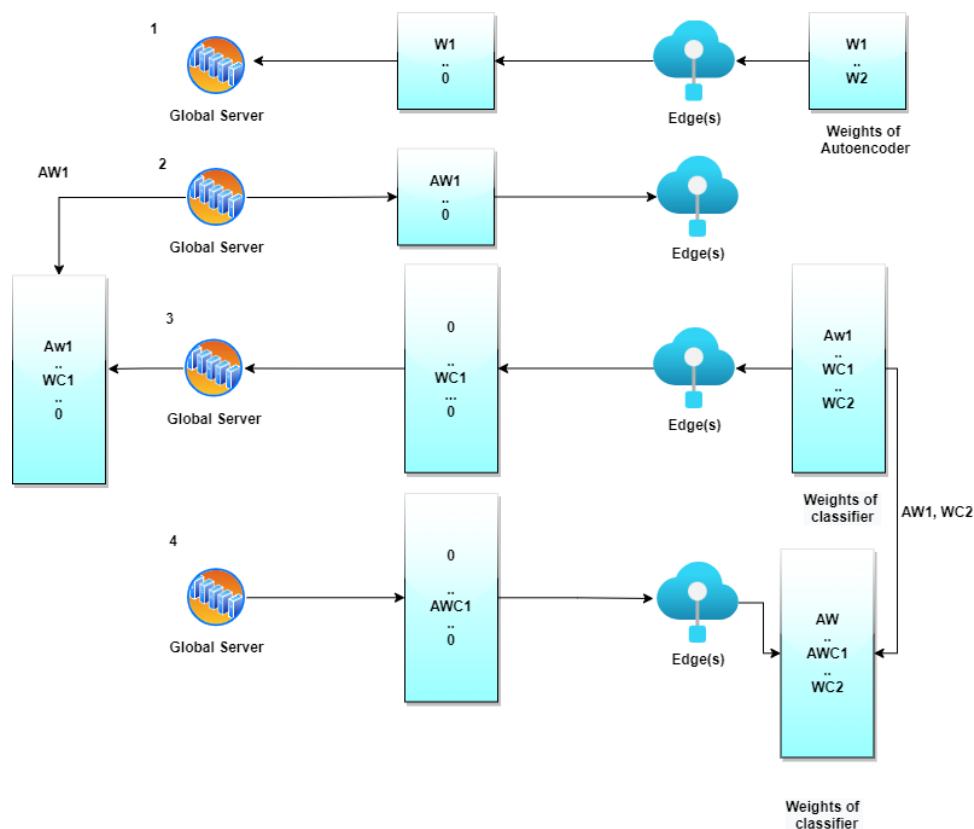


FIGURE 6.6 – La méthode de sélection de couche pour la réduction des coûts de communication [7]

6.4 Résultats expérimentaux

6.4.1 Base de données

À des fins expérimentales, nous avons utilisé la base de données d'arythmie MIT-BIH largement utilisée [286] comme ensemble de données de base. Cette base de données contient 48 extraits d'une demi-heure d'enregistrements ECG ambulatoires à deux canaux, obtenus à partir de 47 sujets étudiés par le laboratoire d'arythmie BIH entre 1975 et 1979. L'ensemble de données comprend 109 446 échantillons. Vingt-trois enregistrements ont été choisis au hasard parmi un ensemble de 4 000 enregistrements ECG ambulatoires de 24 heures collectés auprès d'une population mixte de patients hospitalisés (environ 60%) et ambulatoires (environ 40%) à l'hôpital Beth Israel de Boston ; les 25 enregistrements restants ont été sélectionnés dans le même ensemble pour inclure des arythmies moins courantes mais cliniquement significatives qui ne seraient pas bien représentées dans un petit échantillon aléatoire. Dans notre expérience, nous avons utilisé la dérivation ECG II ré-échantillonnée à la fréquence d'échantillonnage de 125 Hz comme entrée. Il convient de noter que cet ensemble de données a des classes déséquilibrées. La Figure 6.7 montre la distribution de l'ensemble de données d'origine. Ces données très déséquilibrées peuvent causer des problèmes comme le surapprentissage. Par conséquent, pour équilibrer les classes, nous avons utilisé le suréchantillonnage. La distribution des données résultante après suréchantillonnage est illustrée à la Figure 6.8. De plus, cet ensemble de données est hautement prétraité, mais dans des scénarios réels, les données EEG collectées sont toujours bruyantes. Par conséquent, pour simuler des données plus réalistes, nous avons introduit 10-30% de bruit dans l'ensemble de données d'origine et avons également entraîné le cadre proposé sur la version bruyante de l'ensemble de données. Une comparaison des ensembles de données d'origine (propres) et bruyants est illustrée à la Figure 6.9.

Le Framework a été implémenté à l'aide de Python et TensorFlow. Une communication de couche socket sécurisée a été utilisée pour la communication entre le serveur et les périphériques de périphérie. L'encodeur automatique et le classificateur ont été entraînés localement uniquement sur trois appareils Raspberry Pi locaux (Pi 3 modèle B+ avec 1,4 GHz, processeur ARMv8 quad-core 64 bits et 1 Go de SDRAM LPDDR2), désignés par $Edge_1$, $Edge_2$ et $Edge_3$. De plus, un poste de travail avec un processeur Intel Core i-6700HQ et 32 Go de RAM a été utilisé comme serveur global G_s . Il convient de noter que FedHealth [281] a initialement formé son modèle à G_s , ce qui peut entraîner des risques de sécurité dans le cas d'un serveur global malveillant. Si les modèles (AE et C) sont entraînés initialement sur G_s , cela peut entraîner un entraînement biaisé. Par conséquent, pour éviter de tels risques, nous n'avons effectué que l'agrégation aux G_s . De plus, AE a adopté une taille de convolution de 3. Il utilise un Root Mean Square Propagation (RMSProp) comme optimiseur. Chaque appareil E_i utilise 80% des données pour l'entraînement et 20% des données pour l'évaluation. Nous avons distribué l'ensemble de données de manière aléatoire sur chaque périphérique périphérique et introduit du bruit aléatoire. Dans ce cas, les données de $Edge_1$ contiennent 20% de bruit aléatoire, les données de $Edge_2$ contiennent 30% de bruit aléatoire, les données de $Edge_3$ contiennent 10% de bruit aléatoire. De plus, chaque arête a utilisé une taille de lot fixe de 100 et a été entraînée pour 50 époques d'entraînement. De plus, chaque arête utilisait un




FIGURE 6.7 – La distribution de l'ensemble de données d'origine [7]

taux d'apprentissage évolutif, donné par l'équation (6.1).

Le classificateur C a utilisé une taille de lot de 100. Le taux d'apprentissage a été fixé à 0,001 avec 150 époques d'apprentissage. La précision de chacun des C formés localement a été calculée en utilisant l'équation suivante :

$$A_{cc}^i = \frac{|x : x \in D_i \wedge y'(x) = y(x)|}{|x : x \in D_i|}. \quad (6.9)$$

En ce qui concerne le temps d'exécution, compte tenu du paramètre ci-dessus, il a fallu en moyenne 745 secondes pour terminer un cycle global de formation. De plus, il a fallu en moyenne 2,32 secondes pour générer les résultats de prédiction et XAI.

6.4.2 Analyse des performances de la méthode proposée

Dans cette sous-section, nous analysons les performances du cadre proposé en utilisant des métriques de pointe.




FIGURE 6.8 – La distribution de l'ensemble de données suréchantillonné (rééquilibré) [7]

6.4.2.1 Reconstruction de l'Autoencodeur

Nous avons introduit du bruit dans l'ensemble de données et utilisé l'échantillon bruyant comme entrée dans l'encodeur automatique et les échantillons nettoyés comme étiquettes. Les performances de l'autoencodeur ont été mesurées à l'aide de l'erreur absolue moyenne de reconstruction (en anglais Mean Absolute Error, MAE). Reconstruction MAE pour chaque AE formé localement dans chacun de $Edge_1$, $Edge_2$, $Edge_3$ et AE agrégé est donné dans la Figure 6.10. On peut voir que la reconstruction MAE de l'autoencodeur agrégé est proche de 0, ce qui signifie que notre autoencodeur a très bien reconstruit le signal d'origine. De plus, on peut voir que l'agrégation de la MAE de reconstruction AE est inférieure ou presque égale à la MAE de reconstruction de chaque AE formé localement.

6.4.2.2 Performance de classification

Les performances de classification ont été mesurées à l'aide des quatre métriques standard trouvées dans la littérature [324] : l'exactitude de la classification, la précision, le rappel et le score F1. Précision, rappel, métriques du score F1 de chaque classificateur binaire (un pour chacune des cinq étiquettes de classe) sur les trois appareils périphériques ($Edge_1$, $Edge_2$ et $Edge_3$) et le serveur global sont donnés dans la Figure 6.11. Nous




FIGURE 6.9 – Comparaison de la version originale et de la version bruitée du jeu de données [7]

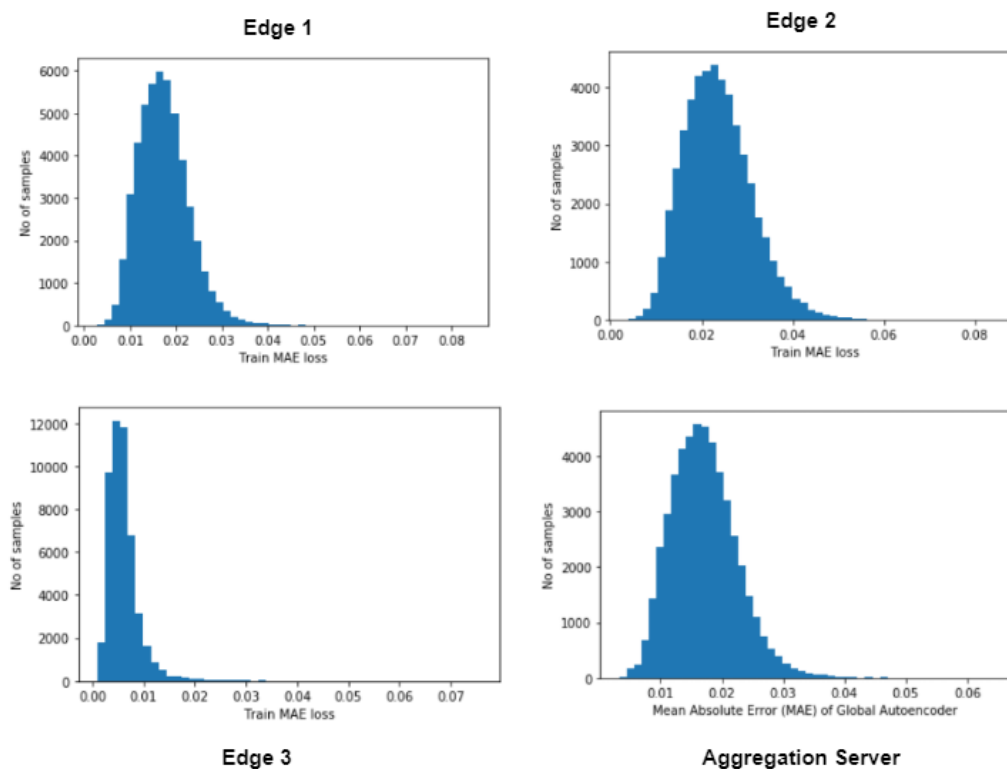


FIGURE 6.10 – Reconstruction MAE [7]

montrons également la précision du classificateur à cinq classes dans la dernière colonne. Il convient de noter que les résultats présentés dans le Tableau 6.11 sont calculés à l'aide

des données bruitées que nous avons préparées précédemment. Nous avons également testé le classificateur proposé en utilisant les données originales (propres). Avec ces données, il a fourni une précision de $98 \pm 0.9\%$. D'autres mesures, telles que la précision, le rappel et le score F1, sont présentées dans la Figure 6.2. Cependant, pour une utilisation en temps réel, nous nous attendons à ce que les données soient bruitées, c'est pourquoi nous avons procédé avec les données bruitées.

TABLEAU 6.2 – La performance de classification du cadre proposé, avec l'ensemble de données d'origine (propre)

Classe	Precision	Recall	F1-Score	Accuracy
N	95%	99%	97%	98.9%
S	98%	97%	98%	
V	97%	99%	98%	
F	99%	93%	96%	
Q	100%	100%	100%	

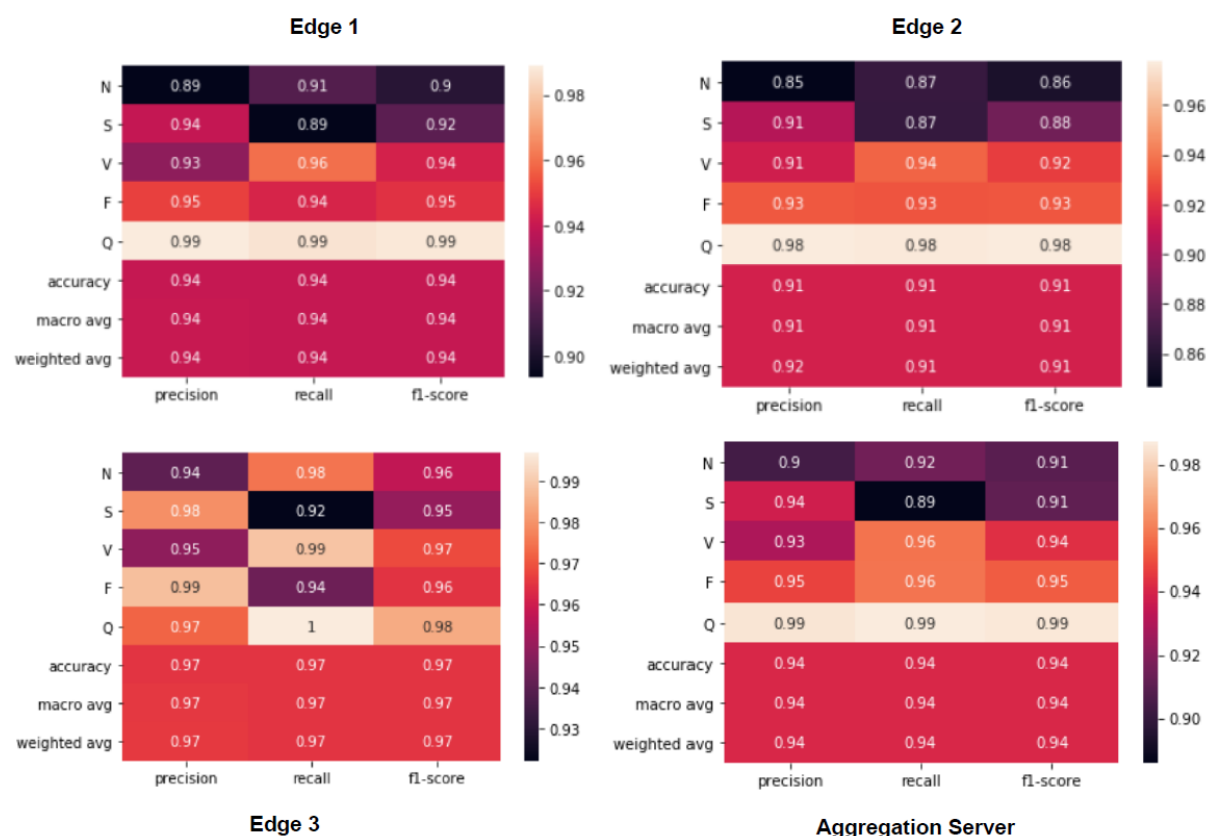


FIGURE 6.11 – Les performances de classification du cadre proposé, avec la version bruitée du jeu de données [7]

6.4.2.3 Analyse Qualitative

Comprendre les raisons des prédictions de la décision du modèle est très important dans les applications de soins de santé. Afin de valider que les décisions prises par le module XAI proposé sont interprétables, nous utilisons la visualisation pour démontrer que les battements cliniquement importants dans l'onde ECG sont utilisés pour la classification. La Figure 6.13 illustre l'importance de chaque battement que le classificateur ECG donne lors de la classification de certaines entrées de signal ECG.

Afin d'obtenir l'interprétabilité/explicabilité du module XAI, il est important de comprendre le signal ECG [325]. En règle générale, l'amplitude et la largeur de l'onde p, du complexe QRS et de l'onde T sont des caractéristiques importantes d'un graphique ECG, comme le montre la Figure 6.12. Ces régions jouent un rôle essentiel dans l'analyse ECG [326]. Le module XAI dans le cadre proposé montre que le classificateur proposé examine ces caractéristiques critiques de l'échantillon d'entrée. Dans la Figure 6.13, les segments rouges montrent les régions les plus importantes du rythme cardiaque pour la décision du réseau tout en prédisant une classe particulière. En d'autres termes, les segments rouges du rythme cardiaque ont plus d'influence sur le processus de détection du classificateur lors de la classification du signal ECG d'entrée. Ces résultats peuvent être utilisés pour aider les cliniciens à diagnostiquer les problèmes de santé sous-jacents. Cependant, nous vous déconseillons fortement d'utiliser ces résultats pour une consultation médicale sans discussion préalable avec un professionnel de la santé. En d'autres termes, les cartes thermiques doivent être contre-vérifiées par des cliniciens ayant des connaissances spécialisées préalables.

6.4.2.4 Comparaison avec d'autres méthodes de pointe

Nous avons comparé notre cadre proposé avec les méthodes de pointe rapportées en 2020 [281, 282, 283, 284, 285, 327, 328, 276, 329]. Tout d'abord, nous comparons les travaux précédents avec les nôtres pour montrer que le cadre proposé fournit toutes les propriétés souhaitables telles que l'interprétabilité, la préservation de la confidentialité et le travail avec des données brutes. Le Tableau 6.3 montre la comparaison entre notre méthode proposée et les autres méthodes. On peut voir que le schéma proposé surpasse les autres en fournissant toutes les propriétés souhaitables, tandis que d'autres manquent de certaines des propriétés souhaitables. De plus, nous comparons également nos travaux avec des travaux existants pour la classification ECG. Il convient de noter que d'autres méthodes ont utilisé l'ensemble de données de base MITBIH (sans bruit), avec lesquelles de meilleurs résultats de précision peuvent être obtenus. En revanche, nous avons introduit du bruit (10%-30%) dans les données pour les rendre plus réalistes. Le Tableau 6.4 montre la comparaison des performances de classification entre notre méthode proposée et les autres méthodes. On peut voir que notre méthode proposée a surpassé les méthodes des autres. Il convient de noter que le classificateur proposé traite les tâches de classification de cinq classes, tandis que d'autres traitent de moins de classes (certaines avec deux et d'autres avec trois). De plus, la méthode proposée fonctionne dans une architecture fédérée et est plus performante que les autres. Notre méthode proposée fournit l'explicabilité en tant que caractéristique supplémentaire. De plus, la méthode proposée assure la confidentialité des données aux utilisateurs via le paramètre fédéré, ce




FIGURE 6.12 – Les principales ondes d’un seul tracé ECG normal [7]

qui n’est pas le cas des autres méthodes. De plus, la méthode proposée peut débruiter les signaux bruts sans aucun prétraitement, suivi d’une classification et d’une explicabilité.

TABLEAU 6.3 – Comparaison avec les travaux de pointe [7]

Schéma	interprétabilité	entrée brute	préservation de la confidentialité
[278]	X	X	X
[279]	X	X	X
[330]	X	X	X
[281]	X	X	✓
[282]	X	X	X
[283]	X	X	X
[284]	X	X	X
[285]	X	X	X
[327]	X	X	X
[328]	X	X	X
[276]	✓	X	X
[329]	X	X	X
Proposed	✓	✓	✓

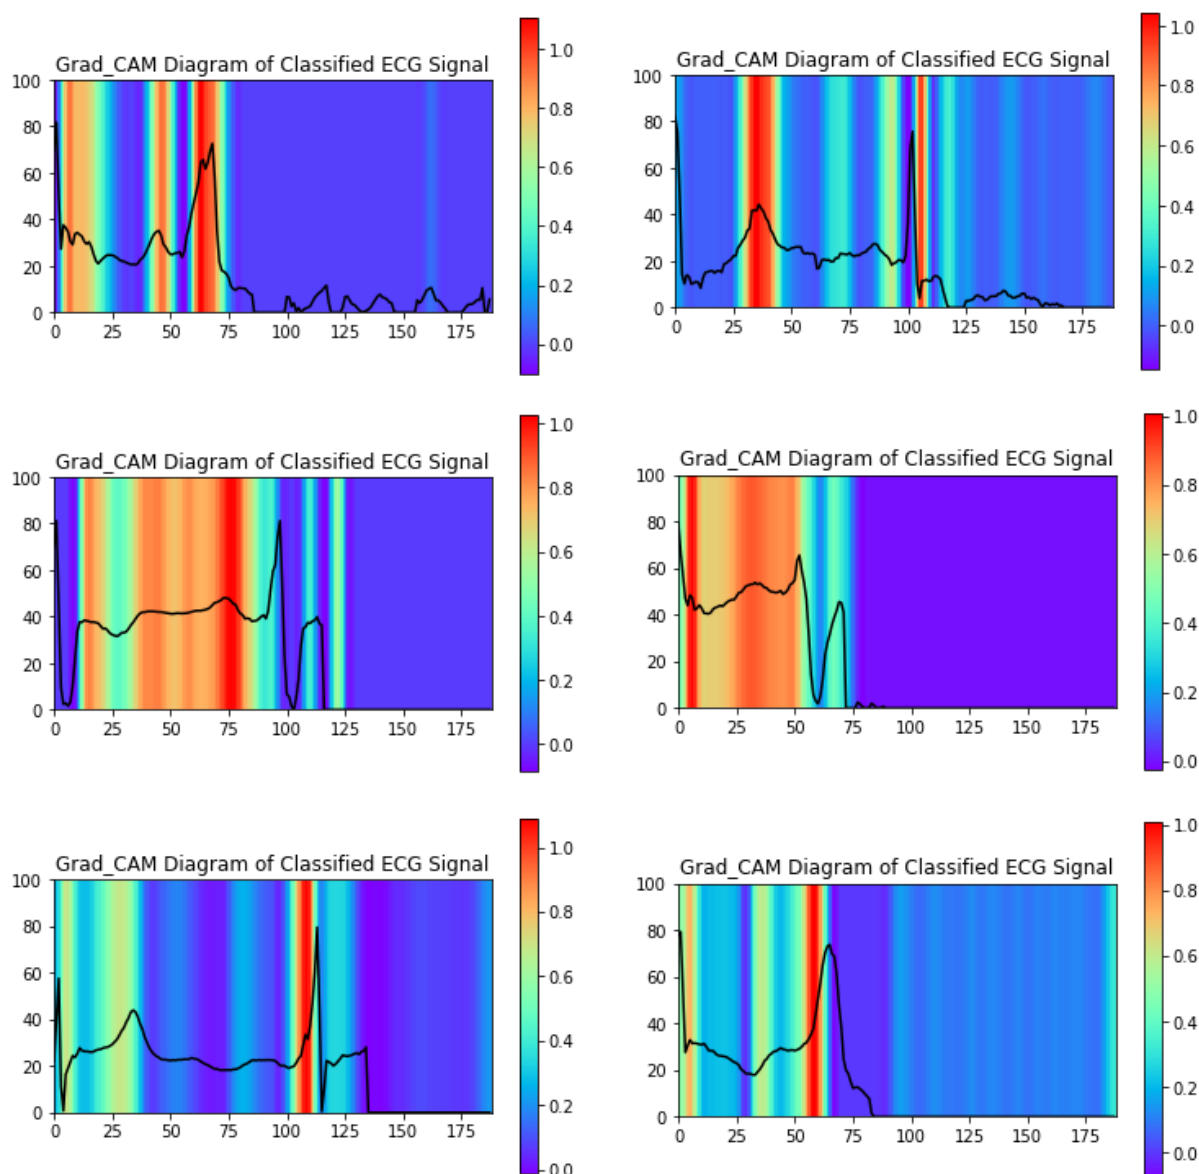


FIGURE 6.13 – Les sorties du module XAI

6.4.2.5 Amélioration de la confidentialité

Comme mentionné précédemment, les données de santé numériques sont comme des empreintes digitales numériques qui contiennent de nombreuses informations personnelles. Par conséquent, nous devons protéger autant que possible ces données tout en les utilisant dans des algorithmes d'apprentissage automatique. La plupart des études antérieures sur la classification ECG n'assurent pas la protection de la confidentialité de ces données car elles sont centralisées et les données sont partagées directement avec le modèle central. Récemment, Chen et al. [281] ont utilisé l'apprentissage fédéré pour assurer la protection de la vie privée, en partageant uniquement les paramètres appris sans partager les données. Bien que les paramètres partagés puissent protéger la confidentialité, il existe encore des chances de récupérer certaines informations à partir des paramètres partagés des couches de niveau supérieur dans le classificateur, car ils peuvent contenir

des informations plus spécifiques aux données, comme indiqué précédemment. À titre de comparaison, dans notre cadre proposé, nous ne partageons que les paramètres appris des couches de niveau inférieur qui ne comportent que des fonctionnalités plus courantes et de bas niveau (c'est-à-dire moins sensibles à la confidentialité). Ainsi, notre cadre proposé peut encore améliorer la confidentialité et en même temps réduire les coûts de communication car moins de paramètres sont partagés entre les serveurs périphériques/locaux et mondiaux. Une comparaison avec le travail existant dans un cadre fédéré pour les soins de santé est présentée dans le Tableau 6.5.

TABLEAU 6.4 – Comparaison avec les études précédentes pour la classification ECG [7]

Schéma	Centralisé ou Fédéré	Acc (données propres)	Acc (données bruitées)
[278]	Centralized	86.0%	-
[279]	Centralized	96.9%	-
[282]	Centralized	98.1%	-
[283]	Centralized	96.5%	-
[285]	Centralized	93.1%	-
[284]	Centralized	98.7%	-
[327]	Centralized	94.9%	-
[328]	Centralized	98.1%	-
[331]	Centralized	98.6%	-
[330]	Centralized	98.3%	-
[276]	Centralized	98.8%	-
Proposed	Federated	98.9%	94.5%

6.4.2.6 Réduction des coûts de communication

Ici, nous montrons la réduction des coûts de communication en utilisant la méthode de réduction des coûts de communication proposée. Le nombre total de paramètres communiqués entre un périphérique et le serveur global, pour un tour global, noté TPC, est donné comme suit :

$$\text{TPC} = W1 + W2 + WC1 + WC2 + AW1 + AW2 + AWC1 + AWC2, \quad (6.10)$$

Dans le cadre proposé, le TPC est donné comme suit :

$$\text{TPC} = 13386 + 13429 + 4160 + 181961 + 13386 + 13429 + 4160 + 181961 = 425872, \quad (6.11)$$

Avec la méthode de réduction des coûts de communication proposée, le TPC est donné comme suit :

$$\text{TPC} = W1 + WC1 + AW1 + AWC1, \quad (6.12)$$

Dans le cadre proposé, le TPC est donné comme suit :

$$\text{TPC} = 13386 + 4160 + 13386 + 4160 = 35092, \quad (6.13)$$

À partir des équations. (6.11) et (6.13), nous pouvons calculer que la méthode de réduction des coûts de communication proposée réduit les coûts de communication de 8,2% .

TABLEAU 6.5 – Comparaison avec les travaux de pointe en apprentissage fédéré pour la santé

Scheme	Réduction des coûts de communication	Amélioration de la confidentialité
[281]	✗	✗
Proposé	✓	✓

6.4.2.7 Complexité temporelle de l'algorithme proposé

Dans cette section, nous fournissons la complexité temporelle de l'algorithme proposé. Dans un réseau basé sur CNN, le nombre d'entités dans chaque carte d'entités est au plus une constante multipliée par le nombre d'entités en entrée, disons n (généralement la constante est < 1). La convolution d'un filtre de taille fixe sur un signal d'entrée avec n caractéristiques prend $O(n)$ temps, puisque chaque sortie n'est que le produit de la somme entre certaines caractéristiques, disons k dans l'entrée, et un nombre fixe de poids w dans le filtre, et w et k ne varient pas avec n . De même, toute opération de mise en pool maximale ou moyenne ne prend pas plus d'un temps linéaire dans la taille d'entrée. De plus, le nœud périphérique peut calculer en parallèle, par conséquent, le temps d'exécution global est toujours linéaire, c'est-à-dire $O(n)$.

6.5 Conclusions

Dans ce chapitre, nous avons proposé un cadre de bout en bout basé sur l'IA préservant la confidentialité, efficace et interprétable/explicable pour répondre aux limites des applications d'apprentissage en profondeur pour la classification des signaux EEG. Premièrement, nous avons proposé un autoencodeur basé sur CNN dans une architecture fédérée pour débruiter le signal ECG brut des patients. Lorsqu'il est entraîné sur l'ensemble de données de base, l'encodeur automatique proposé a fourni une excellente reconstruction des signaux d'entrée bruts et a amélioré les performances globales lorsqu'il est appliqué dans des paramètres fédérés. Deuxièmement, nous avons proposé un nouveau classificateur pour les signaux ECG. Lorsque le classificateur a été formé dans des paramètres fédérés, il a pu améliorer les performances de classification globales des périphériques de périphérie. De plus, les résultats expérimentaux sur la base de données de référence ont révélé que le cadre proposé surpassait les algorithmes existants, y compris les algorithmes centralisés et fédérés. De plus, nous avons étendu la convivialité de notre cadre en fournissant un nouveau module explicable au-dessus du classificateur, dont l'utilité est visuellement démontrée en montrant que des segments de rythme cardiaque cliniquement significatifs des signaux ECG sont en effet à l'origine

des résultats de la classification. De plus, nous avons également proposé une méthode de réduction des coûts de communication, qui peut réduire considérablement les coûts de communication tout en augmentant le niveau de protection de la confidentialité des données ECG des utilisateurs par rapport au serveur global. Par conséquent, le cadre proposé montre son applicabilité en fournissant de nombreuses propriétés souhaitables, notamment l'interprétabilité, la protection de la vie privée, la réduction des coûts de communication et une haute précision dans la classification. Une telle combinaison de telles propriétés ne s'applique pas aux autres solutions existantes, faisant ainsi du cadre proposé une solution unique pour les applications de soins de santé du monde réel où la classification des signaux ECG est une tâche importante.

À terme, le cadre proposé encouragera (1) davantage de propriétaires de données de santé à participer à la formation d'un bon modèle d'apprentissage automatique pour les patients et les professionnels de la santé, avec moins de problèmes de confidentialité, (2) une assistance diagnostique plus précise dans les endroits où l'accès aux cardiologues ou aux soins de santé est limité. installations, (3) des résultats de classification plus interprétables qui peuvent être utilisés pour identifier de nouveaux modèles potentiels conduisant à déclencher des arythmies cardiaques. Par conséquent, le cadre proposé a un grand potentiel pour être ajouté aux plates-formes logicielles informatiques des hôpitaux pour soutenir le travail des professionnels de la santé et, en fin de compte, réduire la mortalité et sauver des vies humaines. Ce chapitre est écrit sur les travaux de 2 post-doctorants (M. Huu Du Nguyen [332], M. Quoc Thong Nguyen [333]) et la thèse en cours de M. Ali Raza ([7]). M. Ali Raza continuera à travailler sur cette direction de recherche et continuera à publier les résultats dans un proche avenir.

Chapitre 7 :

Conclusion générale et Perspectives des thèmes de recherche

7.1 Conclusion générale

Dans l'économie mondialement concurrentielle d'aujourd'hui, prendre de bonnes décisions est un facteur clé du succès de toute entreprise; une bonne décision est susceptible de générer de la valeur pour l'entreprise. Le développement récent des technologies de l'information et de la communication telles que les réseaux de capteurs intelligents, l'Internet des objets (IoT) et l'intelligence artificielle (AI ou en anglais Artificial intelligence, IA) pour favoriser l'amélioration continue, le transfert de connaissances et la prise de décision basée sur les données dans de nombreux domaines. La problématique de l'aide à la décision dans le contexte de l'Industrie 4.0 est une préoccupation majeure dans un grand nombre d'études. Parmi les facteurs qui conduisent à des approches décisionnelles appropriées, la surveillance, la détection d'anomalies et l'optimisation avec des techniques statistiques et d'apprentissage automatique sont des tâches très importantes. Une énorme quantité de données générées à chaque étape des processus industriels entraîne une surcharge de données et la difficulté de discerner les signaux utiles. Les cartes de contrôle et l'apprentissage automatique permettent des décisions significatives à partir de ces données pour optimiser les industries des systèmes.

Cette thèse a systématiquement présenté nos contributions en surveillance, détection d'anomalies et optimisation pour les systèmes industriels avec des techniques statistiques et d'apprentissage automatique. Les études ont été effectuées principalement par des doctorants, post-doctorants et étudiants en master sous ma direction en collaboration avec d'autres collègues. Tout d'abord, nous avons présenté nos contributions dans le domaine de la surveillance statistique des processus, en particulier les cartes de contrôle avancées développées sur la base de techniques statistiques ainsi que l'apprentissage automatique pour la détection d'anomalies dans la fabrication. Deuxièmement, des contributions dans le domaine de la modélisation et de l'optimisation de la production en utilisant l'apprentissage par renforcement avec une étude de cas dans la fabrication de textiles ont été introduites pour montrer des résultats très prometteurs pour l'application de l'apprentissage par renforcement dans l'optimisation du processus de fabrication. Troisièmement, les contributions de la prévision et de la détection d'anomalies à l'aide de techniques d'apprentissage automatique avec des applications dans le domaine de la gestion de la chaîne d'approvisionnement ont été examinées avec des données de l'industrie de la mode. Les algorithmes proposés dans cette étude peuvent également être appliqués à d'autres domaines ainsi qu'ouvrir de nouvelles directions de recherche dans ce domaine. Quatrièmement, la recherche sur la sécurité des réseaux avec des techniques de détection d'anomalies a été introduite avec des applications dans les domaines de la finance, des réseaux de capteurs sans fil, ainsi que des systèmes de contrôle industriels. Enfin, un système de surveillance des signaux ECG avec des applications dans les systèmes de santé intelligents utilisant des techniques d'apprentissage fédéré explicables a été introduit. Mes thèmes de recherche sont brièvement présentés dans la Figure 7.1

Cependant, il reste encore de nombreuses difficultés et défis à surmonter afin de développer de nouvelles approches pour la surveillance, la détection d'anomalies et l'optimisation des systèmes industriels avec des techniques statistiques et d'apprentissage automatique telles que l'amélioration des performances, la réduction des fausses alarmes, intégrer des modèles de détection explicables, réduire la latence dans les contextes industriels, réduire les problèmes de sécurité des données et de confidentialité.

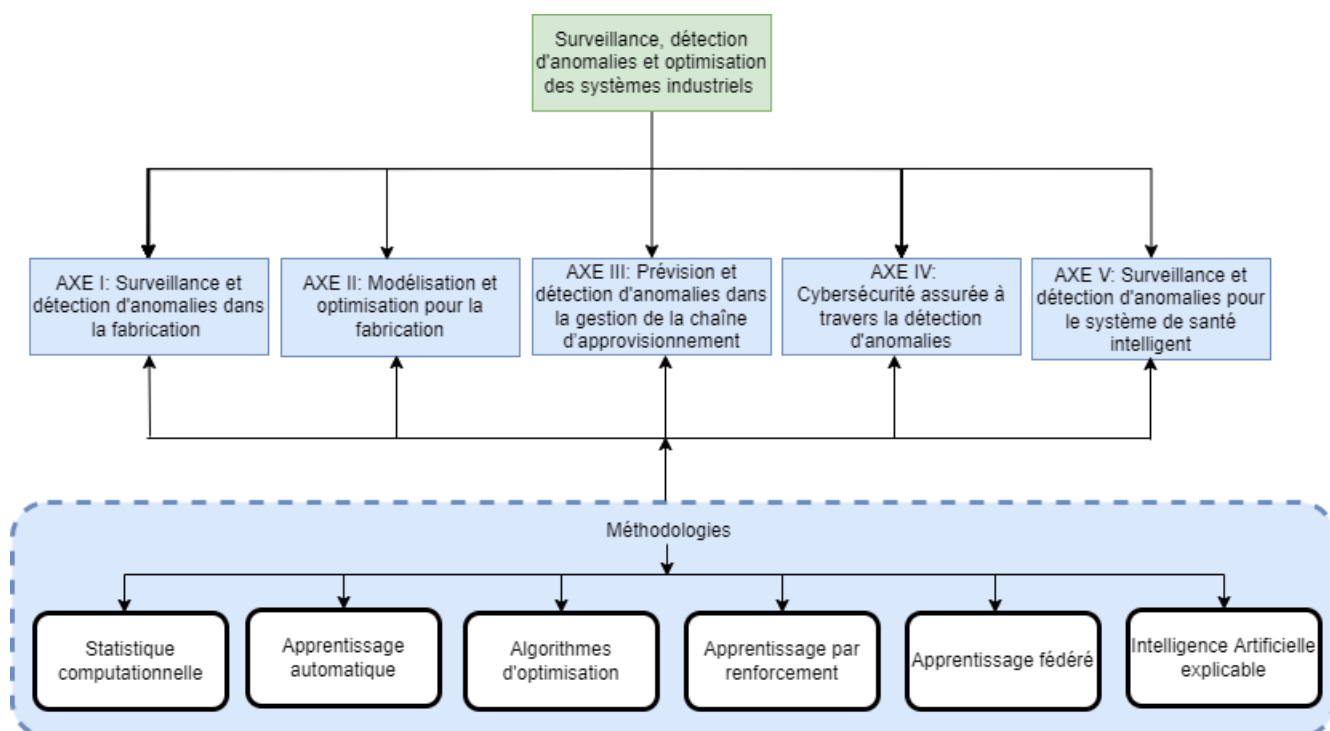


FIGURE 7.1 – Thèmes de recherche

7.2 Perspectives des thèmes de recherche

Les travaux de recherche décrits dans les chapitres 2,3,4,5,6 ont contribué à répondre avec succès à un certain nombre de problématiques de la surveillance, la détection d’anomalies et l’optimisation des systèmes industriels avec des techniques statistiques et d’apprentissage automatique. Sur un horizon à court terme, les différentes thèses en cours (5 à ce jour), vont approfondir et améliorer les résultats obtenus. A plus long terme, l’ensemble des travaux effectués constitue un socle solide pour le développement de différents techniques de la surveillance, la détection d’anomalies et l’optimisation des systèmes industriels. Les pistes envisagées sont détaillées dans ce chapitre pour chacun des cinq thèmes de recherche. Mes perspectives des thèmes de recherche sont brièvement présentés dans la Figure 7.2.

Dans une direction de recherche théorique future qui peut s’intégrer dans 5 thèmes de recherche qui seront détaillés tour à tour dans ce chapitre. Basé sur certaines techniques telles que la matrice quantique, l’estimation de phase quantique et l’amplification d’amplitude, l’informatique quantique est utilisée pour développer des algorithmes quantiques pour l’apprentissage automatique. Étant donné que les données quantiques (sous forme d’état quantique) sont courantes dans tous les domaines du calcul quantique, de la communication quantique et de la simulation quantique, la détection d’états quantiques anormaux est cruciale dans le traitement et la communication de l’information quantique, en particulier via le cloud ou l’Internet quantique. Le calcul quantique sera basé sur des processeurs quantiques bruyants et les techniques IA fonctionnent très bien sur des données à bruit élevé. Cette combinaison est donc parfaite, favorisant ainsi le développement de techniques d’apprentissage automatique quantique performantes avec

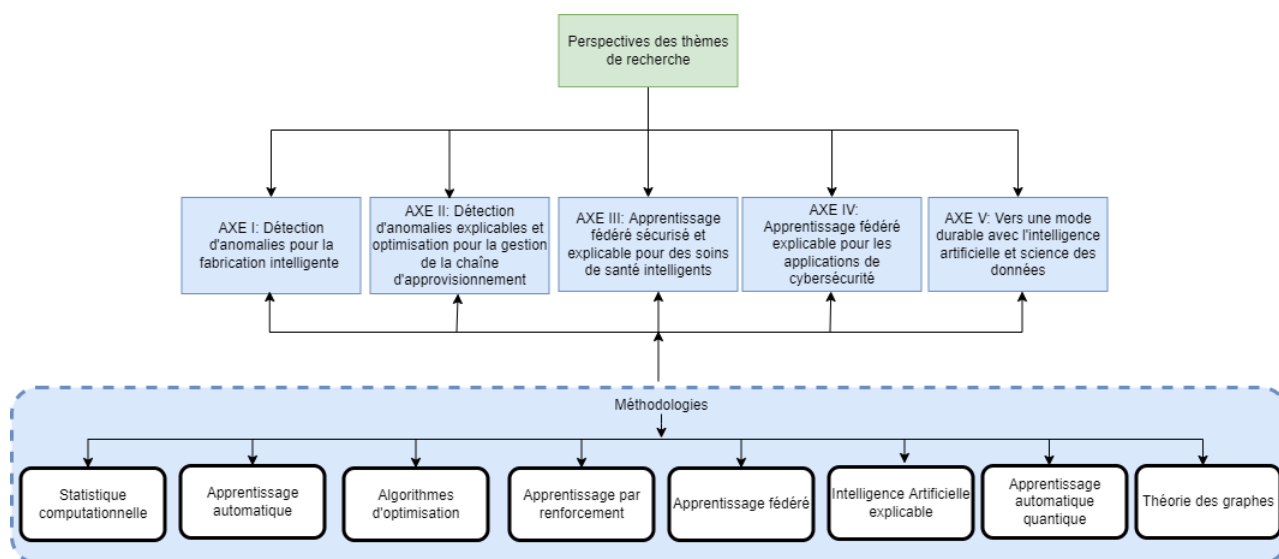


FIGURE 7.2 – Perspectives des thèmes de recherche

les modèles graphiques probabilistes, les réseaux Bayésiens et les champs aléatoires de Markov. Comme sujet de recherche potentiel, la détection d’anomalies quantiques utilisant l’apprentissage automatique quantique [334] est récemment devenue un sujet brûlant avec l’avènement de l’informatique quantique. Nous poursuivrons cette direction de recherche en étendant nos résultats à l’apprentissage automatique quantique. De plus, les problèmes inverses sont également un sujet de recherche intéressant et ont de nombreuses applications dans de nombreux domaines différents. Par exemple, l’apprentissage par renforcement inverse (IRL) est le problème d’inférer la fonction de récompense d’un agent, compte tenu de sa politique ou du comportement observé. Nous prévoyons également de développer apprentissage par renforcement inverses quantique pour apprendre auprès d’experts dans les domaines de l’optimisation des processus de fabrication, de l’optimisation de la chaîne d’approvisionnement ou de la santé.

7.2.1 Détection d’anomalies explicables pour la fabrication intelligente

De nombreuses méthodes de détection d’anomalies basées sur l’IA ont été proposées et ont atteint des performances de détection élevées avec de nombreuses applications, cependant, elles restent une "boîte noire" difficile à interpréter. Un exemple typique est que les anomalies peuvent provenir de dysfonctionnements des capteurs (vibrations, température, ...), où des lectures anormales des capteurs peuvent être le signe de pannes imminentes. Par conséquent, lorsque des anomalies surviennent, l’analyse de la prise de décision du modèle de détection d’anomalies prend du temps. Par conséquent, le développement de techniques de détection d’anomalies explicables sont des études essentielles pour promouvoir l’application des techniques de détection d’anomalies dans divers domaines tels que la gestion de la chaîne d’approvisionnement et la fabrication. Enfin, nous pouvons proposer l’utilisation de méthodes d’interprétation indépendantes du modèle avec les modules innovants, modulaires, d’attention variable et d’attention temporelle pour expliquer la contribution de chaque variable.

Il est évident que les entreprises et les sociétés deviennent rapidement plus intelligentes en ajoutant de l'intelligence à leur processus pour favoriser l'amélioration continue, le transfert de connaissances et des procédures de prise de décision intelligentes. Cela augmente la demande d'outils avancés d'IA et de SPM (en anglais Statistical Process Monitoring), ainsi que des techniques intégrées efficaces à diverses étapes de production pour réduire les coûts de production, améliorer la productivité globale, améliorer la qualité des produits et des processus, réduire les temps d'arrêt, etc. Rendre les processus intelligents et numérisés, motiver les chercheurs et des scientifiques pour développer des stratégies de apprentissage automatique efficaces pour la détection d'anomalies dans les opérations quotidiennes. Cette direction de recherche est fondée sur deux thèses de doctorat par Mme Van Nguyen Thi Thuy et M. Mousab Orabi. Les sujets suivants sont recommandés ici pour de futures recherches.

7.2.1.1 Surveillance et détection d'anomalies pour les processus auto-corrélés et les processus non stationnaires avec optimisation des hyperparamètres

Grâce à l'évolution rapide des technologies des capteurs et à la vitesse des données disponibles dans les processus industriels modernes, les observations sont auto-corrélées, mais elles ont également des comportements non stationnaires dans lesquels elles n'oscillent pas autour d'une moyenne commune ou sa variance et son autocovariance sont changeant avec le temps. Jusqu'à présent, la plupart des recherches existantes se sont concentrées sur le développement de cartes de contrôle basées sur apprentissage automatique et de techniques de reconnaissance de modèles de cartes de contrôle (en anglais Control Chart Pattern Recognition, CCPR) pour surveiller les processus stationnaires et il existe un besoin remarquable de développer de tels outils pour gérer les données de séries chronologiques provenant de processus non stationnaires. Cette lacune devrait être comblée par de nouvelles recherches. Récemment, Tran et al. [50] et Nguyen et al. [4] ont proposé des réseaux de mémoire à long terme (LSTM) et des techniques d'autoencodeur LSTM pour surveiller les données de séries chronologiques multivariées à partir de processus non stationnaires. Ces techniques peuvent également être utilisées comme solutions efficaces pour les problèmes de CCPR impliquant des données non stationnaires auto-corrélées pour une étude future.

Il est important de noter que les hyperparamètres sont ceux qui conduisent à la plus grande précision et/ou au moins d'erreurs dans l'ensemble de validation et fournissent les meilleurs résultats pour le problème qu'ils résolvent. Il est important de noter que l'hyperparamètre est différent du paramètre du modèle. Les hyperparamètres sont les arguments du modèle qui doivent être déterminés avant le début du processus d'apprentissage et ils ne sont pas appris à partir des données d'apprentissage comme les paramètres du modèle. Bien que ces hyperparamètres jouent un rôle crucial dans l'utilisation des algorithmes apprentissage automatique, l'efficacité de l'algorithme dépend en grande partie de la sélection de bonnes valeurs d'hyperparamètres, étonnamment, la plupart des études appliquant apprentissage automatique dans SPM n'ont pas pris en compte l'optimisation des hyperparamètres dans leurs études. [335] a étudié l'application de SVM (en anglais Support Vector Machine) à une classe pour détecter les anomalies

dans les réseaux de capteurs sans fil avec une optimisation des hyperparamètres basée sur les données. De plus, Wu et al. [336] ont proposés une technique efficace pour le réglage des hyperparamètres à l'aide de l'apprentissage par renforcement. Sur la base des discussions mentionnées ci-dessus, il existe un écart important entre les théories et les hypothèses de la littérature et les demandes réelles dans les environnements industriels qui devraient être réduits grâce à de futures recherches. En conséquence, il est recommandé aux scientifiques de fournir des directives illustratives à des praticiens probablement non spécialistes afin de leur montrer clairement comment mettre en œuvre la méthode dans leurs problèmes. De plus, il est également important de préparer le code source des conceptions de test en utilisant apprentissage automatique car la plupart d'entre elles n'ont pas d'expression explicite des limites de contrôle et de l'ARL. Cela faciliterait l'implantation des méthodes proposées pour les praticiens.

7.2.1.2 Carte de contrôle pour les types de données complexes

Les données dans les usines intelligentes sont aujourd'hui collectées avec une fréquence élevée, une dimension élevée, une structure complexe et une grande variété qui ne peuvent pas être traitées directement. Ces nouvelles circonstances créent le concept de données complexes. Les données fonctionnelles, les données de composition et les données topologiques sont des types importants de données complexes. Pour traiter de telles données, de nouvelles méthodes d'analyse de données se sont développées ou les techniques existantes ont été affinées par certains chercheurs. Par exemple, l'analyse topologique des données (en anglais Topological Data Analysis, TDA) a proposé d'analyser les données topologiques qui apparaissent comme un outil puissant pour extraire des informations à partir de données de grande dimension. L'idée centrale de la TDA est de trouver la forme, la structure sous-jacente des formes ou les caractéristiques pertinentes de faible dimension d'une structure complexe et de données massives. Dans [337], l'application de TDA est utilisée pour décrire la série chronologique DL pour l'analyse des données de séries chronologiques et la détection d'anomalies. En particulier, deux technologies clés - Mapper et l'homologie persistante sont appliquées à la fois à l'apprentissage supervisé et à l'apprentissage non supervisé. Mapper présente les caractéristiques distinctives d'un ensemble de données sous la forme d'un graphique facile à comprendre. L'homologie persistante est une technologie qui capture numériquement une forme de données en détail. Cet article a développé une technologie de détection d'anomalies pour les séries chronologiques afin de détecter un état anormal à l'aide de la TDA. De plus, les données sont de plus en plus liées à des données fonctionnelles. Les études sur le suivi des données fonctionnelles ont beaucoup retenu l'attention [338], [339] et [340]. Des méthodes de détection d'anomalies pour les données fonctionnelles basées sur l'ACP (en anglais pour principal component analysis, PCA) fonctionnelle [341], l'ACP fonctionnelle par ondelettes [339] sont développées. Cependant, l'application du apprentissage automatique avancé sur ce type de données pour le développement, la reconnaissance de formes et l'interprétation de cartes de contrôle doit encore être découverte. Ainsi, plus d'efforts sont nécessaires pour développer des tests qui utilisent apprentissage automatique pour suivre ces types de données, besoin de trouver plus de documentation sur les méthodes apprentissage automatique qui leur conviennent afin de les écrire correctement. Par exemple, bien que ces études aient éliminé de nombreuses hypothèses sur la distribution des données lors de la conception de cartes de contrôle

avec des techniques apprentissage automatique, il existe toujours des hypothèses de données indépendantes qui n'existent pas dans l'environnement de données collectées à partir des capteurs IoT. De manière générale, il existe encore très peu d'études sur cette approche prometteuse et des recherches supplémentaires doivent être menées pour découvrir ses nombreuses applications à l'usine intelligente. En conséquence, le développement de techniques apprentissage automatique avancées pour éliminer la plupart des hypothèses de la SPM traditionnelle dans le développement, la reconnaissance de formes et l'interprétation de cartes de contrôle pour surveiller des types de données complexes tels que les données de séries chronologiques multivariées, les données d'image et les Big Data avec des structures complexes est un objectif élevé. -zone potentielle pour effectuer plus de recherches. Ce sera une direction de recherche prometteuse pour résoudre le problème de la mise en œuvre du SPM en usine intelligente avec le Big Data. Bien que [342] révèle de nombreuses pistes pour le suivi de CoDa telles que l'extension de la carte MEWMA (en anglais Multivariate Exponentially Weighted Moving Average) pour le CoDa à la carte MCUSUM (Multivariate Cumulative Sum en anglais) pour le CoDa et l'étude des effets des paramètres estimés associés, il reste encore beaucoup de problèmes qui devraient être approfondi pour surveiller efficacement CoDa. D'un côté, la structure p -variante de CoDa suggère en effet d'introduire une technique de détection d'anomalies/machine learning qui n'agrège pas ces variables, par exemple à partir de SVDD (en anglais Support Vector Data Description); d'autre part, plusieurs variables de composition (cas multivarié) doivent également être étudiées ensemble.

Enfin, bien que les applications des systèmes de vision industrielle dans les ateliers industriels et médicaux aient considérablement augmenté et qu'un grand nombre d'applications possibles existent ici, seuls quelques articles traitent de la surveillance d'images. Megahed et al. [343] ont examinés des cartes de contrôle basées sur des images, y compris des cartes d'analyse d'images univariées, multivariées, de profil, spatiales, multivariées et des dispositifs d'imagerie médicale, et a abordé la capacité de surveillance basée sur des images dans une plus grande variété de caractéristiques de qualité. Ils ont noté que l'utilisation de cartes de contrôle basées sur des images diffère des applications traditionnelles des cartes de contrôle dans la zone SPM. Ces différences peuvent être attribuées à un certain nombre de facteurs, notamment le type de données surveillées, la justification de l'utilisation des cartes de contrôle et la manière dont les cartes de contrôle sont appliquées. De plus, le prétraitement des données d'image peut également devenir un facteur avec une inspection à 100% puisque le temps de prétraitement des données peut être plus long que le temps de cycle de production. Par conséquent, ces facteurs doivent être pris en compte lors de l'élaboration de la stratégie de carte de contrôle. [344] a proposé une carte de contrôle multivariée pour les failles simples et multiples. Dans leur méthode, chaque image est divisée en régions non chevauchantes de taille égale, et les intensités moyennes de ces régions sont surveillées avec une statistique multivariée basée sur la GLR (rapport de vraisemblance généralisé ou en anglais generalized likelihood ratio). [345] a signalé que la recherche existante dans le domaine de le SPM basée sur l'image s'est concentrée sur l'identification de la taille et/ou de l'emplacement des défauts ou sur la détection de l'occurrence des défauts et que les recherches sur la détection et l'identification des défauts sont limitées. Pour gérer de telles situations, ils ont proposé une carte de contrôle basée sur l'EWMA (en anglais Exponentially Weighted Moving Average) et la croissance régionale pour la surveillance d'images en niveaux de gris 8 bits

de produits industriels. Les résultats de l'étude de simulation ont montré que la nouvelle méthode est non seulement efficace pour la détection rapide du défaut, mais également précise pour estimer la taille et l'emplacement du défaut. Récemment, [346] a fourni un aperçu des développements récents sur la surveillance des processus d'image. Bien que nous examinons une partie de la littérature existante dans ce domaine, il existe encore des opportunités de recherche dans l'intégration de méthodes de cartographie de contrôle basées sur apprentissage automatique et de modèles de reconnaissance de formes avec des données d'image. Il est connu qu'avec la fabrication intelligente, la quantité d'images collectées à partir des lignes de production est très importante et chaque image peut inclure des millions de pixels qui nécessitent des approches apprentissage automatique pour développer de nouvelles cartes de contrôle et des cadres CCPR. De nombreux auteurs supposent un processus résiduel indépendant, alors qu'il existe une structure de corrélation spatiale naturelle des pixels dans les voisinages. Par conséquent, il existe un besoin conséquent de certaines approches basées sur le apprentissage automatique pour la surveillance réussie des processus d'image. Les méthodes existantes, par exemple, [347] et [348], peuvent être améliorées pour développer des cartes de contrôle CNN (en anglais convolutional neural network) [349] pour surveiller les images dans la fabrication intelligente.

7.2.1.3 Détection d'anomalies explicables basée sur l'intelligence artificielle pour le journal des événements dans l'exploration de processus en ligne

Les techniques d'exploration de processus (Process Mining en anglais) permettent différents types d'analyses basées sur ce que l'on appelle des journaux d'événements. Par exemple, en utilisant le process mining, on peut reconstruire un modèle de processus à partir d'un journal généré par un système d'information. La détection d'anomalies dans les journaux d'événements basée sur l'intelligence artificielle est récemment apparue comme un nouveau domaine dans le développement de techniques d'exploration de processus pour identifier les anomalies dans les journaux d'événements sans supposer l'existence d'un modèle de processus [350], [351]. Pour être évaluées, les techniques de détection d'anomalies dans les journaux d'événements nécessitent des journaux d'événements dans lesquels les traces et les événements sont étiquetés, c'est-à-dire qu'ils soient normaux ou anormaux. Lorsque de telles techniques exploitent des algorithmes d'apprentissage automatique, des journaux étiquetés sont également nécessaires pour l'entraînement/les tests pendant le développement du modèle. Malheureusement, les journaux d'événements du monde réel étiquetés ne sont pas disponibles parmi ceux habituellement pris en compte dans la communauté de l'exploration de processus. Par conséquent, les chercheurs dans ce domaine se sont appuyés sur l'injection artificielle d'anomalies dans des journaux d'événements réels ou simulés. En tant qu'approche innovante, la détection d'anomalies basée sur des algorithmes de classification à une classe sera très efficace dans ce contexte [352], [353], [354]. En fait, les anomalies dans un journal des événements sont normalement liées à des causes profondes spécifiques [355], [356]. Cependant, alors que les algorithmes de détection d'anomalies peuvent être efficaces pour identifier les anomalies, ils présentent un inconvénient majeur, car leur sortie est difficile à expliquer et à identifier les variables aberrantes. Ainsi, des efforts sont nécessaires pour développer le journal des événements basé sur la détection d'anomalies explicable dans l'exploration de processus en ligne. Nous

prévoyons également de développer apprentissage par renforcement inverses quantique pour apprendre auprès d'experts dans les domaines de l'optimisation des processus de fabrication. Enfin, avec une grande quantité de données du journal des événements disponibles depuis de nombreuses années, nous envisageons de développer apprentissage par renforcement inverse quantique pour pouvoir apprendre de l'expérience d'un expert afin d'optimiser le processus de production. Il sera très important de réduire la dépendance de l'entreprise vis-à-vis de l'expérience du personnel spécialisé car il est difficile de trouver du personnel de remplacement lors de leur départ.

7.2.2 Détection d'anomalies explicables et optimisation pour la gestion de la chaîne d'approvisionnement

L'une des limites de cette étude est la possibilité d'accéder à des données réelles de la société en raison de problèmes de sécurité des entreprises. Cependant, les résultats obtenus sur les données réelles sont également impressionnants et ils ont été confirmés par la société. Une autre limitation est que le modèle de détection d'anomalie est utilisé pour détecter les anomalies qui se sont produites dans les données antérieures. Il pourrait être plus intéressante si elle peut être utilisée pour prédire les anomalies qui se produisent à l'avenir. Cela pourrait être considéré pour des recherches ultérieures. Par exemple, nous pensons à la combinaison de deux modèles, y compris les modèles de prévision et la détection d'anomalies pour cette tâche. Nous pensons de prendre les données du passé jusqu'à nos jours pour construire le modèle de prévision, puis utiliser ce modèle pour prédire les ventes de demain. Après cela, nous utilisons la valeur prédite des ventes comme entrée du modèle de détection d'anomalies, en la combinant avec les ventes des jours précédents de $H-1$, y compris les ventes d'aujourd'hui (où H est la taille de la fenêtre glissante), pour savoir si cette valeur est une anomalie ou non. Cette étude pourrait être très utile aux entreprises pour avoir une stratégie efficace et précoce. De plus, dans le cas de données de grande dimension dans la gestion de la chaîne d'approvisionnement, la plupart des modèles de détection d'anomalies ne considèrent pas les relations possibles entre les variables qui peuvent être réduites l'effet de détection des anomalies. Récemment, les réseaux de neurones (en anglais Graph Neural Networks, GNN) ont montré le succès dans la modélisation des données structurées et graphiques pour la détection d'anomalies [357]. Dans ce contexte, une carte de contrôle basée sur une VAE (en anglais Variational Autoencoders) basée sur un transformateur de graphes, une carte MEWMA et un SVDD peut être une approche intéressante à développer. De plus, la technique d'apprentissage par renforcement et incorporation de graphes sera développée pour optimiser la chaîne d'approvisionnement. Apprentissage par renforcement inverse quantique peut également être développé pour apprendre de l'expérience d'experts dans le domaine.

7.2.3 Apprentissage fédéré sécurisé et explicable pour des soins de santé intelligents

En ce qui concerne les soins de santé, différents hôpitaux collectent des informations chaque jour. Ensemble, ils disposent d'un vaste ensemble de données sur lequel des modèles d'apprentissage en profondeur peuvent être formés pour aider les praticiens cliniques. Cependant, les données de santé sont comme une empreinte numérique, qui contient des informations privées du propriétaire des données, ce qui crée des problèmes

de confidentialité. Par conséquent, le propriétaire des données (l'hôpital individuel ou les patients) n'est pas disposé à partager les données. De plus, les modèles d'apprentissage en profondeur sont comme des boîtes noires, nous ne connaissons pas vraiment la raison de leurs prédictions, mais dans le domaine de la santé, les praticiens cliniques devraient connaître la raison d'une prédiction particulière. Par conséquent, dans le cadre des soins de santé sécurisés et explicables avec apprentissage fédéré, nous, avec notre partenaire britannique (université de Kent, Royaume-Uni) propose de développer un cadre de soins de santé intelligent de bout en bout pour une utilisation en temps réel, basé sur l'Internet avancé des objets (IoT), l'intelligence artificielle (IA), l'IA explicable (XAI) et la blockchain. L'apprentissage fédéré permet aux experts en données de concevoir d'IA sans compromettre la confidentialité des utilisateurs. En d'autres termes, l'apprentissage fédéré est un mécanisme de formation d'un modèle mondial partagé avec un serveur central tout en conservant toutes les données sensibles dans les institutions locales auxquelles les données appartiennent, offre une grande promesse de connecter les sources de données de santé fragmentées avec la préservation de la confidentialité. Cette méthode est conçue pour perturber le paradigme de l'IA centralisée, dans laquelle un algorithme s'améliore à mesure que de plus en plus de données personnelles sont collectées. L'apprentissage fédéré pourrait être la solution pour les industries où les données ne peuvent pas être transférées à des tiers pour des raisons de confidentialité (santé, banque, etc.), la sécurité, la confidentialité et l'hétérogénéité. En particulier, les principaux objectifs du projet sont les suivants : (1) développer de nouvelles méthodes de surveillance de la e-santé (un élément clé du système de santé intelligent proposé), c'est notamment le cas sur les applications de surveillance de la e-santé pour les patients chroniques, où le besoin de qualité des données pour assurer une prise de décision correcte est très important. La surveillance des patients fait référence à une observation continue de l'état d'un patient (physiologique et physique) traditionnellement réalisée par un ou plusieurs capteurs corporels. En particulier, les principaux objectifs du projet sont les suivants : (1) construction d'un système de surveillance physiologique en ligne pour les patients chroniques (où le besoin de qualité des données pour assurer une prise de décision correcte est très important) pour collecter des données sur l'état du patient de la santé en utilisant des "vêtements intelligents" au lieu de capteurs portables (les actions et décisions importantes sont basées sur les données de ces capteurs (par exemple : diagnostic à distance, consultations, hospitalisation, etc.); 2) développer de nouvelles techniques d'apprentissage fédéré explicables pour le système de surveillance ECG [7] et détection des arythmies cardiaques (par la technique de détection d'anomalies), système de reconnaissance de l'activité humaine (éléments clés du système de santé intelligent proposé. (3) L'apprentissage par renforcement inverse quantique peut être développé pour apprendre des experts en dossiers médicaux. (4) introduire un cadre de sécurité basé sur la blockchain pour lutter contre les attaques par empoisonnement des modèles et la confidentialité dans l'architecture d'apprentissage fédérée proposée, et (5) conception de un modèle explicable basé sur l'IA pour expliquer les résultats du modèle d'apprentissage en profondeur.

Nous divisons virtuellement le cadre proposé en deux niveaux : niveau 1 et niveau 2. Ici, le niveau 1 est davantage associé à la fourniture de soins de santé intelligents et précis, tandis que le niveau 2 vise à assurer la confidentialité et la sécurité du paramètre de niveau 1 sous-jacent. Cette direction de recherche est dirigée dans la thèse par M. Ali

Raza.

7.2.4 Apprentissage fédéré explicable pour les applications de cybersécurité

Après avoir passé en revue toutes les conceptions et tous les problèmes liés à l'exécution d'une architecture résiliente et efficace pour la détection d'anomalies dans le contexte d'un système basé sur l'IoT, nous pouvons voir qu'une architecture d'apprentissage fédéré basée sur l'informatique de périphérie est une bonne architecture candidate pour les applications de la fabrication intelligente dans le contexte du Big Data. L'architecture globale s'est avérée avoir des performances de détection élevées, tout en offrant l'avantage d'avoir une réponse rapide puisque la détection d'anomalies est mis en œuvre à proximité des sources d'attaque (c'est-à-dire le bord). L'architecture apprentissage fédéré répartit la tâche de surveillance et de détection sur des zones locales plus petites, afin qu'elle puisse mieux gérer les Big Data générées dans une usine intelligente. De plus, un tel système peut réduire la bande passante pour contrôler les données dans la liaison de transmission entre la périphérie et le cloud, tout en garantissant que le matériel de périphérie ne sera pas surchargé en termes d'utilisation du processeur et de la mémoire. Pour une meilleure conception future du système, les ingénieurs doivent prendre en compte et considérer plusieurs problèmes, comme suit :

- Pour mieux optimiser ces systèmes distribués en termes de poids communiquant entre l'Edge et le Cloud, ainsi que pour définir les données d'entraînement les plus appropriées afin que les appareils Edge utilisent le moins de ressources de calcul possible pour pouvoir effectuer plus d'autres tâches .
- La limite de la taille des données et de leur nombre de fonctionnalités doit être étudiée plus avant pour garantir que le edge computing fonctionne dans un mode stable.
- De plus, davantage d'aspects d'autres applications au sein de la fabrication intelligente devraient être couverts, tels que : la maintenance prédictive, le contrôle qualité, l'optimisation de la production en temps réel dans une usine intelligente 4.0.
- Répondre à un aspect critique lorsque les sites de fabrication ne sont pas identiques, par exemple en nombre de machines. Cela soulève le problème de la formation distribuée déséquilibrée pour tous les modèles d'IA fonctionnant à la périphérie. Étant donné que les ensembles de données de différents sites peuvent être différents (c'est-à-dire une distribution de données déséquilibrée), cela augmente le biais du modèle appris par le serveur apprentissage fédéré.

Une autre perspective est l'interprétabilité des décisions des modèles de boîte noire, qui sont basés sur des algorithmes liés à l'apprentissage automatique avec des tonnes de paramètres. Bien que les résultats de prédiction de ces algorithmes puissent atteindre des performances élevées, il est problématique pour les ingénieurs de les analyser et de les étudier. Par conséquent, le XAI peut être adoptée pour surmonter cet inconvénient, en particulier dans les systèmes de contrôle industriels où les ingénieurs doivent surveiller de près leurs systèmes IoT. La raison en est simplement que XAI aide les humains à comprendre la raison pour laquelle les modèles prédisent sa décision. Avec des cadres XAI de pointe nous permettant d'expliquer et d'évaluer efficacement la fiabilité des résultats, nous devrions à l'avenir les utiliser pour interpréter les décisions prises [358]. Motivé

par ces potentiels, une détection d'anomalies explicables basée sur l'apprentissage fédéré pour les systèmes de contrôle industriel comme l'ensemble de l'architecture pour détecter et analyser les anomalies dans les systèmes de contrôle industriels et pour permettre la détection dans un environnement distribué avec un apprentissage fédéré devrait être développée. Cet axe de recherche est mené dans le cadre d'un projet collaboratif avec HUST (Hanoi University of Science and Technology), Vietnam, une thèse en co-tutelle est prévue en septembre 2022.

7.2.5 Vers une mode durable avec l'intelligence artificielle et science des données

Les industries du textile et de la mode sont difficiles à atteindre la durabilité car elles sont constituées d'une longue chaîne d'approvisionnement. Spécifiquement, la fast fashion a un coût environnemental et social étonnant. Alors que les impacts de l'industrie de la mode en termes de pollution, d'utilisation de l'eau, d'émissions de carbone, de droits humains et d'inégalité entre les sexes augmentent, la nécessité d'une transition vers une mode durable est évidente. En utilisant l'IA, l'industrie de la mode peut être plus durable, réduire les déchets et atteindre une plus grande personnalisation pour les clients [359], [360].

7.2.5.1 Prédiction des tendances pour la mode durable

La tendance de la mode change constamment de temps en temps, ce qui entraîne une difficulté dans la prévision de la demande. D'où, une bonne compréhension de l'évolution des styles et des tendances de mode joue un rôle crucial, au sein des entreprises de mode, et offre d'énormes avantages. Cependant, les tendances de la mode sont souvent perçues comme imprévisibles en raison de l'énorme quantité de facteurs influençant la subjectivité des stylistes ainsi que le goût des consommateurs. Cependant, on est arrivé à un moment où, chaque jour, nous téléchargeons collectivement sur les plateformes des réseaux sociaux des milliards de photos et de publications, ce qui rend le travail des prévisionnistes encore plus difficile. Par conséquent, afin de gérer cette masse d'informations de façon optimale, les techniques d'IA se révèlent particulièrement efficaces [361]. Au lieu de parcourir manuellement Instagram et d'autres plateformes de réseaux sociaux, l'IA permet l'analyse rapide d'une vaste base de données textuelles et visuelles, ce qui serait difficile, voire impossible, pour une personne seule. Récemment, les solutions d'IA permettant un apprentissage profond ont attiré une grande attention dans le domaine de la mode [362].

En outre, les chercheurs ont récemment abordé le défi de la prévision des tendances de la mode en utilisant surtout des images [363]. Cependant, une prédiction des ventes en utilisant uniquement des données quantitatives internes à l'entreprise ne peut pas donner toute seule une prévision fiable, pour la saison à venir, de la demande des clients largement influencée par les tendances du marché. D'autre part, se baser juste sur les données issues des réseaux sociaux donne une vue globale des styles et des produits à la mode mais ne suffit encore pas pour obtenir une prédiction de la demande fiable des clients d'une entreprise bien déterminée [364]. D'où la contribution essentielle de cette direction de recherche : profiter des différents types de données, quantitatives et qualitatives, internes et externes à l'entreprise, dans un seul système de prévision globale. Ceci aide fortement l'entreprise à mieux comprendre dans quels types de produits sont intéressés ses clients,

et de pouvoir ensuite prévoir avec précision leurs demandes futures. Cette direction de recherche est menée dans une thèse en cours par Mme. Rita SLEIMAN.

7.2.5.2 Optimisation d'un outil d'évaluation pour la filière textile-habillement : vers des modes de production et de consommation plus durables

Cette direction de recherche couvre les champs disciplinaires des sciences des matériaux et plus particulièrement de leur caractérisation physico-chimique, du génie des procédés textiles, de la gestion et des théories de l'information. Dans sa démarche et concernant les sciences de l'information, l'entreprise structure, collecte, consolide et analyse des données massives à différents niveaux de degré d'expertise, hétérogènes (géographique, acteurs de la filière B2B2C2C (en anglais Business-to-business-to-consumer), temporalité, etc.) et ce au travers de deux échelles imbriquées : les échelles des marques et des produits. Forte de son modèle de développement à la source d'informations pertinentes et soucieuse d'offrir un service de qualité centrée sur le consommateur tout en aidant les metteurs en marché à mieux répondre à leurs attentes, l'entreprise souhaite exploiter dans ce projet les données massives et riches dont elle dispose ainsi que les possibilités offertes par les sciences de l'information pour enrichir cette dernière (introduction et modification de descripteurs en lien avec son métier, détermination de classes pour les marques et les produits) ainsi que pour garantir la fiabilité, la robustesse et la précision des informations retournées à ses utilisateurs tout autant que de prendre en considération l'aspect dynamique de son modèle à partir d'observations passées et anticiper les évolutions du comportement des consommateurs. Ces données combinent des niveaux de connaissances humaines expertes issues de professionnels et scientifiques de la chaîne d'approvisionnement textile, des sciences de gestion (comportements d'achat, appropriation et perception des consommateurs, traduction sémantique des termes scientifiques en lien avec la responsabilité sociale de l'entreprise, normalisation, etc.), et non expertes, ainsi que des données physiques issues de la caractérisation des produits textiles sur les aspects liés à la durabilité des produits [365], [366]. Cette direction de recherche est menée dans une thèse par Mme. Léa Cateau.

Bibliographie

- [1] P. H. Tran, A. Ahmadi Nadi, T. H. Nguyen, K. D. Tran, and K. P. Tran, "Application of machine learning in statistical process control charts : A survey and perspective," in *Control Charts and Machine Learning for Anomaly Detection in Manufacturing*. Springer, 2022, pp. 7–42.
- [2] Z. He, K.-P. Tran, S. Thomassey, X. Zeng, J. Xu, and C. Yi, "A deep reinforcement learning based multi-criteria decision support system for optimizing textile chemical process," *Computers in Industry*, vol. 125, p. 103373, 2021.
- [3] Z. He, K. P. Tran, S. Thomassey, X. Zeng, J. Xu, and C. Yi, "Multi-objective optimization of the textile manufacturing process using deep-q-network based multi-agent reinforcement learning," *Journal of Manufacturing Systems*, 2021, in press, DOI : 10.1016/j.jmsy.2021.03.017.
- [4] H. Nguyen, K. P. Tran, S. Thomassey, and M. Hamad, "Forecasting and anomaly detection approaches using LSTM and LSTM autoencoder techniques with the applications in supply chain management," *International Journal of Information Management*, vol. 57, pp. 102282 :1–102282 :13, 2021.
- [5] P. H. Tran, K. P. Tran, T. T. Huong, C. Heuchenne, P. HienTran, and T. M. H. Le, "Real time data-driven approaches for credit card fraud detection," in *Proceedings of the 2018 international conference on e-business and applications*, 2018, pp. 6–9.
- [6] T. H. Truong, P. B. Ta, M. L. Dao, D. L. Tran, M. D. Nguyen, A. Q. Le, T. C. Le, D. T. Bui, and K. P. Tran, "Detecting cyberattacks using anomaly detection in industrial control systems : A federated learning approach," *Computers in Industry*, vol. 132, p. 103509, 2021.
- [7] A. Raza, K. P. Tran, L. Koehl, and S. Li, "Designing ECG monitoring healthcare system with federated transfer learning and explainable AI," *Knowledge-Based Systems*, 2021, in press, 10.1016/j.knsys.2021.107763.
- [8] F. S. Zaidi, P. Castagliola, K. P. Tran, and M. B. C. Khoo, "Performance of the mewma-coda control chart in the presence of measurement errors," *Quality and Reliability Engineering International*, vol. 36, no. 7, pp. 2411–2440, 2020.
- [9] K. P. Tran, H. Du Nguyen, and S. Thomassey, "Anomaly detection using long short term memory networks and its applications in supply chain management," *IFAC-PapersOnLine*, vol. 52, no. 13, pp. 2408–2412, 2019.
- [10] B. Lindemann, F. Fesenmayr, N. Jazdi, and M. Weyrich, "Anomaly detection in discrete manufacturing using self-learning approaches," *Procedia CIRP*, vol. 79, pp. 313–318, 2019.
- [11] P. Qiu, "Big data ? Statistical process control can help!" *The American Statistician*, vol. 74, no. 4, pp. 329–344, 2020.
- [12] J. Wang, Y. Ma, L. Zhang, R. X. Gao, and D. Wu, "Deep learning for smart manufacturing : Methods and applications," *Journal of Manufacturing Systems*, vol. 48, pp. 144–156, 2018.
- [13] F. Lopez, M. Saez, Y. Shao, E. Balta, J. Moyne, Z. Mao, K. Barton, and D. Tilbury, "Categorization of anomalies in smart manufacturing systems to support the selection of detection mechanisms," *IEEE Robotics and Automation Letters*, vol. 2, no. 4, pp. 1885–1892, 2017.

- [14] F. Tsung, K. Zhang, L. Cheng, and Z. Song, “Statistical transfer learning : A review and some extensions to statistical process control,” *Quality Engineering*, vol. 30, no. 1, pp. 115–128, 2018.
- [15] I. Zwetsloot, T. Mahmood, and W. Woodall, “Multivariate time-between-events monitoring : An overview and some overlooked underlying complexities,” *Quality Engineering*, pp. 1–13, 2020.
- [16] S. Lee, M. Kwak, K. Tsui, and S. Kim, “Process monitoring using variational autoencoder for high-dimensional nonlinear processes,” *Engineering Applications of Artificial Intelligence*, vol. 83, pp. 13–27, 2019.
- [17] P. Qiu and X. Xie, “Transparent sequential learning for statistical process control of serially correlated data,” *Technometrics*, no. just-accepted, pp. 1–29, 2021.
- [18] G. Celano, P. Castagliola, A. Faraz, and S. Fichera, “Statistical Performance of a Control Chart for Individual Observations Monitoring the Ratio of two Normal Variables,” *Quality and Reliability Engineering International*, vol. 30, no. 8, pp. 1361–1377, 2014.
- [19] G. Celano and P. Castagliola, “Design of a phase ii control chart for monitoring the ratio of two normal variables,” *Quality and Reliability Engineering International*, vol. 32, no. 1, pp. 291–308, 2016.
- [20] A. Spisak, “A Control Chart for Ratios,” *Journal of Quality Technology*, vol. 22, no. 1, pp. 34–37, 1990.
- [21] D. Öksoy, E. Boulos, and L. Pye, “Statistical Process Control by the Quotient of two Correlated Normal Variables,” *Quality Engineering*, vol. 6, no. 2, pp. 179–194, 1994.
- [22] G. Celano and P. Castagliola, “A Synthetic Control Chart for Monitoring the Ratio of Two Normal Variables,” *Quality and Reliability Engineering International*, vol. 32, no. 2, pp. 681–696, 2016.
- [23] K. Tran, P. Castagliola, and G. Celano, “Monitoring the Ratio of Two Normal Variables Using Run Rules Type Control Charts,” *International Journal of Production Research*, vol. 54, no. 6, pp. 1670–1688, 2016.
- [24] —, “Monitoring the Ratio of Two Normal Variables Using EWMA Type Control Charts,” *Quality and Reliability Engineering International*, vol. 32, no. 2, pp. 1853–1869, 2016.
- [25] —, “Monitoring the ratio of population means of a bivariate normal distribution using cusum type control charts,” *Statistical Papers*, vol. 59, no. 1, pp. 387–413, 2018.
- [26] K. P. Tran, P. Castagliola, and G. Celano, “The Performance of the Shewhart-RZ Control Chart in the Presence of Measurement Error,” *International Journal of Production Research*, vol. 54, no. 24, pp. 7504–7522, 2016.
- [27] H. Nguyen and K. Tran, “Effect of the measurement errors on two one-sided shewhart control charts for monitoring the ratio of two normal variables,” *Quality and Reliability Engineering International*, vol. 36, no. 5, pp. 1731–1750, 2020.
- [28] H. Nguyen, K. Tran, and C. Heuchenne, “Monitoring the ratio of two normal variables using variable sampling interval exponentially weighted moving average

- control charts,” *Quality and Reliability Engineering International*, vol. 35, no. 1, pp. 439–460, 2019.
- [29] D. Brook and D. Evans, “An Approach to the Probability Distribution of CUSUM Run Length,” *Biometrika*, vol. 59, no. 3, pp. 539–549, 1972.
- [30] K. Linna, W. Woodall, and K. Busby, “The Performance of Multivariate Control Charts in the Presence of Measurement Error,” *Journal of Quality Technology*, vol. 33, no. 3, pp. 349–355, 2001.
- [31] H. Nguyen, K. Tran, and K. Tran, “The effect of measurement errors on the performance of the exponentially weighted moving average control charts for the ratio of two normally distributed variables,” *European Journal of Operational Research*, vol. 293, no. 1, pp. 203–218, 2021.
- [32] K. D. Tran, A. A. Nadi, T. H. Nguyen, K. P. Tran *et al.*, “One-sided shewhart control charts for monitoring the ratio of two normal variables in short production runs,” *Journal of Manufacturing Processes*, vol. 69, pp. 273–289, 2021.
- [33] F. Pettijohn, P. Potter, and R. Siever, *Sand and Sandstone*, 2nd ed. Springer-Verlag, New York, 1987.
- [34] P. Potter, “Modern Sands of South America : Composition, Provenance and Global Significance,” *Geologische Rundschau*, vol. 83, no. 1, pp. 212–232, 1994.
- [35] R. Tolosana-Delgado and H. Von Eynatten, “Grain-Size Control on Petrographic Composition of Sediments : Compositional Regression and Rounded Zeros,” *Mathematical Geosciences*, vol. 41, no. 8, p. 869, 2009.
- [36] M. Lipp and E. Anklam, “Review of Cocoa Butter and Alternative Fats for Use in Chocolate – Part A. Compositional Data,” *Food Chemistry*, vol. 62, no. 1, pp. 73–97, 1998.
- [37] D. Billheimer, P. Guttorp, and W. Fagan, “Statistical Interpretation of Species Composition,” *Journal of the American statistical Association*, vol. 96, no. 456, pp. 1205–1214, 2001.
- [38] J. Aitchison, *The Statistical Analysis of Compositional Data*, ser. Monographs on Statistics and Applied Probability. Springer Netherlands, 2011.
- [39] V. Pawlowsky-Glahn, J. Egozcue, and R. Tolosana-Delgado, *Modeling and Analysis of Compositional Data*. John Wiley & Sons, 2015.
- [40] R. Boyles, “Using the Chi-Square Statistic to Monitor Compositional Process Data,” *Journal of Applied Statistics*, vol. 24, no. 5, pp. 589–602, 1997.
- [41] R. Guevara-González, J. Vargas-Navas, and D. Linero-Segrera, “Profile Monitoring for Compositional Data,” *Revista Colombiana de Estadística*, vol. 37, no. 1, pp. 159–181, 2014.
- [42] M. Vives-Mestres, J. D. i Estadella, and J. Martín-Fernández, “Out-of-Control Signals in Three-Part Compositional T^2 Control Chart,” *Quality and Reliability Engineering International*, vol. 30, no. 3, pp. 337–346, 2014.
- [43] K. Tran, P. Castagliola, G. Celano, and M. Khoo, “Monitoring Compositional Data using Multivariate Exponentially Weighted Moving Average Scheme,” *Quality and Reliability Engineering International*, vol. 34, no. 3, pp. 391–402, 2018.

- [44] M. Maleki, A. Amiri, and P. Castagliola, “Measurement Errors in Statistical Process Monitoring : a Literature Review,” *Computers & Industrial Engineering*, vol. 103, pp. 316–329, 2017.
- [45] F. Zaidi, P. Castagliola, K. Tran, and M. Khoo, “Performance of the hotelling t^2 control chart for compositional data in the presence of measurement errors,” *Journal of Applied Statistics*, vol. 46, no. 14, pp. 2583–2602, 2019.
- [46] K. Linna and W. Woodall, “Effect of Measurement Error on Shewhart Control Charts,” *Journal of Quality Technology*, vol. 33, no. 2, pp. 213–222, 2001.
- [47] M. Vives-Mestres, J. Daunis-I-Estadella, and J. Martin-Fernandez, “Individual T^2 Control Chart for Compositional Data,” *Journal of Quality Technology*, vol. 46, no. 2, pp. 127–139, 2014.
- [48] C. A. Lowry, W. H. Woodall, C. W. Champ, and S. E. Rigdon, “A multivariate exponentially weighted moving average control chart,” *Technometrics*, vol. 34, no. 1, p. 46, 1992.
- [49] M. Gnanadesikan and S. Gupta, “A selection procedure for multivariate normal distributions in terms of the generalized variances,” *Technometrics*, vol. 12, no. 1, pp. 103–117, 1970.
- [50] K. Tran, H. Nguyen, and S. Thomassey, “Anomaly detection using long short term memory networks and its applications in supply chain management,” *IFAC-PapersOnLine*, vol. 52, no. 13, pp. 2408–2412, 2019.
- [51] P. H. Tran, C. Heuchenne, and S. Thomassey, “An anomaly detection approach based on the combination of lstm autoencoder and isolation forest for multivariate time series data,” in *Proceedings of the 14th International FLINS Conference on Robotics and Artificial Intelligence (FLINS 2020)*. World Scientific, 2020, pp. 18–21.
- [52] S. J. Sheather and J. S. Marron, “Kernel quantile estimators,” *Journal of the American Statistical Association*, vol. 85, no. 410, pp. 410–416, 1990.
- [53] H. Qiu, J. Lee, J. Lin, and G. G. Yu, “Wavelet filter-based weak signature detection method and its application on rolling element bearing prognostics,” *Journal of sound and vibration*, vol. 289, no. 4-5, pp. 1066–1090, 2006.
- [54] K. P. Tran and S. Knoth, “Steady-state arl analysis of arl-unbiased ewma-rz control chart monitoring the ratio of two normal variables,” *Quality and Reliability Engineering International*, vol. 34, no. 3, pp. 377–390, 2018.
- [55] T. Nguyen, H. Nguyen, K. Tran, T. Truong, K. Phung, L. Nguyen, T. Le, and K. Tran, “One-sided synthetic-rz control charts : a new method for anomaly detection,” in *2019 6th NAFOSTED Conference on Information and Computer Science (NICS)*. IEEE, 2019, pp. 262–267.
- [56] H. Nguyen, K. Tran, and T. Goh, “Variable sampling interval control charts for monitoring the ratio of two normal variables,” *Journal of Testing and Evaluation*, vol. 48, no. 3, 2020.
- [57] H. Du Nguyen and K. Phuc Tran, “Effect of the measurement errors on two one-sided shewhart control charts for monitoring the ratio of two normal variables,” *Quality and Reliability Engineering International*, 2020.

- [58] H. D. Nguyen, K. P. Tran, and H. L. Heuchenne, “Cusum control charts with variable sampling interval for monitoring the ratio of two normal variables,” *Quality and Reliability Engineering International*, vol. 36, no. 2, pp. 474–497, 2020.
- [59] K. P. Tran, “Run rules median control charts for monitoring process mean in manufacturing,” *Quality and Reliability Engineering International*, vol. 33, no. 8, pp. 2437–2450, 2017.
- [60] K. P. Tran, P. Castagliola, and N. Balakrishnan, “On the performance of shewhart median chart in the presence of measurement errors,” *Quality and Reliability Engineering International*, vol. 33, no. 5, pp. 1019–1029, 2017.
- [61] K. P. Tran, P. Castagliola, T. H. Nguyen, and A. Cuzol, “Design of a variable sampling interval ewma median control chart,” *International Journal of Reliability, Quality and Safety Engineering*, vol. 26, no. 05, p. 1950021, 2019.
- [62] P. H. Tran, K. P. Tran, and A. Rakitzis, “A synthetic median control chart for monitoring the process mean with measurement errors,” *Quality and Reliability Engineering International*, vol. 35, no. 4, pp. 1100–1116, 2019.
- [63] H. Du Nguyen, Q. T. Nguyen, T. H. Nguyen, N. Balakrishnan, and K. Phuc, “The performance of the ewma median chart in the presence of measurement error,” *Artificial Intelligence*, vol. 1, no. 1, p. 49, 2020.
- [64] K. Duc Tran, H. Du Nguyen, T. Hien Nguyen, and K. Phuc Tran, “Design of a variable sampling interval exponentially weighted moving average median control chart in presence of measurement errors,” *Quality and Reliability Engineering International*, vol. 37, no. 1, pp. 374–390, 2021.
- [65] P. Castagliola, K. Tran, G. Celano, A. Rakitzis, and P. Maravelakis, “An ewma-type sign chart with exact run length properties,” *Journal of quality technology*, vol. 51, no. 1, pp. 51–63, 2019.
- [66] P. Castagliola, K. P. Tran, G. Celano, and P. E. Maravelakis, “The shewhart sign chart with ties : Performance and alternatives,” 2020.
- [67] K. P. Tran, “Designing of run rules t control charts for monitoring changes in the process mean,” *Chemometrics and Intelligent Laboratory Systems*, vol. 174, pp. 85–93, 2018.
- [68] H. Du Nguyen, K. P. Tran, G. Celano, P. E. Maravelakis, and P. Castagliola, “On the effect of the measurement error on shewhart t and ewma t control charts,” *The International Journal of Advanced Manufacturing Technology*, vol. 107, no. 9, pp. 4317–4332, 2020.
- [69] P. Tran and K. P. Tran, “The Efficiency of CUSUM schemes for monitoring the Coefficient of Variation,” *Stochastic Models in Business and Industry*, vol. 32, no. 6, pp. 870–881, 2016.
- [70] K. P. Tran, H. Nguyen, Q. T. Nguyen, and W. Chattinnawat, “One-sided synthetic control charts for monitoring the coefficient of variation with measurement errors,” in *2018 IEEE international conference on industrial engineering and engineering management (IEEM)*. IEEE, 2018, pp. 1667–1671.
- [71] K. P. Tran, C. Heuchenne, and N. Balakrishnan, “On the performance of coefficient of variation charts in the presence of measurement errors,” *Quality and Reliability Engineering International*, vol. 35, no. 1, pp. 329–350, 2019.

- [72] K. P. Tran, H. Du Nguyen, P. H. Tran, and C. Heuchenne, “On the performance of cusum control charts for monitoring the coefficient of variation with measurement errors,” *The International Journal of Advanced Manufacturing Technology*, vol. 104, no. 5, pp. 1903–1917, 2019.
- [73] Q. T. Nguyen, K. P. Tran, P. Castagliola, G. Celano, and S. Lardjane, “One-sided synthetic control charts for monitoring the multivariate coefficient of variation,” *Journal of Statistical Computation and Simulation*, vol. 89, no. 10, pp. 1841–1862, 2019.
- [74] V. Giner-Bosch, K. P. Tran, P. Castagliola, and M. B. C. Khoo, “An ewma control chart for the multivariate coefficient of variation,” *Quality and Reliability Engineering International*, vol. 35, no. 6, pp. 1515–1541, 2019.
- [75] Q. T. Nguyen, K. P. Tran, H. L. Heuchenne, T. H. Nguyen, and H. D. Nguyen, “Variable sampling interval shewhart control charts for monitoring the multivariate coefficient of variation,” *Applied Stochastic Models in Business and Industry*, vol. 35, no. 5, pp. 1253–1268, 2019.
- [76] P. H. Tran, A. Rakitzis, H. Nguyen, Q. T. Nguyen, H. Tran, K. P. Tran, and C. Heuchenne, “New methods for anomaly detection : Run rules multivariate coefficient of variation control charts,” in *2020 International Conference on Advanced Technologies for Communications (ATC)*. IEEE, 2020, pp. 40–44.
- [77] Q.-T. Nguyen, V. Giner-Bosch, K. D. Tran, C. Heuchenne, and K. P. Tran, “One-sided variable sampling interval ewma control charts for monitoring the multivariate coefficient of variation in the presence of measurement errors,” *The International Journal of Advanced Manufacturing Technology*, pp. 1–31, 2021.
- [78] K. Tran, Ed., *Control Charts and Machine Learning for Anomaly Detection in Manufacturing*. Springer Nature, 2021.
- [79] H. Nguyen, K. Tran, X. Zeng, L. Koehl, P. Castagliola, and P. Bruniaux, “Industrial internet of things, big data, and artificial intelligence in the smart factory : A survey and perspective,” in *ISSAT International Conference on Data Science in Business, Finance and Industry*, 2019, pp. 72–76.
- [80] K. P. Tran, “Artificial intelligence for smart manufacturing : Methods and applications,” 2021.
- [81] F. Uddin, *Introductory chapter : textile manufacturing processes*. Rijeka : IntechOpen, 2009.
- [82] Z. He, J. Xu, K. P. Tran, S. Thomassey, X. Zeng, and C. Yi, “Modeling of textile manufacturing processes using intelligent techniques : a review,” *The International Journal of Advanced Manufacturing Technology*, pp. 1–29, 2021.
- [83] A. Hasanbeigi and L. Price, “A review of energy use and energy efficiency technologies for the textile industry,” *Renewable and Sustainable Energy Reviews*, vol. 16, no. 6, pp. 3648–3665, 2012.
- [84] V. Kumar, L. Koehl, X. Zeng, and D. Ekwall, “Coded yarn based tag for tracking textile supply chain,” *Journal of Manufacturing Systems*, vol. 42, pp. 124–139, 2017.
- [85] V. Kumar, L. Koehl, and X. Zeng, “A fully yarn integrated tag for tracking the international textile supply chain,” *Journal of Manufacturing Systems*, vol. 40, pp. 76–86, 2016.

- [86] S. Kaplan, C. Araz, and O. Goktepe, "A multicriteria decision aid approach on navel selection problem for rotor spinning," *Textile Research Journal*, vol. 76, no. 12, pp. 896–904, 2006.
- [87] R. K. R. Guduru, S. H. Shaik, S. Yaramala, N. P. TMS, and A. Domeika, "A dynamic optimization model for multiobjective maintenance of sewing machine," *International Journal of Pure and Applied Mathematics*, vol. 118, no. 20, pp. 33–43, 2018.
- [88] A. Majumdar, S. P. Singh, and A. Ghosh, "Modelling, optimization and decision making techniques in designing of functional clothing," *Indian Journal of Fibre and Textile Research*, vol. 36, pp. 398–409, 12 2011.
- [89] S. Chakraborty and S. Diyaley, "Multi-objective optimization of yarn characteristics using evolutionary algorithms : a comparative study," *Journal of The Institution of Engineers (India) : Series E*, vol. 99, no. 2, pp. 129–140, 2018.
- [90] Z. He, K. P. Tran, S. Thomassey, X. Zeng, and C. Yi, "Modeling color fading ozonation of reactive-dyed cotton using extreme learning machine, support vector regression and random forest," *Textile Research Journal*, vol. 90, no. 7-8, pp. 896–908, 2020.
- [91] J. N. Etters, "Advances in indigo dyeing : Implications for the dyer, apparel manufacturer and environment," *Textile Chemist & Colorist*, vol. 27, no. 2, pp. 17–22, 1995.
- [92] E. Kuznetsova, Y.-F. Li, C. Ruiz, E. Zio, G. Ault, and K. Bell, "Reinforcement learning for microgrid energy management," *Energy*, vol. 59, pp. 133–146, 2013.
- [93] S. M. H. Fard, A. Hamzeh, and S. Hashemi, "Using reinforcement learning to find an optimal set of features," *Computers & Mathematics with Applications*, vol. 66, no. 10, pp. 1892–1904, 2013.
- [94] E. Jasmin, T. I. Ahamed, and V. J. Raj, "Reinforcement learning solution for unit commitment problem through pursuit method," in *2009 International Conference on Advances in Computing, Control, and Telecommunication Technologies*, 2009, pp. 324–327.
- [95] T. Salimans, J. Ho, X. Chen, S. Sidor, and I. Sutskever, "Evolution strategies as a scalable alternative to reinforcement learning," *arXiv preprint arXiv :1703.03864*, 2017.
- [96] F. P. Such, V. Madhavan, E. Conti, J. Lehman, K. O. Stanley, and J. Clune, "Deep neuroevolution : Genetic algorithms are a competitive alternative for training deep neural networks for reinforcement learning," *arXiv preprint arXiv :1712.06567*, 2017.
- [97] C.-J. Hoel, K. Wolff, and L. Laine, "Automated speed and lane change decision making using deep reinforcement learning," in *21st International Conference on Intelligent Transportation Systems (ITSC)*, 2018, pp. 2148–2155.
- [98] M. Mukadam, A. Cosgun, A. Nakhaei, and K. Fujimura, "Tactical decision making for lane changing with deep reinforcement learning," in *Conference : NIPS 2017 Workshop on Machine Learning for Intelligent Transportation Systems*, 2017.
- [99] K. Shyjith, M. Ilangkumaran, and S. Kumanan, "Multi-criteria decision-making approach to evaluate optimum maintenance strategy in textile industry," *Journal of Quality in Maintenance Engineering*, vol. 14, no. 4, 2008.

- [100] T. L. Saaty, "How to make a decision : The analytic hierarchy process," *European Journal of Operational Research*, vol. 48, no. 1, pp. 9–26, 1990.
- [101] J. Dyer, "Remarks on the analytic hierarchy process," *Management Science*, vol. 36, no. 3, pp. 249–258, 1990.
- [102] R. Rocchetta, L. Bellani, M. Compare, E. Zio, and E. Patelli, "A reinforcement learning framework for optimal operation and maintenance of power grids," *Applied Energy*, vol. 241, pp. 291–301, 2019.
- [103] L. Zheng, D. Bing, X. Jun, and G. Shihui, "Bio-degumming optimization parameters of kenaf based on a neural network model," *The Journal of The Textile Institute*, vol. 101, no. 12, pp. 1075–1079, 2010.
- [104] J. Mwasiagi, X. Huang, and X. Wang, "The use of hybrid algorithms to improve the performance of yarn parameters prediction models," *Fibers and Polymers*, vol. 13, 11 2012.
- [105] S. Sette, L. Boullart, L. V. Langenhove, and P. Kiekens, "Optimizing the fiber-to-yarn production process with a combined neural network/genetic algorithm approach," *Textile Research Journal*, vol. 67, no. 2, pp. 84–92, 1997.
- [106] A. Majumdar, A. Das, P. Hatua, and A. Ghosh, "Optimization of woven fabric parameters for ultraviolet radiation protection and comfort using artificial neural network and genetic algorithm," *Neural Computing and Applications*, vol. 27, pp. 2567–2576, 2016.
- [107] J. Xu, Z. He, S. Li, and W. Ke, "Production cost optimization of enzyme washing for indigo dyed cotton denim by combining kriging surrogate with differential evolution algorithm," *Textile Research Journal*, vol. 90, no. 15-16, pp. 1860–1871, 2020.
- [108] R. Rana and F. S. Oliveira, "Dynamic pricing policies for interdependent perishable products or services using reinforcement learning," *Expert Systems with Applications*, vol. 42, no. 1, pp. 426–436, 2015.
- [109] P. Khude, A. Majumdar, and B. Butola, "Modelling and prediction of antibacterial activity of knitted fabrics made from silver nanocomposite fibres using soft computing approaches," *Neural Computing and Applications*, vol. 32, pp. 9509–9519, 2020.
- [110] E. Doran and C. Sahin, "The prediction of quality characteristics of cotton/elastane core yarn using artificial neural networks and support vector machines," *Textile Research Journal*, vol. 90, no. 13-14, pp. 1558–1580, 2019.
- [111] A. Ghosh and P. Chatterjee, "Prediction of cotton yarn properties using support vector machine," *Fibers and Polymers*, vol. 11, pp. 84–88, 2010.
- [112] Y. Wei, D. Kudenko, S. Liu, L. Pan, L. Wu, and X. Meng, "A reinforcement learning based workflow application scheduling approach in dynamic cloud environment," in *Collaborative Computing : Networking, Applications and Worksharing*. Springer International Publishing, 2018, pp. 120–131.
- [113] A. Ghosh, "Forecasting of cotton yarn properties using intelligent machines," *Research Journal of Textile and Apparel*, vol. 14, pp. 55–61, 2010.
- [114] J. Yang, Z. Lu, and B. Li, "Quality prediction in complex industrial process with support vector machine and genetic algorithm optimization : A case study," *Applied Mechanics and Materials*, vol. 232, pp. 603–608, 2012.

- [115] M. Dayik, "Prediction of yarn properties using evaluation programming," *Textile Research Journal*, vol. 79, no. 11, pp. 963–972, 2009.
- [116] A. Moghassem, A. Fallahpour, and M. Shanbeh, "An intelligent model to predict breaking strength of rotor spun yarns using gene expression programming," *Journal of Engineered Fibers and Fabrics*, vol. 7, no. 2, 2012.
- [117] S. Chakraborty, S. Agarwal, and S. Dandge, "Analysis of cotton fibre properties : a data mining approach," *J. Inst. Eng. India Ser. E*, vol. 99, pp. 163–176, 2018.
- [118] V. Nanduri and T. K. Das, "A reinforcement learning model to assess market power under auction-based energy pricing," *IEEE Transactions on Power Systems*, vol. 22, no. 1, pp. 85–95, 2007.
- [119] G. J. M. R. Krashennikova, E. and F. Fernandez, "Reinforcement learning for pricing strategy optimization in the insurance industry," *Engineering Applications of Artificial Intelligence*, vol. 80, pp. 8–19, 2019.
- [120] Y. Chizhov and A. Borisov, "Markov decision process in the problem of dynamic pricing policy," *Aut. Control Comp. Sci.*, vol. 45, pp. 361–371, 2011.
- [121] R. Lu, S. H. Hong, and X. Zhang, "A dynamic pricing demand response algorithm for smart grid : Reinforcement learning approach," *Applied Energy*, vol. 220, pp. 220–230, 2018.
- [122] A. Majumdar, B. Sarkar, and P. K. Majumdar, "Determination of quality value of cotton fibre using hybrid ahp-topsis method of multi-criteria decision-making," *The Journal of The Textile Institute*, vol. 96, no. 5, pp. 303–309, 2005.
- [123] A. Mitra, A. Majumdar, A. Ghosh, P. K. Majumdar, and D. Bannerjee, "Selection of handloom fabrics for summer clothing using multi-criteria decision making techniques," *Journal of Natural Fibers*, vol. 12, no. 1, pp. 61–71, 2015.
- [124] E. Triantaphyllou and S. T. Mann, "A computational evaluation of the original and revised analytic hierarchy process," *Computers & Industrial Engineering*, vol. 26, no. 3, pp. 609–618, 1994.
- [125] A. Liaw and M. Wiener, "Classification and regression by randomforest," *R News*, vol. 23, no. 3, pp. 18–22, 2002.
- [126] L. Breiman, "Random forests," *Machine Learning*, vol. 45, pp. 5–32, 10 2001.
- [127] B.-K. Kwon, J.-S. Won, and D. Kang, "Fast defect detection for various types of surfaces using random forest with vov features," *International Journal of Precision Engineering and Manufacturing*, vol. 16, pp. 965–970, 05 2015.
- [128] V. Venkatraman and B. K. Alsberg, "A quantitative structure-property relationship study of the photovoltaic performance of phenothiazine dyes," *Dyes and Pigments*, vol. 114, pp. 69–77, 2015.
- [129] T. L. Saaty, "What is the analytic hierarchy process?" in *Mathematical Models for Decision Support*. Berlin, Heidelberg : Springer Berlin Heidelberg, 1988, pp. 109–121.
- [130] R. S. Sutton, A. G. Barto *et al.*, *Introduction to reinforcement learning*. MIT press Cambridge, 1998, vol. 135.
- [131] V. Mnih, K. Kavukcuoglu, D. Silver, A. Rusu, J. Veness, M. Bellemare, A. Graves, M. Riedmiller, A. Fidjeland, G. Ostrovski, S. Petersen, C. Beattie, A. Sadik,

- I. Antonoglou, H. King, D. Kumaran, D. Wierstra, S. Legg, and D. Hassabis, "Human-level control through deep reinforcement learning," *Nature*, vol. 518, pp. 529–33, 2015.
- [132] J. Tsitsiklis and B. Van Roy, "An analysis of temporal-difference learning with function approximation," *IEEE Transactions on Automatic Control*, vol. 42, no. 5, pp. 674–690, 1997.
- [133] L.-J. Lin, "Reinforcement learning for robots using neural networks," Ph.D. dissertation, USA, 1992.
- [134] Z. He, M. Li, D. Zuo, and C. Yi, "Color fading of reactive-dyed cotton using uv-assisted ozonation," *Ozone : Science & Engineering*, vol. 41, no. 1, pp. 60–68, 2019.
- [135] —, "The effect of denim color fading ozonation on yarns," *Ozone : Science & Engineering*, vol. 40, no. 5, pp. 377–384, 2018.
- [136] Z. He, M. Li, D. Zuo, J. Xu, and C. Yi, "Effects of color fading ozonation on the color yield of reactive-dyed cotton," *Dyes and Pigments*, vol. 164, 2019.
- [137] X. Zeng, L. Koehl, M. Sanoun, and M. Bueno, M.A.and Renner, "Integration of human knowledge and measured data for optimization of fabric hand," *International Journal of General Systems*, vol. 33, no. 2-3, pp. 243–258, 2004.
- [138] S. Kim and H. Kim, "A new metric of absolute percentage error for intermittent demand forecasts," *International Journal of Forecasting*, vol. 32, no. 3, pp. 669–679, 2016.
- [139] Y. Xu, S. Thomassey, and X. Zeng, *AI for Apparel Manufacturing in Big Data Era : A Focus on Cutting and Sewing*. Springer Singapore, 2018.
- [140] K. K. Annamdas and S. S. Rao, "Multi-objective optimization of engineering systems using game theory and particle swarm optimization," *Engineering Optimization*, vol. 41, no. 8, pp. 737–752, 2009.
- [141] M. Jin, X. Lei, and J. Du, "Evolutionary game theory in multi-objective optimization problem," *International Journal of Computational Intelligence Systems*, vol. 3, no. sup01, pp. 74–87, 2010.
- [142] A. S. Akopov and M. A. Hevencev, "A multi-agent genetic algorithm for multi-objective optimization," in *2013 IEEE International Conference on Systems, Man, and Cybernetics*. IEEE, 2013, pp. 1391–1395.
- [143] H. Zhang, Y. Zeng, X. Jin, B. Shu, Y. Zhou, and X. Yang, "Simulating multi-objective land use optimization allocation using multi-agent system-a case study in changsha, china," *Ecological Modelling*, vol. 320, pp. 334–347, 2016.
- [144] L. Buşoni, R. Babuška, and B. De Schutter, "Multi-agent reinforcement learning : An overview," *Innovations in multi-agent systems and applications-1*, pp. 183–221, 2010.
- [145] M. A. Khamis, S. Member, and W. Gomaa, "Enhanced multiagent multi-objective reinforcement learning for urban traffic light control," in *2012 11th International Conference on Machine Learning and Applications*, vol. 1, 2012, pp. 586–591.
- [146] S. Sette and L. V. Langenhove, "Optimising the fibre-to-yarn production process : finding a blend of fibre qualities to create an optimal price/quality yarn," *Autex Research Journal*, vol. 2, no. 2, pp. 257–263, 2002.

- [147] A. Mukhopadhyay, V. Midha, and N. Ray, "Multi-objective optimization of parametric combination of injected slub yarn for producing knitted and woven fabrics with least abrasive damage," *Research Journal of Textile and Apparel*, vol. 21, no. 2, pp. 111–133, 2017.
- [148] A. A. Almetwally, "Multi-objective optimization of woven fabric parameters using taguchi-grey relational analysis," *Journal of Natural Fibers*, vol. 17, no. 10, pp. 1468–1478, 2020.
- [149] K. Deb, "Multi-objective optimization using evolutionary algorithms," vol. 16, 2001.
- [150] E. Talbi, "Metaheuristics : from design to implementation," vol. 74, 2009.
- [151] B. Kordoghli, "Multi-objective scheduling of flow-shop problems in finishing factory using genetic algorithms," *Journal of Textile and Apparel, Technology and Management*, vol. 63, no. 3, pp. 6–10, 2020.
- [152] D. Nurwaha and X. Wang, "Optimization of electrospinning process using intelligent control systems," *Journal of Intelligent and Fuzzy Systems*, vol. 24, no. 3, pp. 593–600, 2013.
- [153] C. Wu and N. B. Chang, "Global strategy for optimizing textile dyeing manufacturing process via ga-based grey nonlinear integer programming," *Computers & Chemical Engineering*, vol. 27, no. 6, pp. 833–854, 2003.
- [154] D. S., G. A. M. A., and B. D., "Yarn engineering using hybrid artificial neural network-genetic algorithm model," *Fibers Polym*, vol. 14, pp. 1220–1226, 2013.
- [155] K. L. Jeyaraj, C. Muralidharan, T. Senthilvelan, and S. G. Deshmukh, "Genetic algorithm based multi-objective optimization of process parameters in color fast finish processes-a textile case study," *Journal of Textile and Apparel, Technology and Management*, vol. 8, no. 3, 2013.
- [156] A. Majumdar, P. Maland, A. Ghosh, and D. Banerjee, "Multi-objective optimization of air permeability and thermal conductivity of knitted fabrics with desired ultraviolet protection," *The Journal of The Textile Institute*, vol. 108, no. 1, pp. 110–116, 2017.
- [157] P. K. Barzoki, M. Vadood, and M. S. Johari, "Multi-objective optimization of rotorcraft compact spinning core-spun yarn properties," *Journal of Textiles and Polymers*, vol. 6, no. 1, pp. 47–53, 2018.
- [158] M. Vadood, P. K. Barzoki, and M. Johari, "Multi objective optimization of rotorcraft compact spinning system using fuzzy-genetic model," *The Journal of The Textile Institute*, vol. 108, no. 12, pp. 2166–2172, 2017.
- [159] J. Chen, Y. Ding, Y. Jin, and K. Hao, "A synergetic immune clonal selection algorithm based multi-objective optimization method for carbon fiber drawing process," *Fibers Polym*, vol. 14, pp. 1722–1730, 2013.
- [160] G. Derringer and R. Suich, "Simultaneous optimization of several response variables," *Journal of quality technology*, vol. 12, no. 4, pp. 214–219, 1980.
- [161] F. A. Arain, A. Tanwari, T. Hussain, and Z. A. Malik, "Multiple response optimization of rotor yarn for strength, unevenness, hairiness and imperfections," *Fibers Polym*, vol. 13, pp. 118–122, 2012.

- [162] M. Saggiomo, M. Kemper, Y. Gloy, and T. Gries, “Weaving machine as cyber-physical production system : Multi-objective self-optimization of the weaving process,” in *2016 IEEE International Conference on Industrial Technology (ICIT)*, 2016, pp. 2084–2089.
- [163] J. Leng, C. Jin, A. Vogl, and H. Liu, “Deep reinforcement learning for a color-batching resequencing problem,” *Journal of Manufacturing Systems*, vol. 56, pp. 175–187, 2020.
- [164] Z. Zhou, X. Li, and R. N. Zare, “Optimizing chemical reactions with deep reinforcement learning,” *ACS Central Science*, vol. 3, no. 12, pp. 1337–1344, 2017.
- [165] Y. G. Kim, S. Lee, J. Son, H. Bae, and C. B. Do, “Multi-agent system and reinforcement learning approach for distributed intelligence in a flexible smart manufacturing system,” *Journal of Manufacturing Systems*, vol. 57, pp. 440–450, 2020.
- [166] P. Mannion, K. Mason, S. Devlin, and J. Duggan, “Multi-objective dynamic dispatch optimisation using multi-agent reinforcement learning,” in *Proceedings of the 2016 International Conference on Autonomous Agents & Multiagent Systems*, 2016, pp. 1345–1346.
- [167] J. Hu and M. P. Wellman, “Multiagent reinforcement learning : Theoretical framework and an algorithm,” in *ICML*, 1998.
- [168] B. Waschneck, A. Reichstaller, L. Belzner, T. Altenmüller, T. Bauernhansl, A. Knapp, and A. Kyek, “Optimization of global production scheduling with deep reinforcement learning,” *Procedia Cirp*, vol. 72, pp. 1264–1269, 2018.
- [169] V. Mnih, K. Kavukcuoglu, D. Silver, A. Graves, I. Antonoglou, D. Wierstra, and M. A. Riedmiller, “Playing atari with deep reinforcement learning,” *CoRR*, vol. abs/1312.5602, 2013.
- [170] J. K. Gupta, M. Egorov, and M. J. Kochenderfer, “Cooperative multi-agent control using deep reinforcement learning,” in *AAMAS Workshops*, 2017.
- [171] A. Tampuu, T. Matiisen, D. Kodelja, I. Kuzovkin, and K. A. Korjus, “Multiagent cooperation and competition with deep reinforcement learning,” *PLoS One*, vol. 12, p. e0172395, 2017.
- [172] H. P. Leal, B. Kartal, and M. E. Taylor, “A survey and critique of multiagent deep reinforcement learning,” *Autonomous Agents and Multi-Agent Systems*, vol. 33, no. 6, pp. 750–797, Oct 2019.
- [173] Y. Wang, H. Liu, W. Zheng, Y. Xia, Y. Li, P. Chen, K. Guo, and H. Xie, “Multi-objective workflow scheduling with deep-q-network-based multi-agent reinforcement learning,” *IEEE Access*, vol. 7, pp. 39 974–39 982, 2019.
- [174] H. Zhang, S. Feng, C. Liu, Y. Ding, Y. Zhu, Z. Zhou, W. Zhang, Y. Yu, H. Jin, and Z. Li, “Cityflow : A multi-agent reinforcement learning environment for large scale city traffic scenario,” *CoRR*, vol. abs/1905.05217, 2019. [Online]. Available : <http://arxiv.org/abs/1905.05217>
- [175] R. R., O. J., and P. R., “IntegratedMRF : random forest-based framework for integrating prediction from different data types,” *Bioinformatics*, vol. 33, no. 9, pp. 1407–1410, 02 2017.

- [176] A. Greenwaldm and K. B. Hallm, “Correlated q-learning,” in *ICML*, 2003.
- [177] Z. He, K. Tran, S. Thomassey, X. Zeng, J. Xu, and C. Haiyi, “A deep reinforcement learning based multi-criteria decision support system for textile manufacturing process optimization,” 2020.
- [178] M. Li, Z. He, and J. Xu, “A comparative study of ozonation on aqueous reactive dyes and reactive-dyed cotton,” *Coloration Technology*, vol. 137, no. 4, pp. 376–388, 2021.
- [179] C. Cie, *Ink jet textile printing*. Elsevier, 2015.
- [180] A. Agarwal, M. Abadi, M. Barhamand, and P. Brevdo, “Tensorflow : Large-scale machine learning on heterogeneous distributed systems,” 2015.
- [181] R. Poli, J. Kennedy, and T. Blackwell, “Particle swarm optimization,” *Swarm intelligence*, vol. 1, no. 1, pp. 33–57, 2007.
- [182] A. Konak, D. W. Coit, and A. E. Smith, “Multi-objective optimization using genetic algorithms : A tutorial,” *Reliability Engineering & System Safety*, vol. 91, no. 9, pp. 992–1007, 2006, special Issue - Genetic Algorithms and Reliability.
- [183] C. Giri, S. Jain, X. Zeng, and P. Bruniaux, “A detailed review of artificial intelligence applied in the fashion and apparel industry,” *IEEE Access*, vol. 7, pp. 95 376–95 396, 2019.
- [184] L. C. Zimmer, C. Poppe, and L. Karger, “Estimating optimum process parameters in textile draping of variable part geometries - a reinforcement learning approach,” *Procedia manufacturing*, vol. 47, pp. 847–854, 2020.
- [185] Z. Chourabi, F. Khedher, A. Babay, and M. Cheikhrouhou, “Multi-criteria decision making in workforce choice using ahp, wsm and wpm,” *The Journal of The Textile Institute*, vol. 110, no. 7, pp. 1092–1101, 2019.
- [186] A. Majumdar, S. Kaplan, and O. Goktepe, “Navel selection for rotor spinning denim fabrics using a multi-criteria decision-making process,” *The Journal of The Textile Institute*, vol. 101, no. 4, pp. 304–309, 2010.
- [187] Z. He, K. P. Tran, S. Thomassey, X. Zeng, C. Yi *et al.*, “Application of artificial intelligence in modeling a textile finishing process,” in *Reliability and Statistical Computing*. Springer, Cham, 2020, pp. 61–84.
- [188] Z. He, K.-p. Tran, S. Thomassey, X. Zeng, and C. Yi, “A reinforcement learning based decision support system in textile manufacturing process,” in *Developments of Artificial Intelligence Technologies in Computation and Robotics : Proceedings of the 14th International FLINS Conference (FLINS 2020)*. World Scientific, 2020, pp. 550–557.
- [189] K. . P. Tran, Ed., *Machine Learning and Probabilistic Graphical Models for Decision Support Systems*. Taylor & Francis, CRC Press, 2022.
- [190] A. Acharya, S. K. Singh, V. Pereira, and P. Singh, “Big data, knowledge co-creation and decision making in fashion industry,” *International Journal of Information Management*, vol. 42, pp. 90–101, 2018.
- [191] H. Y. Chen, A. Das, and D. Ivanov, “Building resilience and managing post-disruption supply chain recovery : Lessons from the information and communication technology industry,” *International Journal of Information Management*, vol. 49, pp. 330–342, 2019.

- [192] A. Dolgui, D. Ivanov, S. Potryasaev, B. Sokolov, M. Ivanova, and F. Werner, "Blockchain-oriented dynamic modelling of smart contract design and execution in the supply chain," *International Journal of Production Research*, vol. 58, no. 7, pp. 2184–2199, 2020.
- [193] S. Hosseini, D. Ivanov, and A. Dolgui, "Review of quantitative methods for supply chain resilience analysis," *Transportation Research Part E : Logistics and Transportation Review*, vol. 125, pp. 285–307, 2019.
- [194] D. Ivanov and A. Dolgui, "A digital supply chain twin for managing the disruption risks and resilience in the era of industry 4.0," *Production Planning & Control*, pp. 1–14, 2020.
- [195] D. Ivanov, A. Dolgui, and B. Sokolov, "The impact of digital technology and industry 4.0 on the ripple effect and supply chain risk analytics," *International Journal of Production Research*, vol. 57, no. 3, pp. 829–846, 2019.
- [196] L. Bontemps, J. McDermott, and N.-A. Le-Khac, "Collective anomaly detection based on long short-term memory recurrent neural networks," in *International Conference on Future Data and Security Engineering*. Springer, 2016, pp. 141–152.
- [197] P. Malhotra, L. Vig, G. Shroff, and P. Agarwal, "Long short term memory networks for anomaly detection in time series," in *Proceedings*, vol. 89. Presses universitaires de Louvain, 2015, pp. 89–94.
- [198] P. Malhotra, A. Ramakrishnan, G. Anand, L. Vig, P. Agarwal, and G. Shroff, "Lstm-based encoder-decoder for multi-sensor anomaly detection," *arXiv preprint arXiv :1607.00148*, 2016.
- [199] B. Schölkopf, J. C. Platt, J. Shawe-Taylor, A. J. Smola, and R. C. Williamson, "Estimating the support of a high-dimensional distribution," *Neural computation*, vol. 13, no. 7, pp. 1443–1471, 2001.
- [200] W. Zhao, W. Dai, and S. Zhou, "Outlier detection in cold-chain logistics temperature monitoring," *Elektronika ir Elektrotechnika*, vol. 19, no. 3, pp. 65–68, 2013.
- [201] F. A. Roesch and P. C. Van Deusen, "Anomaly detection for analysis of annual inventory data : A quality control approach," *Southern Journal of Applied Forestry*, vol. 34, no. 3, pp. 131–137, 2010.
- [202] G. Alfian, M. Syafrudin, and J. Rhee, "Real-time monitoring system using smartphone-based sensors and nosql database for perishable supply chain," *Sustainability*, vol. 9, no. 11, p. 2073, 2017.
- [203] M. Sharma and M. Singh, "Outlier detection in rfid datasets in supply chain process : A review," *International Journal of Computer Applications*, vol. 65, no. 25, 2013.
- [204] S. P. Huang and D. Wang, "Research on supply chain abnormal event detection based on the rfid technology," in *Applied Mechanics and Materials*, vol. 513. Trans Tech Publ, 2014, pp. 3309–3312.
- [205] R. A. A. Habeeb, F. Nasaruddin, A. Gani, I. A. T. Hashem, E. Ahmed, and M. Imran, "Real-time big data processing for anomaly detection : A survey," *International Journal of Information Management*, vol. 45, pp. 289–307, 2019.
- [206] R. Chalapathy and S. Chawla, "Deep learning for anomaly detection : A survey," *arXiv preprint arXiv :1901.03407*, 2019.

- [207] G. P. Zhang, “Time series forecasting using a hybrid arima and neural network model,” *Neurocomputing*, vol. 50, pp. 159–175, 2003.
- [208] R. Carbonneau, K. Laframboise, and R. Vahidov, “Application of machine learning techniques for supply chain demand forecasting,” *European Journal of Operational Research*, vol. 184, no. 3, pp. 1140–1154, 2008.
- [209] H. Maqsood, I. Mehmood, M. Maqsood, M. Yasir, S. Afzal, F. Aadil, M. M. Selim, and K. Muhammad, “A local and global event sentiment based efficient stock exchange forecasting using deep learning,” *International Journal of Information Management*, vol. 50, pp. 432–451, 2020.
- [210] R. Yang, L. Yu, Y. Zhao, H. Yu, G. Xu, Y. Wu, and Z. Liu, “Big data analytics for financial market volatility forecast based on support vector machine,” *International Journal of Information Management*, vol. 50, pp. 452–462, 2020.
- [211] S. Siami-Namini, N. Tavakoli, and A. S. Namin, “A comparison of arima and lstm in forecasting time series,” in *2018 17th IEEE International Conference on Machine Learning and Applications (ICMLA)*. IEEE, 2018, pp. 1394–1401.
- [212] B. Lim and S. Zohren, “Time series forecasting with deep learning : A survey,” *arXiv preprint arXiv :2004.13408*, 2020.
- [213] T. Xia, Y. Song, Y. Zheng, E. Pan, and L. Xi, “An ensemble framework based on convolutional bi-directional lstm with multiple time windows for remaining useful life estimation,” *Computers in Industry*, vol. 115, p. 103182, 2020.
- [214] K. Deng, X. Zhang, Y. Cheng, Z. Zheng, F. Jiang, W. Liu, and J. Peng, “A remaining useful life prediction method with long-short term feature processing for aircraft engines,” *Applied Soft Computing*, p. 106344, 2020.
- [215] A. L. Ellefsen, E. Bjørlykhaug, V. Æsøy, S. Ushakov, and H. Zhang, “Remaining useful life predictions for turbofan engine degradation using semi-supervised deep architecture,” *Reliability Engineering & System Safety*, vol. 183, pp. 240–251, 2019.
- [216] S. Thomassey, “Sales forecasting in apparel and fashion industry : A review,” in *Intelligent fashion forecasting systems : Models and applications*. Springer, 2014, pp. 9–27.
- [217] —, “Sales forecasts in clothing industry : The key success factor of the supply chain management,” *International Journal of Production Economics*, vol. 128, no. 2, pp. 470–483, 2010.
- [218] R. Sirovich, G. Craparotta, and E. Marocco, “An intelligent fashion replenishment system based on data analytics and expert judgment,” in *Artificial Intelligence for Fashion Industry in the Big Data Era*. Springer, 2018, pp. 173–195.
- [219] M. L. Wang, “Advanced multivariate time series forecasting models,” *Journal of Mathematics and Statistics*, no. 14, pp. , 253–260, 2018.
- [220] B. S. Freeman, G. Taylor, B. Gharabaghi, and J. Thé, “Forecasting air quality time series using deep learning,” *Journal of the Air & Waste Management Association*, vol. 68, no. 8, pp. 866–886, 2018.
- [221] A. Saxena and K. Goebel, “C-mapss data set,” *NASA Ames Prognostics Data Repository*, 2008.

- [222] S. Rita, T. Kim-Phuc, and T. Sébastien, “Long term demand forecasting system for demand driven manufacturing,” in *IFIP International Conference on Advances in Production Management Systems*. Springer, 2021, pp. 13–20.
- [223] H. Haddadpajouh and R. Parizi, “A survey on internet of things security : Requirements, challenges, and solutions,” *Internet of Things*, p. 100129, 11 2019.
- [224] Y. Lu, X. Xu, and L. Wang, “Smart manufacturing process and system automation – a critical review of the standards and envisioned scenarios,” *Journal of Manufacturing Systems*, vol. 56, pp. 312–325, 2020.
- [225] J. Wang, Y. Ma, L. Zhang, R. X. Gao, and D. Wu, “Deep learning for smart manufacturing : Methods and applications,” *Journal of Manufacturing Systems*, vol. 48, pp. 144–156, 2018.
- [226] N. Tuptuk and S. Hailes, “Security of smart manufacturing systems,” *Journal of Manufacturing Systems*, vol. 47, pp. 93–106, 2018.
- [227] M. A. Amanullah, R. A. Ariyaluran Habeeb, F. Nasaruddin, A. Gani, E. Ahmed, A. Nainar, N. Akim, and M. Imran, “Deep learning and big data technologies for iot security,” *Computer Communications*, vol. 151, 02 2020.
- [228] D. Myers, S. Suriadi, K. Radke, and E. Foo, “Anomaly detection for industrial control systems using process mining,” *Computers & Security*, vol. 78, pp. 103–125, 2018.
- [229] P. Nader, P. Honeine, and P. Beuseroy, “ l_p -norms in one-class classification for intrusion detection in scada systems,” *IEEE Transactions on Industrial Informatics*, vol. 10, no. 4, pp. 2308–2317, 2014.
- [230] A. Gumaiei, M. M. Hassan, S. Huda, M. R. Hassan, D. Camacho, J. Del Ser, and G. Fortino, “A robust cyberattack detection approach using optimal features of scada power systems in smart grids,” *Applied Soft Computing*, vol. 96, p. 106658, 2020.
- [231] P. Priyanga S, K. Krithivasan, P. S, and S. Sriram V S, “Detection of cyberattacks in industrial control systems using enhanced principal component analysis and hypergraph-based convolution neural network (epca-hg-cnn),” *IEEE Transactions on Industry Applications*, vol. 56, no. 4, pp. 4394–4404, 2020.
- [232] G. Li, Y. Shen, P. Zhao, X. Lu, J. Liu, Y. Liu, and S. C. Hoi, “Detecting cyberattacks in industrial control systems using online learning algorithms,” *Neurocomputing*, vol. 364, pp. 338–348, 2019.
- [233] D. Li, K. Paynabar, and N. Gebraeel, “A degradation-based detection framework against covert cyberattacks on scada systems,” *IISE Transactions*, vol. 53, no. 7, pp. 812–829, 2021.
- [234] M. Kravchik and A. Shabtai, “Efficient cyber attack detection in industrial control systems using lightweight neural networks and pca,” *IEEE Transactions on Dependable and Secure Computing*, pp. 1–1, 2021.
- [235] F. Adamsky, M. Aubigny, F. Battisti, M. Carli, F. Cimorelli, T. Cruz, A. Di Giorgio, C. Foglietta, A. Galli, A. Giuseppi, F. Liberati, A. Neri, S. Panziera, F. Pascucci, J. Proenca, P. Pucci, L. Rosa, and R. Soua, “Integrated protection of industrial control systems from cyber-attacks : the atena approach,” *International Journal of Critical Infrastructure Protection*, vol. 21, pp. 72–82, 2018.

- [236] R. F. Babiceanu and R. Seker, “Cyber resilience protection for industrial internet of things : A software-defined networking approach,” *Computers in Industry*, vol. 104, pp. 47–58, 2019.
- [237] Y. Xiao, H. Wang, L. Zhang, and W. Xu, “Two methods of selecting Gaussian kernel parameters for one-class SVM and their application to fault detection,” *Knowledge-Based Systems*, vol. 59, pp. 75–84, 2014.
- [238] V. V. Trinh, K. P. Tran, and T. H. Truong, “Data-driven hyperparameter optimization of one-class support vector machines for anomaly detection in wireless sensor networks,” in *2017 International Conference on Advanced Technologies for Communications (ATC)*, Oct 2017, pp. 6–10.
- [239] P. Buonadonna, D. Gay, J. M. Hellerstein, W. Hong, and S. Madden, “TASK : Sensor network in a box,” *Proceedings of the Second European Workshop on Wireless Sensor Networks, EWSN 2005*, vol. 2005, pp. 133–144, 2005.
- [240] C.-C. Chang and C.-J. Lin, “LIBSVM : A library for support vector machines,” *ACM Transactions on Intelligent Systems and Technology*, vol. 2, no. 3, pp. 1–27, 2011.
- [241] Q. T. Nguyen, K. P. Tran, P. Castagliola, T. T. Huong, M. K. Nguyen, and S. Lardjane, “Nested one-class support vector machines for network intrusion detection,” in *2018 IEEE Seventh International Conference on Communications and Electronics (ICCE)*. IEEE, 2018, pp. 7–12.
- [242] K. P. Tran, A. T. Mai *et al.*, “Anomaly detection in wireless sensor networks via support vector data description with mahalanobis kernels and discriminative adjustment,” in *2017 4th NAFOSTED Conference on Information and Computer Science*. IEEE, 2017, pp. 7–12.
- [243] N. Tracy, J. Young, and R. Mason, “Multivariate control charts for individual observations,” *Journal of Quality Technology*, vol. 24, no. 2, pp. 88–95, 1992.
- [244] C. Everett, “Credit card fraud funds terrorism,” *Computer Fraud & Security*, vol. 2003, no. 5, p. 1, 2003.
- [245] T. Bhatla, V. Prabhu, and A. Dua, “Understanding credit card frauds,” *Cards business review*, vol. 1, no. 6, 2003.
- [246] A. Dal Pozzolo, G. Boracchi, O. Caelen, C. Alippi, and G. Bontempi, “Credit card fraud detection and concept-drift adaptation with delayed supervised information,” in *2015 International Joint Conference on Neural Networks (IJCNN)*. IEEE, 2015.
- [247] T. H. Truong, P. B. Ta, Q. T. Nguyen, H. Du Nguyen, and K. P. Tran, “A data-driven approach for network intrusion detection and monitoring based on kernel null space,” in *International Conference on Industrial Networks and Intelligent Systems*. Springer, 2019, pp. 130–140.
- [248] P. Bodesheim, A. Freytag, E. Rodner, M. Kemmler, and J. Denzler, “Kernel null space methods for novelty detection,” in *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 2013, pp. 3374–3381.
- [249] P. Bodesheim, A. Freytag, E. Rodner, and J. Denzler, “Local novelty detection in multi-class recognition problems,” in *Applications of Computer Vision (WACV), 2015 IEEE Winter Conference on*. IEEE, 2015, pp. 813–820.

- [250] T. H. Truong, P. B. Ta, M. L. Dao, D. T. Bui, T. B. Nguyen, D. L. Tran, and K. P. Tran, “Lockedge : Low-complexity cyberattack detection in iot edge computing,” *IEEE Access*, vol. 9, pp. 29 696–29 710, 2021.
- [251] B. McMahan, E. Moore, D. Ramage, S. Hampson, and B. A. y Arcas, “Communication-efficient learning of deep networks from decentralized data,” in *Proceedings of the 20th International Conference on Artificial Intelligence and Statistics*, ser. Proceedings of Machine Learning Research, vol. 54. Fort Lauderdale, FL, USA : PMLR, 20–22 Apr 2017, pp. 1273–1282.
- [252] D. P. Kingma and M. Welling, “Auto-encoding variational bayes,” 2014.
- [253] S. Lin, R. Clark, R. Birke, S. Schönborn, N. Trigoni, and S. Roberts, “Anomaly detection for time series using vae-lstm hybrid model,” in *ICASSP 2020 - 2020 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, 2020, pp. 4322–4326.
- [254] S. J. Sheather and J. S. Marron, “Kernel quantile estimators,” *Journal of the American Statistical Association*, vol. 85, no. 410, pp. 410–416, 1990.
- [255] I. P. Turnipseed, “A new scada dataset for intrusion detection research,” 2015.
- [256] E. Keogh, J. Lin, and A. Fu, “Hot sax : efficiently finding the most unusual time series subsequence,” in *Fifth IEEE International Conference on Data Mining (ICDM’05)*, 2005, pp. 8 pp.–.
- [257] “Nyc taxi and limousine commission,” Last accessed on May, 2021. [Online]. Available : <https://www1.nyc.gov/site/tlc/about/tlc-trip-record-data.page>
- [258] [Online]. Available : <https://docs.emqx.io/en/broker/v4.3/>
- [259] M. Marjani, F. Nasaruddin, A. Gani, A. Karim, I. A. T. Hashem, A. Siddiq, and I. Yaqoob, “Big IoT data analytics : architecture, opportunities, and open research challenges,” *iee access*, vol. 5, pp. 5247–5261, 2017.
- [260] D. Mourtzis, E. Vlachou, and N. Milas, “Industrial big data as a result of IoT adoption in manufacturing,” *Procedia CIRP*, vol. 55, pp. 290–295, 2016.
- [261] M. Mohammadi, A. Al-Fuqaha, S. Sorour, and M. Guizani, “Deep learning for IoT big data and streaming analytics : A survey,” *IEEE Communications Surveys & Tutorials*, vol. 20, no. 4, pp. 2923–2960, 2018.
- [262] J. W. Shavlik, T. Dietterich, and T. G. Dietterich, *Readings in Machine Learning*. Morgan Kaufmann, 1990.
- [263] A. Esteva, A. Robicquet, B. Ramsundar, V. Kuleshov, M. DePristo, K. Chou, C. Cui, G. Corrado, S. Thrun, and J. Dean, “A guide to deep learning in healthcare,” *Nature Medicine*, vol. 25, no. 1, pp. 24–29, 2019.
- [264] A. M. Ozbayoglu, M. U. Gudelek, and O. B. Sezer, “Deep learning for financial applications : A survey,” *Applied Soft Computing*, pp. 106 384 :1–106 384 :29, 2020.
- [265] A. Kamilaris and F. X. Prenafeta-Boldú, “Deep learning in agriculture : A survey,” *Computers and electronics in agriculture*, vol. 147, pp. 70–90, 2018.
- [266] M. Z. Hossain, F. Sohel, M. F. Shiratuddin, and H. Laga, “A comprehensive survey of deep learning for image captioning,” *ACM Computing Surveys*, vol. 51, no. 6, pp. 118 :1–118 :36, 2019.

- [267] T. Georgiou, Y. Liu, W. Chen, and M. Lew, “A survey of traditional and deep learning-based feature descriptors for high dimensional data in computer vision,” *International Journal of Multimedia Information Retrieval*, vol. 9, no. 3, pp. 135–170, 2020.
- [268] R. Miotto, F. Wang, S. Wang, X. Jiang, and J. T. Dudley, “Deep learning for healthcare : review, opportunities and challenges,” *Briefings in Bioinformatics*, vol. 19, no. 6, pp. 1236–1246, 2018.
- [269] V. Kumar and M. Garg, “Deep learning in predictive analytics : A survey,” in *Proceedings of the 2017 International Conference on Emerging Trends in Computing and Communication Technologies*. IEEE, 2017.
- [270] Z. Ji, Z. C. Lipton, and C. Elkan, “Differential privacy and machine learning : a survey and review,” 2014. [Online]. Available : <https://arxiv.org/abs/1412.7584>
- [271] L. Van Zoonen, “Privacy concerns in smart cities,” *Government Information Quarterly*, vol. 33, no. 3, pp. 472–480, 2016.
- [272] J. Konečný, H. B. McMahan, D. Ramage, and P. Richtárik, “Federated optimization : Distributed machine learning for on-device intelligence,” arXiv preprint arXiv :1610.02527, 2016. [Online]. Available : <https://arxiv.org/abs/1610.02527>
- [273] D. Gunning and D. Aha, “DARPA’s explainable artificial intelligence (XAI) program,” *AI Magazine*, vol. 40, no. 2, pp. 44–58, 2019.
- [274] W. Samek, T. Wiegand, and K.-R. Müller, “Explainable artificial intelligence : Understanding, visualizing and interpreting deep learning models,” 2017. [Online]. Available : <https://arxiv.org/abs/1708.08296>
- [275] J. Choo and S. Liu, “Visual analytics for explainable deep learning,” *IEEE Computer Graphics and Applications*, vol. 38, no. 4, pp. 84–92, 2018.
- [276] S. Mousavi, F. Afghah, and U. R. Acharya, “HAN-ECG : An interpretable atrial fibrillation detection model using hierarchical attention networks,” *Computers in Biology and Medicine*, vol. 127, pp. 104 057 :1–104 057 :9, 2020.
- [277] R. R. Selvaraju, A. Das, R. Vedantam, M. Cogswell, D. Parikh, and D. Batra, “Grad-CAM : Why did you say that?” 2016. [Online]. Available : <https://arxiv.org/abs/1611.07450>
- [278] B. Pyakillya, N. Kazachenko, and N. Mikhailovsky, “Deep learning for ECG classification,” in *Journal of Physics : Conference Series*, vol. 913. IOP Publishing, 2017, pp. 012 004 :1–012 004 :5.
- [279] S. M. Mathews, C. Kambhamettu, and K. E. Barner, “A novel application of deep learning for single-lead ECG classification,” *Computers in Biology and Medicine*, vol. 99, pp. 53–62, 2018.
- [280] F. Murat, O. Yildirim, M. Talo, U. B. Baloglu, Y. Demir, and U. R. Acharya, “Application of deep learning techniques for heartbeats detection using ECG signals-analysis and review,” *Computers in biology and medicine*, pp. 103 726 :1–103 726 :14, 2020.
- [281] Y. Chen, X. Qin, J. Wang, C. Yu, and W. Gao, “Fedhealth : A federated transfer learning framework for wearable healthcare,” *IEEE Intelligent Systems*, vol. 35, no. 4, pp. 83–93, 2020.

- [282] S. L. Oh, E. Y. Ng, R. San Tan, and U. R. Acharya, “Automated diagnosis of arrhythmia using combination of CNN and LSTM techniques with variable length heart beats,” *Computers in biology and medicine*, vol. 102, pp. 278–287, 2018.
- [283] S. Liaqat, K. Dashtipour, A. Zahid, K. Assaleh, K. Arshad, and N. Ramzan, “Detection of atrial fibrillation using a machine learning approach,” *Information*, vol. 11, no. 12, pp. 549 :1–549 :15, 2020.
- [284] U. Erdenebayar, H. Kim, J.-U. Park, D. Kang, and K.-J. Lee, “Automatic prediction of atrial fibrillation based on convolutional neural network using a short-term normal electrocardiogram signal,” *Journal of Korean medical science*, vol. 34, no. 7, pp. e64 :1–e64 :10, 2019.
- [285] D. K. Atal and M. Singh, “Arrhythmia classification with ECG signals based on the optimization-enabled deep convolutional neural network,” *Computer Methods and Programs in Biomedicine*, vol. 196, pp. 105 607 :1–105 607 :19, 2020.
- [286] G. B. Moody and R. G. Mark, “The impact of the MIT-BIH Arrhythmia Database,” *IEEE Engineering in Medicine and Biology Magazine*, vol. 20, no. 3, pp. 45–50, 2001.
- [287] Z. Yang, M. Ghadamyari, H. Khorramdel, S. M. S. Alizadeh, S. Pirouzi, M. Milani, F. Banihashemi, and N. Ghadimi, “Robust multi-objective optimal design of islanded hybrid system with renewable and diesel sources/stationary and mobile energy storage systems,” *Renewable and Sustainable Energy Reviews*, vol. 148, p. 111295, 2021.
- [288] J. Liu, C. Chen, Z. Liu, K. Jermsittiparsert, and N. Ghadimi, “An igdt-based risk-involved optimal bidding strategy for hydrogen storage-based intelligent parking lot of electric vehicles,” *Journal of Energy Storage*, vol. 27, p. 101057, 2020.
- [289] P. Angelov, D. P. Filev, and N. Kasabov, *Evolving intelligent systems : methodology and applications*. John Wiley & Sons, 2010, vol. 12.
- [290] A. Handa, A. Sharma, and S. K. Shukla, “Machine learning in cybersecurity : A review,” *Wiley Interdisciplinary Reviews : Data Mining and Knowledge Discovery*, vol. 9, no. 4, p. e1306, 2019.
- [291] H. Storm, K. Baylis, and T. Heckelei, “Machine learning in agricultural and applied economics,” *European Review of Agricultural Economics*, vol. 47, no. 3, pp. 849–892, 2020.
- [292] K. Shailaja, B. Seetharamulu, and M. Jabbar, “Machine learning in healthcare : A review,” in *2018 Second international conference on electronics, communication and aerospace technology (ICECA)*. IEEE, 2018, pp. 910–914.
- [293] N. Razmjooy, F. R. Sheykhahmad, and N. Ghadimi, “A hybrid neural network–world cup optimization algorithm for melanoma detection,” *Open Medicine*, vol. 13, no. 1, pp. 9–16, 2018.
- [294] A. Parsian, M. Ramezani, and N. Ghadimi, “A hybrid neural network–gray wolf optimization algorithm for melanoma detection.” *Biomedical Research (0970-938X)*, vol. 28, no. 8, 2017.
- [295] Z. Xu, F. R. Sheykhahmad, N. Ghadimi, and N. Razmjooy, “Computer-aided diagnosis of skin cancer based on soft computing techniques,” *Open Medicine*, vol. 15, no. 1, pp. 860–871, 2020.

- [296] K. Kourou, T. P. Exarchos, K. P. Exarchos, M. V. Karamouzis, and D. I. Fotiadis, "Machine learning applications in cancer prognosis and prediction," *Computational and structural biotechnology journal*, vol. 13, pp. 8–17, 2015.
- [297] H. H. Atkinson, C. Rosano, E. M. Simonsick, J. D. Williamson, C. Davis, W. T. Ambrosius, S. R. Rapp, M. Cesari, A. B. Newman, T. B. Harris, S. M. Rubin, K. Yaffe, S. Satterfield, and S. B. Kritchevsky, "Cognitive function, gait speed decline, and comorbidities : the health, aging and body composition study," *The Journals of Gerontology Series A : Biological Sciences and Medical Sciences*, vol. 62, no. 8, pp. 844–850, 2007.
- [298] Y. Chen, J. Wang, M. Huang, and H. Yu, "Cross-position activity recognition with stratified transfer learning," *Pervasive and Mobile Computing*, vol. 57, pp. 1–13, 2019.
- [299] S. C. Mukhopadhyay, "Wearable sensors for human activity monitoring : A review," *IEEE sensors journal*, vol. 15, no. 3, pp. 1321–1330, 2014.
- [300] O. D. Lara and M. A. Labrador, "A survey on human activity recognition using wearable sensors," *IEEE Communications Surveys & Tutorials*, vol. 15, no. 3, pp. 1192–1209, 2012.
- [301] R. Bhardwaj, A. R. Nambiar, and D. Dutta, "A study of machine learning in healthcare," in *Proceedings of the 2017 IEEE 41st Annual Computer Software and Applications Conference*, vol. 2. IEEE, 2017, pp. 236–241.
- [302] G. Manogaran and D. Lopez, "A survey of big data architectures and machine learning algorithms in healthcare," *International Journal of Biomedical Engineering and Technology*, vol. 25, no. 2-4, pp. 182–211, 2017.
- [303] R. Fakoor, F. Ladhak, A. Nazi, and M. Huber, "Using deep learning to enhance cancer diagnosis and classification," *Proceedings of the WHEALTH Workshop at the 30th International Conference on Machine Learning*, vol. 28, 2013.
- [304] S. H. Jambukia, V. K. Dabhi, and H. B. Prajapati, "Classification of ECG signals using machine learning techniques : A survey," in *Proceedings of the 2015 International Conference on Advances in Computer Engineering and Applications*. IEEE, 2015, pp. 714–721.
- [305] C. Roopa and B. Harish, "A survey on various machine learning approaches for ECG analysis," *International Journal of Computer Applications*, vol. 163, no. 9, pp. 25–33, 2017.
- [306] S. Sahoo, M. Dash, S. Behera, and S. Sabut, "Machine learning approach to detect cardiac arrhythmias in ECG signals : A survey," *IRBM*, pp. 185–194, 2020.
- [307] J. Rubin, R. Abreu, A. Ganguli, S. Nelaturi, I. Matei, and K. Sricharan, "Recognizing abnormal heart sounds using deep learning," 2017. [Online]. Available : <https://arxiv.org/abs/1707.04642>
- [308] M. Gjoreski, A. Gradišek, B. Budna, M. Gams, and G. Poglajen, "Machine learning and end-to-end deep learning for the detection of chronic heart failure from heart sounds," *IEEE Access*, vol. 8, pp. 20 313–20 324, 2020.
- [309] J.-S. Huang, B.-Q. Chen, N.-Y. Zeng, X.-C. Cao, and Y. Li, "Accurate classification of ECG arrhythmia using MOWPT enhanced fast compression deep learning networks," *Journal of Ambient Intelligence and Humanized Computing*, 2020.

- [310] N. Inkster, *China's Cyber Power*. The International Institute for Strategic Studies, 2018. [Online]. Available : <https://www.iiss.org/publications/adelphi/2016/chinas-cyber-power>
- [311] B. Liu, M. Ding, S. Shaham, W. Rahayu, F. Farokhi, and Z. Lin, "When machine learning meets privacy : A survey and outlook," *ACM Computing Surveys*, vol. 54, no. 2, pp. 31 :1–31 :36, 2021.
- [312] N. Waheed, X. He, M. Ikram, M. Usman, S. S. Hashmi, and M. Usman, "Security and privacy in IoT using machine learning and blockchain : Threats and countermeasures," *ACM Computing Surveys (CSUR)*, vol. 53, no. 6, pp. 122 :1–122 :37, 2020.
- [313] Q. Yang, Y. Liu, T. Chen, and Y. Tong, "Federated machine learning : Concept and applications," *ACM Transactions on Intelligent Systems and Technology*, vol. 10, no. 2, pp. 12 :1–12 :19, 2019.
- [314] J. Xu, B. S. Glicksberg, C. Su, P. Walker, J. Bian, and F. Wang, "Federated learning for healthcare informatics," *Journal of Healthcare Informatics Research*, vol. 5, no. 1, pp. 1–19, 2021.
- [315] P. Huang, G. Wang, and S. Qin, "Boosting for transfer learning from multiple data sources," *Pattern Recognition Letters*, vol. 33, no. 5, pp. 568–579, 2012.
- [316] X. Qin, Y. Chen, J. Wang, and C. Yu, "Cross-dataset activity recognition via adaptive spatial-temporal transfer learning," *Proceedings of the ACM on Interactive, Mobile, Wearable and Ubiquitous Technologies*, vol. 3, no. 4, pp. 148 :1–148 :25, 2019.
- [317] R. Yilmazer and D. Birant, "Shelf auditing based on image classification using semi-supervised deep learning to increase on-shelf availability in grocery stores," *Sensors*, vol. 21, no. 2, p. 327, 2021.
- [318] F. K. Došilović, M. Brčić, and N. Hlupić, "Explainable artificial intelligence : A survey," in *Proceedings of the 2018 41st International Convention on Information and Communication Technology, Electronics and Microelectronics*. IEEE, 2018, pp. 210–215.
- [319] R. Assaf, I. Giurgiu, F. Bagehorn, and A. Schumann, "MTEX-CNN : Multivariate time series explanations for predictions with convolutional neural networks," in *Proceedings of the 2019 IEEE International Conference on Data Mining*. IEEE, 2019, pp. 952–957.
- [320] H. B. McMahan, E. Moore, D. Ramage, S. Hampson, and B. A. y Arcas, "Communication-efficient learning of deep networks from decentralized data," in *Proceedings of the 20th International Conference on Artificial Intelligence and Statistics (AISTATS) 2017*. JMLR, 2017, pp. 1273–1282.
- [321] V. Smith, C.-K. Chiang, M. Sanjabi, and A. Talwalkar, "Federated multi-task learning," *arXiv preprint arXiv :1705.10467*, 2017. [Online]. Available : <https://arxiv.org/abs/1705.10467>
- [322] F. Sattler, S. Wiedemann, K.-R. Müller, and W. Samek, "Robust and communication-efficient federated learning from non-IID data," *IEEE Transactions on Neural Networks and Learning Systems*, vol. 31, no. 9, pp. 3400–3413, 2019.
- [323] S. J. N. B. D. K. E. B. M. S. K. T. M. e. a. Arpit, Devansh, "A closer look at memorization in deep networks," in *Proceedings of the 34th International Conference on Machine Learning*. JMLR, 2017, pp. 233–242.

- [324] Y. H. Hu, S. Palreddy, and W. J. Tompkins, “A patient-adaptable ECG beat classifier using a mixture of experts approach,” *IEEE Transactions on Biomedical Engineering*, vol. 44, no. 9, pp. 891–900, 1997.
- [325] M. B. Conover, *Understanding Electrocardiography*. Elsevier Health Sciences, 2002.
- [326] S. K. Berkaya, A. K. Uysal, E. S. Gunal, S. Ergin, S. Gunal, and M. B. Gulmezoglu, “A survey on ecg analysis,” *Biomedical Signal Processing and Control*, vol. 43, pp. 216–235, 2018.
- [327] U. R. Acharya, H. Fujita, O. S. Lih, Y. Hagiwara, J. H. Tan, and M. Adam, “Automated detection of arrhythmias using different intervals of tachycardia ECG segments with convolutional neural network,” *Information Sciences*, vol. 405, pp. 81–90, 2017.
- [328] Z. Yao, Z. Zhu, and Y. Chen, “Atrial fibrillation detection by multi-scale convolutional neural networks,” in *Proceedings of the 2017 20th International Conference on Information Fusion*. IEEE, 2017.
- [329] S. Nurmaini, A. E. Tondas, A. Darmawahyuni, M. N. Rachmatullah, R. U. Partan, F. Firdaus, B. Tutuko, F. Pratiwi, A. H. Juliano, and R. Khoirani, “Robust detection of atrial fibrillation from short-term electrocardiogram using convolutional neural networks,” *Future Generation Computer Systems*, vol. 113, pp. 304–317, 2020.
- [330] C. Yuan, Y. Yan, L. Zhou, J. Bai, and L. Wang, “Automated atrial fibrillation detection based on deep learning network,” in *Proceedings of the 2016 IEEE International Conference on Information and Automation*. IEEE, 2016, pp. 1159–1164.
- [331] Y. Xia, N. Wulan, K. Wang, and H. Zhang, “Detecting atrial fibrillation by deep convolutional neural networks,” *Computers in Biology and Medicine*, vol. 93, pp. 84–92, 2018.
- [332] H. D. Nguyen, K. P. Tran, X. Zeng, L. Koehl, and G. Tartare, “An improved ensemble machine learning algorithm for wearable sensor data based human activity recognition,” in *Reliability and Statistical Computing*. Springer, 2020, pp. 207–228.
- [333] P. H. Tran, Q. T. Nguyen, K. P. Tran, and C. Heuchenne, “Wearable sensor data based human activity recognition using deep learning : A new approach,” in *Developments of Artificial Intelligence Technologies in Computation and Robotics : Proceedings of the 14th International FLINS Conference (FLINS 2020)*. World Scientific, 2020, pp. 581–588.
- [334] N. Liu and P. Rebentrost, “Quantum machine learning for quantum anomaly detection,” *Physical Review A*, vol. 97, no. 4, Apr 2018.
- [335] K. T. V.V. Trinh and T. Truong., “Data driven hyperparameter optimization of one-class support vector machines for anomaly detection in wireless sensor networks,” in *2017 International Conference on Advanced Technologies for Communications (ATC)*. IEEE, 2017, pp. 6–10.
- [336] J. Wu, S. P. Chen, and X. Liu, “Efficient hyperparameter optimization through model-based reinforcement learning,” *Neurocomputing*, vol. 409, pp. 381–393, 2020.
- [337] Y. Umeda, J. Kaneko, and H. Kikuchi, “Topological data analysis and its application to time-series data analysis,” *Fujitsu Scientific & Technical Journal*, vol. 55, no. 2, pp. 65–71, 2019.

- [338] B. Colosimo and M. Pacella, “A comparison study of control charts for statistical monitoring of functional data,” *International Journal of Production Research*, vol. 48, no. 6, pp. 1575–1601, 2010.
- [339] J. Liu, J. Chen, and D. Wang, “Wavelet functional principal component analysis for batch process monitoring,” *Chemometrics and Intelligent Laboratory Systems*, vol. 196, p. 103897, 2020.
- [340] M. Flores, R. F.-C. S. Naya, S. Zaragoza, P. Raña, and J. Tarrío-Saavedra, “Constructing a control chart using functional data,” *Mathematics*, vol. 8, no. 1, p. 58, 2020.
- [341] G. Yu, C. Zou, and Z. Wang, “Outlier detection in functional observations with applications to profile monitoring,” *Technometrics*, vol. 54, no. 3, pp. 308–318, 2012.
- [342] K. P. Tran, P. Castagliola, and G. Celano, “Monitoring the ratio of population means of a bivariate normal distribution using cusum type control charts,” *Statistical Papers*, vol. 59, no. 1, pp. 387–413, 2018.
- [343] F. Megahed, W. Woodall, and J. Camelio, “A review and perspective on control charting with image data,” *Journal of Quality Technology*, vol. 43, no. 2, pp. 83–98, 2011.
- [344] Z. He, L. Zuo, M. Zhang, and F. Megahed, “An image-based multivariate generalized likelihood ratio control chart for detecting and diagnosing multiple faults in manufactured products,” *International Journal of Production Research*, vol. 54, no. 6, pp. 1771–1784, 2016.
- [345] L. Zuo, Z. He, and M. Zhang, “An ewma and region growing based control chart for monitoring image data,” *Quality Technology & Quantitative Management*, vol. 17, no. 4, pp. 470–485, 2020.
- [346] Y. Okhrin, W. Schmid, and I. Semeniuk, “Monitoring image processes : Overview and comparison study,” in *International Workshop on Intelligent Statistical Quality Control*. Springer, 2019, pp. 143–163.
- [347] —, “New approaches for monitoring image data,” *IEEE Transactions on Image Processing*, vol. 30, pp. 921–933, 2020.
- [348] Y. Yuan and L. Lin, “Self-Supervised Pre-Training of Transformers for Satellite Image Time Series Classification,” *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2020.
- [349] Q. Nguyen, H. Nguyen, K. P. Tran, P. Castagliola, and E. Frénod, “Real-time production monitoring approach for smart manufacturing with artificial intelligence techniques,” in *ISSAT International Conference on Data Science in Business, Finance and Industry*, 2019, pp. 100–103.
- [350] A. C. Choueiri and E. A. P. Santos, “Discovery of path-attribute dependency in manufacturing environments : A process mining approach,” *Journal of Manufacturing Systems*, vol. 61, pp. 54–65, 2021.
- [351] Á. Valencia-Parra, B. Ramos-Gutiérrez, Á. J. Varela-Vaca, M. T. Gómez-López, and A. García Bernal, “Enabling process mining in airbus manufacturing,” in *Business Process Management Cases Vol. 2*. Springer, 2021, pp. 125–138.

- [352] D. Myers, S. Suriadi, K. Radke, and E. Foo, "Anomaly detection for industrial control systems using process mining," *Computers & Security*, vol. 78, pp. 103–125, 2018.
- [353] M. Sanchez, E. Exposito, and J. Aguilar, "Autonomic computing in manufacturing process coordination in industry 4.0 context," *Journal of industrial information integration*, vol. 19, p. 100159, 2020.
- [354] D. Myers, K. Radke, S. Suriadi, and E. Foo, "Process discovery for industrial control system cyber attack detection," in *IFIP International Conference on ICT Systems Security and Privacy Protection*. Springer, 2017, pp. 61–75.
- [355] H. T. C. Nguyen, S. Lee, J. Kim, J. Ko, and M. Comuzzi, "Autoencoders for improving quality of process event logs," *Expert Systems with Applications*, vol. 131, pp. 132–147, 2019.
- [356] B. Xia, J. Yin, J. Xu, and Y. Li, "Loggan : a sequence-based generative adversarial network for anomaly detection based on system logs," in *International Conference on Science of Cyber Security*. Springer, 2019, pp. 61–76.
- [357] L. Xie, D. Pi, X. Zhang, J. Chen, Y. Luo, and W. Yu, "Graph neural network approach for anomaly detection," *Measurement*, vol. 180, p. 109546, 2021.
- [358] G. Vilone and L. Longo, "Notions of explainability and evaluation approaches for explainable artificial intelligence," *Information Fusion*, 2021.
- [359] S. Aggarwal, P. Bhardwaj, and J. Arora, "Ai in fashion : Present and future applications," in *Transforming Management Using Artificial Intelligence Techniques*. CRC Press, 2020, pp. 129–141.
- [360] M. Li and L. Zhao, "Exploring global fashion sustainability practices through dictionary-based text mining," *Clothing and Textiles Research Journal*, p. 0887302X21998268, 2021.
- [361] M. Shi, C. Chussid, P. Yang, M. Jia, V. Dyk Lewis, and W. Cao, "The exploration of artificial intelligence application in fashion trend forecasting," *Textile Research Journal*, p. 004051752111006212, 2021.
- [362] S. S. Banerjee, S. Mohapatra, and G. Saha, "Developing a framework of artificial intelligence for fashion forecasting and validating with a case study," *International Journal of Enterprise Network Management*, vol. 12, no. 2, pp. 165–180, 2021.
- [363] Z. Al-Halah, R. Stiefelhagen, and K. Grauman, "Fashion forward : Forecasting visual style in fashion," in *Proceedings of the IEEE international conference on computer vision*, 2017, pp. 388–397.
- [364] S. Thomassey and X. Zeng, "Introduction : Artificial intelligence for fashion industry in the big data era," in *Artificial intelligence for fashion industry in the big data era*. Springer, 2018, pp. 1–6.
- [365] A. Scerbaka, "Application of make/use platform for sustainable fashion design," in *IOP Conference Series : Materials Science and Engineering*, vol. 827, no. 1. IOP Publishing, 2020, p. 012047.
- [366] Y.-S. Gloy, *Industry 4.0 in Textile Production*. Springer, 2021.

Surveillance, Détection d'Anomalies et Optimisation des Systèmes Industriels avec des Techniques Statistiques et d'Apprentissage Automatique

Résumé : De nos jours, les systèmes industriels, tels que les systèmes de production, les systèmes de contrôle industriel, les réseaux de communication sans fil, les systèmes robotiques et les systèmes de santé, deviennent de plus en plus complexes et de plus en plus connectés à Internet avec la technologie Internet des objets (IoT). Le développement récent des technologies de l'information et de la communication telles que l'IoT et l'intelligence artificielle (IA) pour favoriser l'amélioration continue, le transfert de connaissances et la prise de décision basée sur les données dans de nombreux domaines. Cette thèse présentera systématiquement des contributions en surveillance, détection d'anomalies et optimisation pour les systèmes industriels avec des techniques statistiques et d'apprentissage automatique. Dans un premier temps, nous introduirons des contributions dans le domaine de la surveillance statistique des processus, en particulier des cartes de contrôle avancées développées sur la base de techniques statistiques ainsi que de l'apprentissage automatique. Deuxièmement, des contributions dans le domaine de la modélisation et de l'optimisation de la production en utilisant l'apprentissage par renforcement avec une étude de cas dans la fabrication de textiles seront introduites. Troisièmement, les contributions de la prévision et de la détection d'anomalies à l'aide de techniques d'apprentissage automatique avec des applications dans le domaine de la gestion de la chaîne d'approvisionnement seront examinées avec des données de l'industrie de la mode. Quatrièmement, les recherches sur la sécurité des réseaux avec des techniques de détection d'anomalies seront détaillées avec des applications dans les domaines de la finance, des réseaux de capteurs sans fil, ainsi que des systèmes de contrôle industriels. Ensuite, un système de surveillance du signal électrocardiogramme (ECG) avec des applications dans les systèmes de santé intelligents utilisant des techniques d'apprentissage fédéré explicables sera présenté. Enfin, les conclusions, ainsi que les perspectives sur les futures directions de recherche, seront discutées dans le dernier chapitre de cette thèse.

Mots clés : Surveillance, détection d'anomalies, optimisation, systèmes industriels, carte de contrôle, intelligence artificielle, intelligence artificielle explicable, système d'aide à la décision, apprentissage automatique, apprentissage par renforcement, apprentissage fédéré, optimisation de la fabrication, surveillance ECG, cybersécurité .

Monitoring, Anomaly Detection, and Optimization for Industrial Systems with Statistical and Machine Learning techniques

Abstract : Nowadays, industrial systems, such as production systems, industrial control systems, wireless communication networks, robotic systems, and healthcare systems, are becoming complex and more and more connected to the Internet with the Internet of things (IoT) technology. The recent development of information and communication technologies such as the IoT, and Artificial Intelligence (AI) to drive continuous improvement, knowledge transfer, and data-driven decision-making in many fields. This thesis will systematically present contributions in Monitoring, Anomaly

Detection, and Optimization for Industrial Systems with Statistical and Machine Learning techniques. First, we will introduce contributions in the field of statistical process monitoring, specifically advanced control charts developed based on statistical techniques as well as machine learning. Second, contributions in the field of modeling and optimizing production using reinforcement learning with a case study in textile manufacturing will be introduced. Third, the contributions of forecasting and anomaly detection using machine learning techniques with applications in the field of supply chain management will be examined with data from the fashion industry. Fourth, research on network security with anomaly detection techniques will be detailed with applications in the fields of finance, wireless sensor networks, as well as industrial control systems. Next, an electrocardiogram (ECG) signal monitoring system with applications in smart healthcare systems using explainable federated learning techniques will be introduced. Finally, the conclusions, as well as perspectives on future research directions, will be discussed in the final chapter of this thesis.

Keywords : Monitoring, Anomaly Detection, Optimization, Industrial Systems, Control Chart, Artificial Intelligence, Explainable Artificial Intelligence, Decision Support System, Machine Learning, Reinforcement Learning, Federated Learning, Manufacturing Optimization, Electrocardiogram (ECG) monitoring, Cybersecurity

GEMTEX, ENSAIT, Universtié de Lille
2 All. Louise et Victor Champier, 59100 Roubaix