

Optimisation des politiques de contrôle pour les systèmes de production non fiables par l'analyse des données et le machine learning

par

Mayssen DIDI

MÉMOIRE PRÉSENTÉ À L'ÉCOLE DE TECHNOLOGIE SUPÉRIEURE
COMME EXIGENCE PARTIELLE À L'OBTENTION DE
LA MAÎTRISE AVEC MÉMOIRE EN GÉNIE DE LA PRODUCTION
AUTOMATISÉE
M. Sc. A.

MONTREAL, LE 22 JUILLET 2026

ÉCOLE DE TECHNOLOGIE SUPÉRIEURE
UNIVERSITÉ DU QUÉBEC

© Tous droits réservés

Cette licence signifie qu'il est interdit de reproduire, d'enregistrer ou de diffuser en tout ou en partie, le présent document. Le lecteur qui désire imprimer ou conserver sur un autre media une partie importante de ce document, doit obligatoirement en demander l'autorisation à l'auteur.

PRÉSENTATION DU JURY

CE MÉMOIRE A ÉTÉ ÉVALUÉ

PAR UN JURY COMPOSÉ DE :

M. Ali Gharbi, directeur de mémoire
Département de génie des systèmes à l'École de technologie supérieure

M. Tony Wong, président du jury
Département de génie des systèmes à l'École de technologie supérieure

M. Julio Cesar Montecinos, membre du jury
Département de génie des systèmes à l'École de technologie supérieure

IL A FAIT L'OBJET D'UNE SOUTENANCE DEVANT JURY ET PUBLIC

LE 14 JUILLET 2026

À L'ÉCOLE DE TECHNOLOGIE SUPÉRIEURE

REMERCIEMENTS

Je tiens à exprimer ma profonde gratitude à mon directeur de recherche, le Professeur Ali Gharbi, pour sa disponibilité, sa patience, ses précieux conseils ainsi que son encadrement rigoureux tout au long de ce projet de recherche. Son expertise, sa confiance et son soutien constant ont joué un rôle déterminant dans la réalisation de ce mémoire et dans le développement de mes compétences en recherche.

Je souhaite également remercier les membres du jury pour l'intérêt qu'ils portent à ce travail en acceptant de l'évaluer et d'en apprécier la contribution.

Mes remerciements s'adressent également aux membres du Laboratoire de conception et contrôle des systèmes de production (LC2SP) de l'École de technologie supérieure (ÉTS). Les échanges scientifiques, l'esprit de collaboration ainsi que l'environnement de recherche stimulant du laboratoire ont contribué de manière significative à l'avancement de ce travail.

Enfin, j'adresse mes plus sincères remerciements à ma famille pour son soutien et ses encouragements tout au long de mon parcours académique. Malgré la distance, leur présence constante et leurs sacrifices ont été une source inestimable de motivation et de persévérance.

À toutes les personnes qui, de près ou de loin, ont contribué à la réalisation de ce mémoire, j'adresse ma sincère reconnaissance.

Optimisation des politiques de contrôle pour les systèmes de production non fiables par l'analyse des données et le machine learning

Mayssen DIDI

RÉSUMÉ

Cette recherche porte sur le développement d'une approche combinant simulation, apprentissage automatique et optimisation pour la détermination des paramètres de contrôle de systèmes manufacturiers et fabrication-refabrication soumise à différentes sources d'incertitude, telle que les pannes des machines, la variabilité de la demande et la variabilité des retours de produits. Elle repose sur l'exploitation de données générées par simulation pour l'entraînement de modèles d'apprentissage automatique utilisés dans le processus d'optimisation.

Dans un premier temps, l'approche est développée pour un système manufacturier non fiable de type M1P1 sous demande constante. Une stratégie de construction de la base de données est proposée et utilisée pour l'entraînement des modèles d'apprentissage automatique. L'approche est ensuite étendue à des environnements caractérisés par une demande variable. Les résultats obtenus montrent que le modèle développé permette de prédire efficacement le coût total du système ainsi que les paramètres de contrôle associés, en fournissant des résultats comparables avec ceux obtenus par optimisation basée sur la simulation. Une extension supplémentaire est réalisée dans un contexte de demande saisonnière variable afin d'évaluer l'intérêt d'une adaptation dynamique des paramètres de contrôle en fonction de l'évolution de la demande. Les résultats montrent que cette approche permet d'obtenir des coûts inférieurs à ceux d'une politique statique reposant sur un seuil de couverture fixe, les gains de performance devenant plus importants lorsque la variabilité de la demande augmente.

Dans un second temps, l'approche est appliquée à un système hybride fabrication-refabrication soumis à des demandes variables, à des retours variables ainsi qu'à des pannes et réparations aléatoires. Les modèles développés permettent de prédire le coût total du système et de déterminer les paramètres de contrôle associés aux activités de fabrication et de refabrication. Les résultats montrent que l'approche proposée surpasse systématiquement l'optimisation basée sur la simulation reposant sur des seuils fixes et permet d'améliorer les performances économiques du système.

Dans l'ensemble, les résultats obtenus démontrent que l'apprentissage automatique constitue un outil pertinent pour la détermination des paramètres de contrôle dans les systèmes de production soumis à l'incertitude. Les travaux réalisés confirment la capacité de l'approche proposée à traiter efficacement des systèmes manufacturiers et fabrication-refabrication soumis à des niveaux croissants de complexité et d'incertitude.

Mots-clés : apprentissage automatique, simulation, optimisation, contrôle de la production, systèmes manufacturiers non fiables, système fabrication-refabrication non fiable, demande variable, retours variables, politique à seuil critique (HPP)

Optimization of Control Policies for Failure-Prone Production Systems Through Data Analytics and Machine Learning

Mayssen DIDI

ABSTRACT

This research focuses on the development of an approach combining simulation, machine learning, and optimization for determining the control parameters of manufacturing and manufacturing–remanufacturing systems subject to various sources of uncertainty, including machine failures, demand variability, and product return variability. The proposed approach relies on the use of simulation-generated data to train machine learning models integrated into the optimization process.

First, the approach is developed for an unreliable M1P1 manufacturing system (one machine, one product) operating under constant demand. A database construction strategy is proposed and used for training the machine learning models. The approach is then extended to environments characterized by variable demand. The results show that the developed model is able to accurately predict both the total system cost and the associated control parameters, providing results comparable to those obtained through simulation-based optimization. A further extension is carried out in the context of seasonal demand variability in order to evaluate the benefits of dynamically adapting the control parameters according to demand evolution. The results show that this dynamic approach yields lower costs than a static policy based on a fixed hedging point, with performance improvements becoming more significant as demand variability increases.

In a second stage, the approach is applied to a hybrid manufacturing–remanufacturing system subject to variable demand, variable product returns, and random machine failures and repairs. The developed models are used to predict the total system cost and determine the control parameters associated with manufacturing and remanufacturing activities. The results show that the proposed approach consistently outperforms simulation-based optimization relying on fixed control thresholds and leads to improved economic performance of the system.

Overall, the results demonstrate that machine learning constitutes a relevant tool for determining control parameters in production systems operating under uncertainty. The findings confirm the ability of the proposed approach to efficiently address manufacturing and manufacturing–remanufacturing systems characterized by increasing levels of complexity and uncertainty.

Keywords: machine learning, simulation, optimization, production control, unreliable manufacturing systems, unreliable manufacturing–remanufacturing system, demand variability, return variability, hedging point policy (HPP)

TABLE DES MATIÈRES

	Page
INTRODUCTION	1
CHAPITRE 1 REVUE DE LITTÉRATURE.....	5
1.1 Contexte et motivation de la recherche.....	5
1.2 Systèmes manufacturiers non fiables et politiques de contrôle	7
1.2.1 Systèmes manufacturiers non fiables	7
1.2.2 Systèmes fabrication /refabrication non fiables.....	9
1.2.3 Politique à seuil critique (HPP)	10
1.2.4 Extensions de la politique HPP	12
1.3 Variabilité de la demande dans les systèmes de production	13
1.3.1 Demande variable dans les systèmes manufacturiers non fiables	13
1.3.2 Demande variable dans les systèmes fabrication–refabrication	15
1.3.3 Demande et retours variables dans les systèmes fabrication– refabrication.....	16
1.4 Critique de la littérature	18
1.5 Apprentissage automatique appliqué au contrôle des systèmes de production	21
1.6 Optimisation basée sur des modèles de substitution.....	24
1.7 Problématique	26
1.8 Conclusion du chapitre	27
CHAPITRE 2 APPLICATION DE L’APPRENTISSAGE AUTOMATIQUE AU CONTRÔLE D’UN SYSTÈME MANUFACTURIER NON FIABLE	29
2.1 Introduction.....	29
2.2 Systèmes manufacturiers non fiables sous demande constante	30
2.2.1 Description du système de production.....	30
2.2.2 Notations et variables du système	31
2.2.3 Hypothèses de modélisation	32
2.2.4 Dynamique du système.....	33
2.2.5 Politique de contrôle (HPP).....	33
2.2.6 Approche proposée	34

2.2.6.1	Phase 1 : Génération des bases de données.....	36
2.2.6.2	Phase 2 : Modèle d'apprentissage automatique	37
2.2.6.3	Phase 3 : Optimisation des paramètres de contrôle.....	38
2.2.7	Évaluation des performances	39
2.2.7.1	Comparaison des modèles d'apprentissage automatique.....	39
2.2.7.2	Validation croisée.....	42
2.2.7.3	Comparaison des algorithmes d'optimisation.....	43
2.2.8	Stratégie de structuration des bases de données	44
2.2.8.1	Augmentation du nombre de configurations optimales	46
2.2.8.2	Ajout des configurations générées par simulation	48
2.2.8.3	Ajout des configurations optimales dans une base fixe	49
2.2.8.4	Impact du nombre de répliques	50
2.2.8.5	Synthèse des résultats et efficacité de l'approche proposée .	52
2.2.9	Mécanisme de l'approche proposée.....	53
2.3	Contrôle des systèmes manufacturiers sous demande variable	55
2.3.1	Introduction à la demande variable.....	55
2.3.2	Modélisation de la demande et adaptation de l'approche.....	56
2.3.2.1	Comparaison des modèles d'apprentissage automatique.....	57
2.3.2.2	Validation croisée.....	58
2.3.2.3	Comparaison des algorithmes d'optimisation.....	59
2.3.3	Évaluation du modèle sous demande variable.....	60
2.3.3.1	Impact de la variabilité de la demande.....	61
2.3.3.2	Impact du temps moyen entre pannes (MTTF).....	62
2.3.3.3	Impact du coût de pénurie	63
2.3.4	Évaluation du modèle sous demande variable.....	63
2.3.5	Contrôle dynamique sous demande saisonnière variable	66
2.3.5.1	Demande saisonnière et principe de l'approche dynamique	66
2.3.5.2	Comparaison des approches statique et dynamique.....	69
2.3.6	Discussion et limites des approches sous demande variable	71
2.4	Conclusion du chapitre	73

CHAPITRE 3	APPLICATION DE L'APPRENTISSAGE AUTOMATIQUE AU CONTRÔLE D'UN SYSTÈME HYBRIDE FABRICATION– REFABRICATION SOUS DEMANDE ET RETOURS VARIABLES	77
3.1	Introduction.....	77
3.2	Description du système étudié	78
3.3	Notations et paramètres du système.....	79
3.4	Hypothèses et paramètres du système.....	80
3.5	Modélisation mathématique du système	81
3.6	Politique de contrôle appliquée.....	84
3.7	Approche proposée	85
3.8	Évaluation des performances	88
3.8.1	Comparaison des modèles d'apprentissage automatique	88
3.8.2	Ajustement des hyperparamètres et validation croisée.....	91
3.8.3	Comparaison des algorithmes d'optimisation	93
3.9	Expériences numériques	94
3.9.1	Scénario de base	94
3.9.2	Résultats du scénario de base	95
3.9.3	Analyse de sensibilité	96
3.9.3.1	Effet du coût de pénurie sur le coût total	97
3.9.3.2	Effet de la disponibilité des machines sur le coût total	99
3.9.3.3	Effet de la variabilité de la demande sur le coût total	101
3.9.3.4	Effet de la variabilité du coefficient de retour	102
3.9.3.5	Discussion des résultats.....	104
3.10	Conclusion du chapitre	106
CONCLUSION		109
LISTE DE RÉFÉRENCES BIBLIOGRAPHIQUES		113

LISTE DES TABLEAUX

	Page
Tableau 2.1 Paramètres du système.....	39
Tableau 2.2 Performances des algorithmes	39
Tableau 2.3 Résultats de la validation croisée.....	43
Tableau 2.4 Comparaison des performances des algorithmes d'optimisation	44
Tableau 2.5 Performances des modèles d'apprentissage automatique sous demande variable	57
Tableau 2.6 Résultats de la validation croisée du modèle de réseau de neurones.....	58
Tableau 2.7 Statistiques de la validation croisée du modèle retenu	59
Tableau 2.8 Comparaison des performances des algorithmes d'optimisation sous demande variable	59
Tableau 2.9 Paramètres du système.....	60
Tableau 2.10 Comparaison entre les résultats de simulation et les prédictions du modèle	64
Tableau 2.11 Paramètres du système.....	69
Tableau 2.12 Comparaison des approches de contrôle statique et dynamique sous demande saisonnière variable	70
Tableau 3.1 Comparaison des performances des algorithmes.....	89
Tableau 3.2 Performances du modèle de forêt aléatoire avant et après ajustement des hyperparamètres	91
Tableau 3.3 Résultats de la validation croisée à 5 plis du modèle de forêt aléatoire	93
Tableau 3.4 Comparaison des performances des algorithmes d'optimisation sous demande variable	94
Tableau 3.5 Paramètres du scénario de base	95
Tableau 3.6 Comparaison des résultats obtenus par optimisation basée sur la simulation et par l'approche proposée	95

LISTE DES FIGURES

	Page
Figure 2.1	Schéma du système manufacturier M1P1 sous demande constante 31
Figure 2.2	Structure générale de l’approche proposée..... 35
Figure 2.3	Structure générale du modèle de réseau de neurones 40
Figure 2.4	Évolution des erreurs durant l’entraînement du modèle..... 41
Figure 2.5	Comparaison entre les valeurs prédites et les valeurs réelles 42
Figure 2.6	Erreur relative moyenne du coût total en fonction du nombre de configurations optimales 47
Figure 2.7	Erreur relative moyenne du coût total en fonction du nombre de configurations générées par simulation 48
Figure 2.8	Erreur relative moyenne du coût total en fonction du nombre de configurations optimales intégrées dans une base fixe..... 50
Figure 2.9	Erreur relative moyenne du coût total en fonction du nombre de répliques 51
Figure 2.10	Mécanisme général de l’approche proposée..... 54
Figure 2.11	Structure du modèle de réseau de neurones sous demande variable 58
Figure 2.12	Analyse de sensibilité du coût total : comparaison entre la simulation et le modèle d’apprentissage automatique (ML) 61
Figure 2.13	Comparaison entre les résultats simulés et les prédictions du modèle 66
Figure 2.14	Évolution de la demande saisonnière variable au cours du temps 68
Figure 2.15	Comparaison des coûts totaux moyens obtenus par les approches statique et dynamique pour différents niveaux de variabilité saisonnière de la demande 70
Figure 3.1	Structure générale du système HMRS étudié 78
Figure 3.2	Représentation de la phase d'optimisation pour le système hybride fabrication–refabrication 88

Figure 3.3	Comparaison entre les valeurs réelles et prédites obtenues avec le modèle de forêt aléatoire	90
Figure 3.4	Variation du coût total en fonction du coût de pénurie	98
Figure 3.5	Variation du coût total en fonction de la disponibilité de la machine.....	99
Figure 3.6	Variation du coût total en fonction d'écart type de la demande	101
Figure 3.7	Variation du coût total en fonction d'écart type du coefficient de retour.....	103

LISTE DES ABRÉVIATIONS, SIGLES ET ACRONYMES

CT	Total Cost
GA	Genetic Algorithm
HPP	Hedging Point Policy
kNN	k-Nearest Neighbors
MAE	Mean Absolute Error
ML	Machine Learning
MSE	Mean Square Error
RMSE	Root Mean Square Error
M1P1	One Machine–One Product
HMRS	Hybrid Manufacturing Remanufacturing System
MTTF	Mean Time To Failure
MTTR	Mean Time To Repair
NN	Neural Network
PSO	Particle Swarm Optimization
RF	Random Forest
SA	Simulated Annealing
XGBoost	Extreme Gradient Boosting
Z	Seuil de contrôle associé à l'activité de production
Z_f	Seuil de contrôle associé à l'activité de fabrication
Z_R	Seuil de contrôle associé à l'activité de refabrication

INTRODUCTION

Les systèmes manufacturiers modernes évoluent dans un environnement caractérisé par une concurrence accrue, une mondialisation des marchés et des exigences croissantes en matière de qualité, de flexibilité et de délais de livraison. Dans ce contexte, les entreprises doivent continuellement améliorer leurs performances opérationnelles afin de maintenir leur compétitivité et de répondre efficacement aux besoins des clients. Toutefois, les systèmes de production réels sont confrontés à différentes sources d'incertitude susceptibles d'affecter leur fonctionnement et leurs performances économiques.

Parmi ces sources d'incertitude, les défaillances des machines occupent une place importante en raison de leur impact direct sur la capacité de production disponible. Les interruptions causées par les pannes et les opérations de réparation peuvent entraîner des pénuries, des retards de livraison ainsi qu'une augmentation des coûts de stockage et de pénurie. Parallèlement, les entreprises manufacturières doivent également faire face à la variabilité de la demande, qui résulte notamment des fluctuations du marché, de l'évolution des préférences des consommateurs et des variations saisonnières. La prise en compte simultanée de ces différentes sources d'incertitude complique la détermination des décisions de production et renforce la nécessité de développer des politiques de contrôle capables de s'adapter aux conditions réelles de fonctionnement du système.

Afin de faire face à ces défis, de nombreux travaux ont été consacrés au développement de politiques de contrôle permettant de gérer efficacement les systèmes manufacturiers non fiables. Parmi les approches les plus étudiées figure la politique à seuil critique (Hedging Point Policy – HPP), qui repose sur le maintien d'un niveau de stock de sécurité permettant de limiter les effets des interruptions de production tout en assurant un compromis entre les coûts de stockage et les coûts de pénurie. Bien que cette politique ait démontré son efficacité dans plusieurs contextes de production, la détermination des paramètres de contrôle optimaux demeure un problème complexe, particulièrement lorsque plusieurs paramètres du système sont susceptibles de varier simultanément.

Parallèlement aux avancées réalisées dans le domaine des systèmes de production, les progrès récents de l'intelligence artificielle ont favorisé l'émergence de nouvelles approches d'aide à la décision fondées sur l'apprentissage automatique. Grâce à leur aptitude à capturer les relations entre les variables du système, ces approches offrent des perspectives intéressantes pour le traitement de problèmes complexes de planification et de contrôle de la production. Dans le domaine manufacturier, elles permettent notamment de développer des modèles prédictifs capables de déterminer rapidement les performances d'un système à partir de données, réduisant ainsi l'effort computationnel associé aux procédures traditionnelles d'optimisation.

Dans ce contexte, ce mémoire s'intéresse à l'application de l'apprentissage automatique au contrôle de systèmes de production soumis à différentes sources d'incertitude, notamment les pannes des machines, la variabilité de la demande et la variabilité des retours de produits. L'objectif de ce mémoire est de développer une approche combinant simulation, apprentissage automatique et optimisation afin de soutenir les décisions de contrôle dans des systèmes de production soumis à différentes sources d'incertitude. Plus précisément, cette approche vise à déterminer efficacement les paramètres de contrôle permettant de minimiser le coût total moyen à long terme du système. Afin d'atteindre cet objectif général, les objectifs spécifiques suivants sont poursuivis :

- Développer une approche intégrant simulation, apprentissage automatique et optimisation pour la détermination des paramètres de contrôle des systèmes de production.
- Analyser l'influence de différentes stratégies de construction des bases de données d'apprentissage et évaluer l'impact de leur composition sur les performances des modèles d'apprentissage automatique.
- Étudier et comparer différentes techniques d'apprentissage automatique afin d'identifier les modèles les plus adaptés à la prédiction des performances du système et des paramètres de contrôle.

- Appliquer l'approche développée à un système manufacturier non fiable afin d'évaluer son efficacité sous demande constante, puis sous demande variable.
- Étendre l'approche proposée à un système hybride fabrication–refabrication non fiable caractérisé par la variabilité de la demande, l'incertitude des retours et les défaillances.

Afin de répondre à ces objectifs, l'approche proposée est développée et validée progressivement sur deux systèmes de production de complexité croissante.

Dans un premier temps, l'approche proposée est appliquée à un système manufacturier non fiable de type M1P1 (une machine, un produit), largement utilisé dans la littérature comme système de référence pour l'étude des problèmes de contrôle de production. L'objectif consiste à évaluer la capacité de l'approche développée à déterminer efficacement les paramètres de contrôle du système sous différentes conditions opérationnelles. Par ailleurs, différentes stratégies de construction des bases de données d'apprentissage sont analysées. Les performances de plusieurs modèles d'apprentissage automatique sont également évaluées et comparées dans différentes conditions d'exploitation du système.

Dans un second temps, l'approche développée est étendue à un système hybride fabrication–refabrication composé de deux unités de production soumises à des pannes et réparations aléatoires. Dans ce système, la demande et les retours de produits sont considérés comme variables, ce qui introduit des sources supplémentaires d'incertitude. L'objectif consiste alors à déterminer les seuils de contrôle associés aux activités de fabrication et de refabrication permettant de minimiser le coût total du système.

Ce mémoire est organisé en trois chapitres. Le premier chapitre présente une revue de la littérature consacrée aux systèmes manufacturiers non fiables, aux systèmes hybrides fabrication–refabrication, aux politiques de contrôle de type HPP, à la variabilité de la demande ainsi qu'aux applications de l'apprentissage automatique dans les systèmes de production. La problématique de recherche et les objectifs poursuivis y sont également présentés.

Le deuxième chapitre est consacré à l'application de l'apprentissage automatique au contrôle d'un système manufacturier non fiable de type M1P1. Après la présentation du système étudié et de l'approche proposée, les performances de différents modèles d'apprentissage automatique sont évaluées et comparées. Plusieurs analyses sont également réalisées afin d'étudier l'influence de la structure des bases de données d'apprentissage et des conditions opérationnelles sur les résultats obtenus.

Le troisième chapitre présente l'application de l'approche développée au contrôle d'un système hybride fabrication–refabrication sous demande et retours variables. Les résultats obtenus permettent d'évaluer la capacité de l'approche proposée à déterminer efficacement les paramètres de contrôle du système ainsi que sa robustesse sous différentes conditions opérationnelles.

CHAPITRE 1

REVUE DE LITTÉRATURE

1.1 Contexte et motivation de la recherche

Au cours des dernières décennies, les systèmes manufacturiers ont connu des évolutions importantes sous l'effet des avancées technologiques, de l'évolution des marchés et de l'augmentation des exigences des clients. Dans ce contexte, les entreprises cherchent continuellement à améliorer leurs performances opérationnelles afin d'accroître leur compétitivité et de répondre efficacement aux besoins du marché (Ascic et al., 2022).

L'atteinte de ces objectifs représente toutefois un défi en raison des nombreuses sources d'incertitude qui caractérisent les environnements de production modernes. Parmi les différentes sources d'incertitudes auxquelles sont confrontés les systèmes manufacturiers, les défaillances des machines occupent une place importante en raison de leur impact direct sur la capacité de production et les performances du système. Les interruptions causées par les pannes réduisent temporairement ou complètement la capacité de production disponible, ce qui peut entraîner des retards de livraison, des pénuries de produits ainsi qu'une dégradation des performances opérationnelles du système (Gershwin, 2018).

Au-delà de leurs conséquences opérationnelles, les défaillances des machines peuvent engendrer des impacts économiques importants pour les entreprises manufacturières. Les arrêts non planifiés réduisent la disponibilité des ressources de production, perturbent les activités de fabrication et peuvent entraîner des coûts considérables associés aux retards de production et à l'incapacité de satisfaire la demande. Les conséquences économiques associées à ces perturbations sont considérables. Selon Siemens (2024), les pertes annuelles liées aux arrêts non planifiés dans les entreprises manufacturières figurant au classement Fortune Global 500 sont estimées à près de 1,4 trillion de dollars, tandis que le coût d'une heure d'arrêt dans certaines industries peut atteindre plusieurs millions de dollars. De plus, une étude menée par ABB (2023) révèle qu'environ 69 % des installations industrielles subissent au moins un arrêt

non planifié chaque mois, soulignant l'importance de prendre en compte la fiabilité des machines dans les décisions de production.

Parallèlement aux perturbations liées aux défaillances des machines, les entreprises manufacturières sont également confrontées à une autre source majeure d'incertitudes : la variabilité de la demande. Dans de nombreux secteurs industriels, les quantités demandées évoluent continuellement sous l'effet des fluctuations du marché, de l'évolution des préférences des consommateurs, des cycles de vie des produits ainsi que des variations saisonnières. Ces fluctuations influencent directement les activités de production, les niveaux d'inventaire ainsi que les décisions de planification, rendant plus complexe la gestion des ressources au sein des systèmes manufacturiers (Botha, 2017).

L'importance de cette problématique est largement observée dans les environnements industriels. Rivera-Castro et al. (2019) rapportent le cas d'un fabricant de produits électroniques gérant plus de 2 500 composants différents et mettent en évidence les variations importantes pouvant être observées dans les niveaux de demande. Des études industrielles indiquent également que les écarts entre les niveaux de demande planifiés et les niveaux observés peuvent atteindre 44 à 53 % pour les nouveaux produits et environ 31 % pour les produits existants. Ces résultats mettent en évidence les fluctuations de la demande auxquelles les entreprises manufacturières sont confrontées lors de la planification de leurs activités de production et de gestion des stocks.

La variabilité de la demande constitue ainsi un défi important pour les systèmes manufacturiers. Une augmentation de la demande peut conduire à des situations de pénurie lorsque la capacité de production disponible devient insuffisante pour satisfaire les besoins du marché, tandis qu'une diminution de la demande peut entraîner une accumulation excessive de stocks et une augmentation des coûts de possession. Les responsables de production doivent ainsi continuellement ajuster leurs décisions afin de maintenir un équilibre entre la satisfaction de la demande, les niveaux d'inventaire et les coûts associés au système.

La gestion des systèmes manufacturiers devient encore plus complexe lorsque les fluctuations de la demande se produisent dans un environnement où les capacités de production sont elles-mêmes affectées par des défaillances des machines. Dans ce contexte, les entreprises doivent faire face simultanément à l'incertitude associée à l'évolution de la demande et à celle liée à la disponibilité des ressources de production. La coexistence de ces deux sources d'incertitude complique la planification des activités de production et renforce la nécessité de développer des approches de contrôle capables de s'adapter aux conditions réelles de fonctionnement du système (Sajadi et al., 2010).

Dans ce contexte, les politiques de planification et de contrôle de la production jouent un rôle fondamental dans l'amélioration des performances des systèmes manufacturiers. Elles visent à déterminer les décisions de production permettant d'assurer un équilibre entre les coûts de stockage et les coûts de pénurie. Plusieurs approches de contrôle ont ainsi été développées dans la littérature afin d'aider les entreprises à gérer efficacement les perturbations et les différentes sources d'incertitudes affectant les systèmes de production.

1.2 Systèmes manufacturiers non fiables et politiques de contrôle

1.2.1 Systèmes manufacturiers non fiables

Les systèmes manufacturiers sont des systèmes de production composés de différentes ressources permettant de transformer des matières premières en produits finis destinés à satisfaire une demande donnée. Dans les modèles de production idéalisés, les machines sont généralement supposées disponibles en permanence et capables d'assurer la production sans interruption. Toutefois, les environnements industriels réels sont soumis à diverses perturbations susceptibles d'affecter le fonctionnement du système et ses performances. Parmi celles-ci, les défaillances des machines représentent l'une des principales sources d'incertitudes affectant les systèmes manufacturiers (Gershwin, 2018).

En pratique, les machines sont sujettes à des pannes susceptibles d'interrompre temporairement les activités de production. Après une défaillance, une opération de réparation

est nécessaire avant le retour de la machine à un état opérationnel. Le fonctionnement des systèmes manufacturiers non fiables est ainsi caractérisé par une alternance entre des périodes de production et des périodes d'arrêt. Afin de représenter ce comportement, la littérature utilise généralement des indicateurs de fiabilité tels que le temps moyen avant défaillance (Mean Time To Failure – MTTF) et le temps moyen de réparation (Mean Time To Repair – MTTR), qui permettent d'évaluer la disponibilité des machines.

Les défaillances des machines influencent directement la capacité de production du système et sa capacité à satisfaire la demande des clients. Lorsque les machines deviennent indisponibles, la production peut être réduite ou complètement interrompue, ce qui augmente le risque de pénurie et détériore les performances du système. À l'inverse, afin de se prémunir contre les futures interruptions de production, les entreprises peuvent être amenées à constituer des stocks de sécurité plus importants, entraînant une augmentation des coûts de possession. Les décisions de production doivent ainsi tenir compte d'un compromis entre les coûts de stockage et les coûts associés aux ruptures de stock. Ces difficultés ont été largement observées dans différents secteurs industriels où les pannes des machines influencent directement les niveaux d'inventaire, les retards de production ainsi que les coûts de stockage et de pénurie (Ouaret et al., 2018).

La prise en compte des défaillances et des réparations constitue déjà un défi important pour le contrôle des systèmes manufacturiers. Toutefois, les systèmes de production étudiés dans la littérature ne se limitent pas aux systèmes manufacturiers. Certaines entreprises intègrent également des activités de récupération et de valorisation des produits en fin de vie, ce qui conduit à des systèmes de production plus complexes. Parmi ceux-ci figurent les systèmes hybrides fabrication–refabrication, qui combinent les activités de fabrication de produits neufs et de refabrication de produits retournés. L'intégration de ces flux supplémentaires engendre de nouvelles contraintes de gestion et de contrôle qui seront présentés dans la section suivante.

1.2.2 Systèmes fabrication /refabrication non fiables

La refabrication désigne un processus industriel consistant à restaurer des produits ou composants usagés à un état de qualité comparable à celui d'un produit neuf (Mitra, 2012). Cette approche permet de prolonger le cycle de vie des produits tout en récupérant la valeur résiduelle des articles retournés après leur utilisation. L'intérêt croissant pour la réduction des coûts, la préservation des ressources et les objectifs de développement durable a conduit de nombreuses entreprises à intégrer des activités de refabrication dans leurs systèmes de production (Govindan et al., 2015 ; Souza, 2012).

Lorsque les activités de refabrication sont combinées aux opérations de fabrication traditionnelles, le système de production obtenu est généralement désigné sous le nom de système hybride fabrication–refabrication. Dans ces systèmes, la demande peut être satisfaite à partir de deux sources complémentaires : la fabrication de nouveaux produits à partir de matières premières et la refabrication de produits retournés provenant du marché (Behret et Korugan, 2009). Cette configuration est largement utilisée dans plusieurs secteurs industriels manipulant des produits à forte valeur ajoutée, notamment les industries automobile, électronique et aérospatiale (Esmaeilian et al., 2016).

Comparativement aux systèmes manufacturiers traditionnels, les systèmes de fabrication–refabrication introduisent des sources de complexité supplémentaires liées à la présence simultanée de flux directs et inverses. La gestion de ces systèmes nécessite de coordonner à la fois la fabrication de nouveaux produits et la refabrication des produits retournés, tout en tenant compte de la disponibilité des retours et de leur réintégration dans le processus de production. La présence simultanée de stocks de produits finis et de produits retournés ajoute également de nouvelles contraintes de planification et de contrôle. Plusieurs travaux de synthèse ont présenté les principaux modèles et problématiques associés aux systèmes de refabrication et de logistique inverse, notamment les activités de collecte, d'inspection, de production, de récupération et d'élimination des produits retournés (Fleischmann et al., 1997 ; Dekker et al., 2004 ; De Brito et al., 2013 ; Govindan et al., 2015).

Lorsque les ressources de production sont soumises à des défaillances et à des réparations, les systèmes de fabrication–refabrication doivent également faire face aux conséquences associées à l’indisponibilité des machines. Les interruptions de production affectent simultanément les activités de fabrication et de refabrication, réduisant ainsi la capacité du système à satisfaire la demande. Les décideurs doivent alors coordonner les flux de production et de retour tout en tenant compte de la disponibilité des machines et des niveaux de stocks. Cette combinaison de contraintes a conduit au développement de modèles de contrôle spécifiquement adaptés aux systèmes de fabrication–refabrication non fiables.

Les défis associés aux défaillances des machines, à la coordination des activités de fabrication et de refabrication ainsi qu’à la gestion des stocks ont suscité un intérêt important dans la littérature. De nombreux travaux ont ainsi été consacrés au développement de politiques de contrôle visant à améliorer les performances des systèmes manufacturiers et fabrication–refabrication non fiables. Parmi les approches proposées, les politiques à seuil critique (Hedging Point Policies – HPP) occupent une place centrale dans la littérature sur le contrôle des systèmes de production non fiables. La section suivante présente les principes fondamentaux de cette politique de contrôle.

1.2.3 Politique à seuil critique (HPP)

Le contrôle de la production constitue un élément essentiel dans la gestion des systèmes manufacturiers non fiables. En présence de défaillances et de réparations, les décideurs doivent définir des politiques de production capables d’assurer un équilibre entre la satisfaction de la demande, les niveaux d’inventaire et les coûts associés au système. Parmi les approches proposées dans la littérature, la politique à seuil critique, communément appelée Hedging Point Policy (HPP), occupe une place importante dans le domaine du contrôle des systèmes sujets aux pannes. Introduite par Kimemia et Gershwin (1983), cette politique repose sur le principe de constituer un stock de sécurité permettant de faire face aux interruptions futures de production.

L'idée fondamentale de la HPP consiste à maintenir un niveau d'inventaire cible, appelé seuil critique ou hedging point, qui sert de protection contre les futures interruptions de production. Lorsque les machines sont disponibles, le système ne produit pas uniquement pour satisfaire la demande courante, mais également pour constituer une réserve de stock destinée à absorber les conséquences des pannes futures. La difficulté principale réside alors dans la détermination du niveau optimal de ce stock de sécurité, lequel résulte d'un compromis entre les coûts de stockage et les coûts associés aux pénuries.

Le fonctionnement de cette politique est relativement simple. Lorsque le niveau d'inventaire est inférieur au seuil critique, la production est généralement effectuée au taux maximal afin de reconstituer le stock de sécurité. Lorsque le niveau d'inventaire atteint ce seuil, le taux de production est ajusté de manière à satisfaire la demande. Enfin, lorsque le niveau d'inventaire dépasse le seuil critique, la production peut être interrompue afin d'éviter une accumulation excessive de stock.

Les travaux d'Akella et Kumar (1986) constituent une contribution majeure dans ce domaine. Les auteurs ont étudié un système manufacturier composé d'une seule machine produisant un seul type de produit faisant face à une demande constante. La machine est sujette à des pannes et réparations aléatoires, tandis que l'objectif consiste à minimiser les coûts de stockage et de pénurie. Leurs résultats montrent que la politique optimale possède une structure de type HPP, caractérisée par l'existence d'un niveau de stock critique permettant de minimiser le coût total du système.

Par la suite, Bielecki et Kumar (1988) ont approfondi l'étude de cette politique en développant des résultats analytiques permettant de déterminer explicitement le niveau optimal du seuil critique ainsi que le coût optimal associé. Ces travaux ont contribué à établir la HPP comme l'une des politiques de contrôle les plus importantes pour les systèmes manufacturiers non fiables et ont servi de fondement à de nombreuses extensions développées pour des environnements de production plus complexes.

1.2.4 Extensions de la politique HPP

Au fil des années, les politiques HPP ont fait l'objet de nombreuses extensions visant à mieux représenter la complexité des systèmes manufacturiers rencontrés dans la pratique. Alors que les premiers travaux concernaient principalement des systèmes simples, les recherches ultérieures ont progressivement intégré de nouvelles contraintes opérationnelles ainsi que des configurations de production plus complexes.

Plusieurs études ont cherché à combiner les décisions de production avec d'autres activités influençant les performances du système. Rezg et al. (2008) ainsi que Gharbi et al. (2024) ont intégré les décisions de maintenance au cadre de contrôle afin de tenir compte de l'impact des opérations de maintenance sur la disponibilité des machines. Les extensions proposées par Yan et al. (2017) concernent quant à elles les systèmes multi-machines, permettant une représentation plus réaliste des environnements industriels. Les chercheurs se sont également intéressés à l'intégration de nouvelles contraintes dans les politiques de contrôle. Afshar-Bakeshloo et al. (2018) ont proposé une approche prenant en compte les impacts environnementaux associés aux activités de production. Assid et al. (2019) et Ponghah et al. (2022) ont étendu les politiques HPP aux systèmes hybrides fabrication–refabrication, où les décisions de production doivent coordonner simultanément les activités de fabrication et de refabrication. Enfin, Dhahri et al. (2022) ont étudié l'application de ces politiques dans des réseaux de production et de logistique plus complexes.

Malgré ces avancées, la majorité des travaux présentés précédemment reposent encore sur l'hypothèse d'une demande constante. Cette hypothèse permet de simplifier l'analyse et le développement des politiques de contrôle, mais elle ne reflète pas toujours les conditions réelles observées dans les environnements industriels. En pratique, les fluctuations de la demande constituent une source d'incertitude importante susceptible d'influencer les décisions de production, les niveaux d'inventaire ainsi que les performances globales du système. La prise en compte de cette variabilité dans les modèles de contrôle a ainsi fait l'objet de nombreux travaux de recherche qui seront présentés dans la section suivante.

1.3 Variabilité de la demande dans les systèmes de production

La majorité des travaux présentés dans les sections précédentes ont été développés sous l'hypothèse d'une demande constante. Cette hypothèse permet de simplifier l'analyse du système et la détermination des politiques de contrôle. Toutefois, dans de nombreux environnements industriels, la demande évolue continuellement sous l'effet de plusieurs facteurs, tels que les fluctuations du marché, l'évolution des préférences des consommateurs, les cycles de vie des produits ou encore les variations saisonnières. Ces fluctuations constituent une source d'incertitude importante susceptible d'influencer les décisions de production, les niveaux d'inventaire et les performances globales du système (Botha, 2017).

1.3.1 Demande variable dans les systèmes manufacturiers non fiables

L'intégration de la variabilité de la demande dans les systèmes manufacturiers non fiables a suscité un intérêt croissant au cours des dernières décennies. Dans ce contexte, les politiques de contrôle doivent tenir compte simultanément des fluctuations de la demande et des perturbations associées aux défaillances et aux réparations des machines. Plusieurs travaux ont ainsi cherché à étendre les approches développées sous l'hypothèse d'une demande constante afin de les adapter à des environnements caractérisés par une demande variable.

Parmi les premiers travaux consacrés à cette problématique, Perkins et Srikant (2001) ont étudié un système manufacturier non fiable dans lequel la demande survient sous forme de rafales (« bursts ») modélisées par un processus de Poisson. Les auteurs ont analysé la structure de la politique de contrôle optimale et montré que celle-ci conserve une forme de type HPP malgré la présence de la variabilité de la demande.

Dans la même perspective, Sajadi et al. (2010) ont considéré un réseau de systèmes manufacturiers non fiables soumis à une demande de type Poisson et ont utilisé une approche combinant simulation et méthodologie des surfaces de réponse pour optimiser les décisions de contrôle du système.

D'autres auteurs se sont intéressés à des environnements dans lesquels la demande présente des variations périodiques reflétant des effets saisonniers. Polotski et al. (2022) ont étudié un système manufacturier non fiable composé d'une seule machine produisant un produit périssable soumis à une demande saisonnière. La demande est modélisée par une fonction périodique variant au cours du temps, tandis que la politique de contrôle repose sur une extension de la HPP dans laquelle le seuil de sécurité évolue en fonction de la demande. Les auteurs développent une approche basée sur les équations de Hamilton–Jacobi–Bellman afin de déterminer une courbe de seuil variable dans le temps, adaptée aux fluctuations saisonnières de la demande.

D'autres représentations de la demande variable ont également été proposées dans la littérature. Ouaret (2022) a étudié un système manufacturier non fiable dans lequel la demande suit un processus stochastique caractérisé par des moyennes variables dans le temps et a déterminé une politique de contrôle optimale de type HPP à l'aide des équations de Hamilton–Jacobi–Bellman. De leur côté, Wang et Chen (2024) ont développé un modèle de contrôle optimal stochastique intégrant simultanément les décisions de production et de tarification sous incertitude de la demande, cette dernière étant représentée par un processus de diffusion gouverné par un mouvement brownien.

Les travaux précédents montrent que la variabilité de la demande a été intégrée dans les systèmes manufacturiers non fiables à travers différentes représentations, notamment les processus de Poisson, les profils saisonniers, les distributions probabilistes et les processus stochastiques continus. Ces contributions ont permis d'adapter les politiques de contrôle de type HPP à des environnements plus réalistes caractérisés par des fluctuations de la demande, tout en tenant compte des défaillances et des réparations des machines.

La variabilité de la demande a également été étudiée dans le contexte des systèmes hybrides fabrication–refabrication. Dans ces systèmes, les décisions de contrôle doivent non seulement tenir compte des fluctuations de la demande et de la disponibilité des ressources de production, mais également de la présence des produits retournés qui alimentent les activités de

refabrication. Selon les hypothèses retenues dans la littérature, les retours peuvent être considérés comme constants, dépendants de la demande ou encore variables et soumis à différentes sources d'incertitude. Ces différentes configurations ont conduit au développement de plusieurs modèles de contrôle adaptés aux systèmes fabrication–refabrication sous demande variable.

1.3.2 Demande variable dans les systèmes fabrication–refabrication

L'intégration de la variabilité de la demande dans les systèmes hybrides fabrication–refabrication a suscité un intérêt croissant dans la littérature. Comparativement aux systèmes manufacturiers traditionnels, ces systèmes doivent coordonner simultanément les activités de fabrication et de refabrication tout en gérant les flux de produits retournés. Dans ce contexte, les décisions de contrôle doivent être ajustées en fonction de l'évolution de la demande ainsi que de la disponibilité des produits retournés destinés à la refabrication.

Afin de tenir compte de cette variabilité, plusieurs chercheurs ont développé des modèles de contrôle dans lesquels la demande évolue selon différents processus stochastiques. Dans la majorité de ces travaux, les flux de retour sont représentés comme une fonction de la demande ou des ventes passées. Ouaret et al. (2013) ont étudié le contrôle optimal d'un système hybride fabrication–refabrication sous demande stochastique. La demande est modélisée à l'aide d'un processus de diffusion stochastique, tandis que le flux de retour est supposé proportionnel à la demande à travers un coefficient fixe. Le problème est formulé comme un modèle de commande optimale stochastique résolu à l'aide des équations de Hamilton–Jacobi–Bellman, et la politique optimale obtenue présente une structure de type HPP.

Dans la même perspective, Ndhaief et al. (2020) ont étudié un système hybride fabrication–refabrication non fiable dans lequel la demande suit une distribution normale discrète, tandis que les retours sont représentés comme une fraction retardée de la demande passée. Les auteurs ont développé un modèle intégré de production et de maintenance afin de déterminer les décisions optimales sous incertitude. Hajej et al. (2020) ont considéré une configuration

similaire dans laquelle la demande est également modélisée par une distribution normale, alors que les retours sont générés après une période de location et dépendent des ventes réalisées antérieurement.

D'autres travaux ont proposé des représentations plus élaborées de la demande variable. Corsini et al. (2023) ont étudié un système hybride fabrication–refabrication intégré dans une chaîne logistique en boucle fermée sous demande variable. La demande est modélisée à l'aide d'un processus stochastique non stationnaire de type ARIMA, tandis que les retours sont générés à partir des ventes passées. Les auteurs ont développé une politique de contrôle adaptative inspirée du cadre HPP. De leur côté, Turki et al. (2018) ont analysé un système hybride fabrication–refabrication sous demande stochastique pour les produits neufs et refabriqués. Le flux de retour dépend des ventes antérieures de produits neufs, introduisant ainsi une relation retardée entre la demande et la disponibilité des produits retournés. Une approche d'optimisation basée sur la simulation a été utilisée afin de déterminer les décisions de production et de gestion des stocks.

Bien que ces travaux permettent d'intégrer la variabilité de la demande dans les systèmes fabrication–refabrication, les retours demeurent généralement représentés à travers une relation fixe avec la demande ou les ventes passées. Or, dans de nombreux contextes industriels, les flux de retour sont eux-mêmes soumis à différentes sources d'incertitude susceptibles d'influencer la disponibilité des produits destinés à la refabrication. Afin de mieux représenter les conditions observées dans les environnements industriels, plusieurs chercheurs ont développé des modèles tenant compte simultanément de la variabilité de la demande et de celle des retours. La section suivante présente les principaux travaux consacrés à cette problématique.

1.3.3 Demande et retours variables dans les systèmes fabrication–refabrication

Au-delà de la variabilité de la demande, les flux de retour constituent également une source importante d'incertitude dans les systèmes hybrides fabrication–refabrication. Les quantités

retournées peuvent varier dans le temps sous l'effet de plusieurs facteurs, tels que la durée de vie des produits, les comportements des utilisateurs, les conditions d'utilisation ou encore les politiques de récupération mises en œuvre par les entreprises.

Dans ce contexte, plusieurs chercheurs ont développé des modèles intégrant simultanément les incertitudes associées à la demande et aux retours afin d'améliorer les décisions de fabrication et de refabrication. Han et al. (2016) ont développé un modèle d'optimisation robuste dans lequel la demande ainsi que les quantités retournées sont considérées comme des paramètres incertains. Les auteurs déterminent les décisions optimales de fabrication et de refabrication permettant de minimiser les coûts du système sous différentes conditions d'incertitude. De même, Wang et Han (2020) ont étudié un système hybride fabrication–refabrication multi-périodes dans lequel la demande évolue au cours du temps, tandis que les retours sont modélisés comme des quantités stochastiques caractérisées par une qualité et un rendement incertain. Le problème de planification est résolu à l'aide d'algorithmes métaheuristiques afin de déterminer les décisions optimales de fabrication et de refabrication.

Une autre contribution est proposée par Salviano et Andres (2020), qui ont étudié un système intégré de fabrication–refabrication caractérisé par une demande et des retours stochastiques. Les auteurs formulent le problème sous la forme d'un modèle de planification de production stochastique et utilisent un filtre de Kalman afin d'estimer l'état du système et de mettre à jour périodiquement les décisions de production. De son côté, Cheng (2022) a étudié un système hybride fabrication–refabrication multi-périodes dans lequel les produits neufs et refabriqués sont considérés comme parfaitement substituables pour satisfaire la demande du marché. La demande est stochastique et les retours sont également incertains, puisque chaque produit reste en utilisation pendant une durée aléatoire avant d'être retourné au système. Les quantités retournées dépendent ainsi des ventes passées et des durées d'utilisation aléatoire des produits. Le problème est modélisé à l'aide de la programmation dynamique et la solution optimale est caractérisée par une politique à seuil permettant de déterminer les quantités à fabriquer.

Les travaux précédents considèrent principalement des systèmes de production fiables et se concentrent sur les incertitudes associées à la demande et aux retours. Or, dans les environnements industriels réels, les systèmes fabrication–refabrication sont également exposés aux défaillances et réparations des équipements, ce qui ajoute une source supplémentaire d’incertitude susceptible d’affecter les décisions de production et de gestion des stocks.

Dans ce contexte, Polotski et al. (2019) ont étudié un système hybride fabrication–refabrication composé de deux machines sujettes aux pannes et réparations, l’une dédiée à la fabrication et l’autre à la refabrication. Les auteurs considèrent des taux de demande et de retour variables dans le temps et développent un modèle de commande optimale stochastique fondé sur les équations de Hamilton–Jacobi–Bellman afin de déterminer les politiques optimales de fabrication, de refabrication et d’élimination. Plus récemment, Polotski et al. (2023) ont analysé un système hybride fabrication–refabrication non fiable dans lequel la demande et les retours présentent des composantes variables et stochastiques. Les auteurs proposent une approche basée sur un filtre de Kalman permettant d’estimer les états du système et les flux de retour afin de déterminer une politique de contrôle généralisée pour les activités de fabrication, de refabrication et d’élimination.

Les travaux présentés dans cette section montrent que la prise en compte simultanée de la variabilité de la demande, de la variabilité des retours et des défaillances des machines conduit à des problèmes de contrôle particulièrement complexes. Ces recherches ont permis de développer différentes approches de modélisation et de contrôle adaptées aux systèmes fabrication–refabrication évoluant dans des environnements fortement incertains.

1.4 Critique de la littérature

La revue de littérature présentée dans les sections précédentes montre que des progrès importants ont été réalisés dans le développement de politiques de contrôle pour les systèmes manufacturiers et les systèmes hybrides fabrication–refabrication soumis à différentes sources

d'incertitude. Les travaux recensés ont progressivement intégré les phénomènes de défaillance et de réparation des équipements, la variabilité de la demande ainsi que l'incertitude associée aux flux de retour. Plusieurs extensions des politiques de type HPP ont ainsi été proposées afin de prendre en compte des configurations de production de plus en plus complexes.

Par ailleurs, plusieurs travaux portant sur les systèmes manufacturiers et fabrication–refabrication soumis à des défaillances et réparations ont intégré la variabilité de la demande et des retours à travers différentes représentations stochastiques. Bien que ces approches permettent de représenter les principales sources d'incertitude affectant le système, certaines limites demeurent quant à la manière dont la demande et les retours sont pris en compte dans la construction des paramètres de contrôle. Certaines approches reposent sur des hypothèses concernant l'évolution future de ces variables afin de déterminer les paramètres de contrôle. Dans ce contexte, les seuils de production sont déterminés à partir des trajectoires anticipées de la demande ou des retours et évoluent en fonction de celles-ci (Polotski et al., 2019). Toutefois, dans les environnements industriels réels, l'évolution future de ces variables demeure incertaine et peut différer des comportements supposés lors de la phase de modélisation. Dans de telles situations, les paramètres de contrôle obtenus peuvent devenir moins adaptés aux conditions réelles du système et affecter ses performances. D'autres travaux représentent la demande à l'aide de processus stochastiques et déterminent les politiques de contrôle à partir de caractéristiques statistiques de la demande, telle que sa valeur moyenne ou sa distribution de probabilité, plutôt qu'à partir des valeurs effectivement observées au cours du temps (Sajadi et al., 2010 ; Ouaret, 2022). Cette simplification permet de faciliter la résolution du problème de contrôle, mais elle peut limiter la capacité du système à réagir directement aux fluctuations réelles de la demande observées au cours de son fonctionnement.

Une autre limite concerne les méthodes utilisées pour déterminer les paramètres de contrôle. Dans de nombreux travaux, les politiques optimales sont obtenues à partir de procédures numériques nécessitant la résolution des équations de Hamilton–Jacobi–Bellman (HJB) ou à l'aide de procédures d'optimisation basées sur la simulation. Bien que ces approches

traditionnelles permettent de traiter des systèmes complexes caractérisés par plusieurs sources d'incertitude, elles présentent certaines limitations.

Dans les approches numériques, le problème de contrôle est généralement résolu à travers une discrétisation de l'espace d'état sur un domaine de calcul fini. Cette formulation permet de rendre le problème d'optimisation traitable, mais introduit une dépendance à certains choix de modélisation, notamment la résolution de la grille et les limites du domaine de calcul. Comme le soulignent Berthaut et al. (2009), ces choix peuvent influencer les paramètres de contrôle obtenus et engendrer des imprécisions numériques, particulièrement à proximité des frontières du domaine étudié. Par ailleurs, les paramètres de contrôle obtenus par les approches numériques sont généralement associés à une configuration spécifique définie par les paramètres du système. Toute modification des paramètres nécessite alors une nouvelle phase d'optimisation afin de recalculer les paramètres de contrôle appropriés (Yang et al., 2014). Cette dépendance peut accroître le temps nécessaire à l'obtention de nouvelles solutions lorsque les conditions opérationnelles évoluent fréquemment.

Des limitations similaires sont observées dans les approches reposant sur l'optimisation basée sur la simulation. Les paramètres de contrôle obtenus dépendent généralement de la configuration du système considérée lors des expériences de simulation. Toute modification des paramètres du système nécessite de nouvelles simulations ainsi qu'une nouvelle procédure d'optimisation, ce qui augmente l'effort computationnel requis pour déterminer les paramètres de contrôle (Pasupathy et Ghosh, 2013).

Ces différentes limites réduisent l'applicabilité des approches traditionnelles dans des environnements caractérisés par des changements fréquents des conditions opérationnelles. Elles soulignent la nécessité de développer des approches capables de déterminer rapidement des paramètres de contrôle adaptés à de nouvelles configurations du système sans recourir systématiquement à une nouvelle phase d'optimisation. Dans cette perspective, les techniques d'apprentissage automatique (machine learning) apparaissent comme une alternative

prometteuse, puisqu'elles permettent d'exploiter les relations entre les caractéristiques du système et les décisions de contrôle à partir de données préalablement générées.

1.5 Apprentissage automatique appliqué au contrôle des systèmes de production

Face aux limites des approches traditionnelles présentées précédemment, les techniques d'apprentissage automatique suscitent un intérêt croissant dans le domaine manufacturier. Grâce à leur capacité à apprendre à partir des données et à modéliser des relations complexes entre les variables d'un système, elles sont de plus en plus utilisées pour soutenir la prise de décision dans des environnements caractérisés par l'incertitude et la variabilité.

L'apprentissage automatique constitue un sous-domaine de l'intelligence artificielle permettant aux systèmes informatiques d'apprendre à partir de données et d'identifier automatiquement des relations entre les variables d'un problème sans être explicitement programmés pour chaque situation possible (Domingos, 2012). Grâce à leur capacité à modéliser des relations complexes et non linéaires, les techniques d'apprentissage automatique sont de plus en plus utilisées pour soutenir la prise de décision dans des environnements industriels caractérisés par de multiples sources d'incertitude et de variabilité. Parmi les algorithmes les plus utilisés figurent les réseaux de neurones (Neural Networks), les forêts aléatoires (Random Forests) et les méthodes de gradient boosting telles que XGBoost, qui ont démontré leur efficacité pour prédire différents indicateurs de performance des systèmes de production (Bodendorf et al., 2021 ; Zhong et al., 2023 ; Xie, 2024).

Plusieurs travaux ont exploré l'utilisation de l'apprentissage automatique afin de soutenir la prise de décision dans des environnements caractérisés par une demande incertaine. El Filali et al. (2022) utilisent des réseaux de neurones récurrents et des architectures Long Short-Term Memory (LSTM) pour apprendre les comportements de la demande à partir de séries temporelles de ventes historiques et prédire la demande future dans une chaîne logistique pharmaceutique. Dans le domaine de la gestion des stocks, Lolli et al. (2019) développent un modèle supervisé de classification multicritère destiné aux systèmes caractérisés par une

demande intermittente. De leur côté, Priore et al. (2018) utilisent des techniques d'apprentissage automatique afin de sélectionner dynamiquement des politiques de réapprovisionnement dans un environnement où la demande est représentée par une variable stochastique suivant une distribution normale. Le modèle apprend les relations entre les conditions du système et les performances des différentes politiques afin de sélectionner la règle de réapprovisionnement la plus appropriée.

Les techniques d'apprentissage automatique ont également été appliquées dans le domaine de la fabrication–refabrication et de la logistique inverse. Shah et al. (2018) proposent une approche basée sur l'apprentissage par renforcement (Reinforcement Learning) afin de déterminer une politique optimale d'utilisation de matières premières neuves et de matériaux récupérés dans un système de refabrication. Plus récemment, Kim et al. (2024) présentent une revue de littérature consacrée aux applications de l'apprentissage automatique dans les systèmes de refabrication. Les auteurs montrent que ces approches sont utilisées dans plusieurs domaines, tels que la classification des produits retournés, le contrôle de la qualité, la planification de la production, la gestion des stocks, l'ordonnancement ainsi que la maintenance.

Dans le contexte du contrôle de production, Behnamfar et al. (2022) développent une approche combinant simulation et apprentissage automatique afin de déterminer les paramètres d'une politique de contrôle de type Hedging Point Policy dans un système manufacturier non fiable. Le modèle tient compte des défaillances des équipements ainsi que de plusieurs niveaux de demande étudiés à travers différents scénarios de simulation. Les paramètres de contrôle sont ensuite appris à partir des données générées par simulation. Toutefois, la demande est représentée par plusieurs niveaux déterministes et demeure constante durant chaque expérience de simulation, de sorte que les variations de la demande sont analysées à travers des scénarios distincts plutôt qu'à travers un processus évoluant continuellement dans le temps.

Ces travaux démontrent le potentiel de l'apprentissage automatique pour soutenir la prise de décision dans des environnements industriels caractérisés par l'incertitude. Toutefois, la

majorité des études se concentrent principalement sur le développement des modèles d'apprentissage et l'évaluation de leurs performances prédictives. Les aspects liés à la qualité des données d'apprentissage ainsi qu'à l'influence de la composition des bases de données sur les performances des modèles demeurent relativement peu étudiés.

Plusieurs travaux soulignent pourtant que la qualité des données d'apprentissage constitue un facteur déterminant pour la performance des modèles d'apprentissage automatique (Freiesleben et al., 2020 ; Chan et al., 2022). Lorsque les données réelles sont insuffisantes ou indisponibles, les bases d'apprentissage sont généralement construites à partir de données générées par simulation. Certaines études utilisent des plans d'expériences pour générer ces données (Assid et al., 2025), tandis que d'autres s'appuient directement sur les résultats de simulation (Park et al., 2021 ; Rabaev et al., 2024). Toutefois, peu de travaux examinent de manière systématique l'influence de la composition de la base de données sur les performances des modèles. Fontana et al. (2023) ont étudié l'effet de différentes stratégies de génération des données sur la précision des modèles d'apprentissage automatique. Cette analyse demeure principalement centrée sur le choix du plan d'expériences utilisé pour générer les données et ne s'intéresse pas à certaines caractéristiques de la base d'apprentissage susceptibles d'influencer les performances des modèles. En particulier, les auteurs n'analysent pas si la base de données doit contenir uniquement des solutions optimales ou également des solutions réalisables, mais non optimales. Pourtant, dans les systèmes de production, les données générées peuvent correspondre à des configurations présentant différents niveaux de performance et ne se limitent pas nécessairement aux seules solutions optimales. Les auteurs n'étudient pas non plus l'effet que peut avoir la présence de solutions optimales sur la qualité de l'apprentissage et la précision des prédictions obtenues. Ainsi, malgré leur influence potentielle sur l'efficacité et la précision de l'apprentissage, ces aspects liés à la composition des bases de données demeurent encore peu explorés dans la littérature (Arboretti et al., 2021 ; Xu et al., 2024).

Par ailleurs, peu d'études ont exploré l'utilisation de l'apprentissage automatique pour déterminer directement les paramètres de contrôle de systèmes manufacturiers ou fabrication—

refabrication non fiables soumis simultanément aux défaillances des équipements et à la variabilité de la demande ou des retours. Les travaux existants s'intéressent principalement à la prévision de la demande, à la gestion des stocks ou à la sélection de politiques de décision prédéfinies. L'utilisation de modèles d'apprentissage capables d'établir directement une relation entre les caractéristiques du système et les paramètres de contrôle demeure encore limitée. Cette lacune ouvre la voie au développement d'approches combinant simulation, apprentissage automatique et optimisation afin de soutenir les décisions de contrôle dans des environnements industriels complexes.

1.6 Optimisation basée sur des modèles de substitution

Les travaux présentés dans la section précédente montrent que les techniques d'apprentissage automatique sont de plus en plus utilisées pour soutenir les décisions de contrôle dans les systèmes de production. Dans de nombreux problèmes d'optimisation, ces techniques ne sont toutefois pas utilisées de manière isolée, mais s'inscrivent dans une démarche plus générale connue sous le nom d'optimisation basée sur des modèles de substitution (Surrogate-Based Optimization, SBO). Cette famille d'approches vise à résoudre des problèmes dont l'évaluation de la fonction objective est coûteuse en temps de calcul en remplaçant cette dernière par un modèle approximatif dont l'évaluation est beaucoup plus rapide (Forrester et al., 2008).

Le principe général des approches de Surrogate-Based Optimization consiste à construire un modèle de substitution (surrogate model) à partir d'un ensemble de données générées par simulation, expérimentation ou toute autre source d'évaluation de la fonction objective. Une fois entraîné, ce modèle est utilisé au cours du processus d'optimisation afin de fournir une approximation rapide de la fonction objective pour différentes solutions candidates. Il ne détermine toutefois pas directement les variables de décision optimales, mais sert uniquement à approximer la fonction objective. Un algorithme d'optimisation est ensuite chargé d'explorer l'espace des variables de décision afin d'identifier les solutions optimales à partir des prédictions fournies par le modèle de substitution (Jin, 2011).

Plusieurs techniques ont été proposées dans la littérature pour construire ces modèles de substitution. Les premières approches reposaient principalement sur des méthodes statistiques, telles que les surfaces de réponse (Response Surface Methodology), le krigeage (Kriging), les processus gaussiens (Gaussian Processes) ou les fonctions de base radiale (Radial Basis Functions) (Koziel et Leifsson, 2013). Plus récemment, les progrès réalisés dans le domaine de l'apprentissage automatique ont conduit à l'utilisation de modèles plus flexibles, notamment les réseaux de neurones, les machines à vecteurs de support, les forêts aléatoires et les méthodes de gradient boosting (Bhosekar et Ierapetritou, 2018). Grâce à leur capacité à apprendre directement à partir des données et à modéliser des relations complexes et fortement non linéaires, ces modèles sont aujourd'hui de plus en plus utilisés comme modèles de substitution dans les problèmes d'optimisation complexes. Ils peuvent également être entraînés sur des bases de données intégrant simultanément un grand nombre de caractéristiques du système, ce qui leur permet de représenter les interactions entre ces variables sur un domaine d'apprentissage plus étendu (Pedrozo et al., 2025).

Pour résoudre cette étape d'optimisation, différents algorithmes peuvent être utilisés selon la nature du problème considéré. Dans les applications portant sur le contrôle des systèmes de production, plusieurs travaux ont notamment recours à des métaheuristiques, telles que le recuit simulé (Simulated Annealing), les algorithmes génétiques (Genetic Algorithms) ou l'optimisation par essaim particulaire (Particle Swarm Optimization) (Kosanoglu et al., 2024 ; Hu et al., 2025). Ces méthodes permettent d'explorer efficacement des espaces de recherche complexes et sont fréquemment associées aux modèles de substitution afin d'identifier les variables de décision minimisant la fonction objective.

Dans le domaine du contrôle des systèmes de production, plusieurs travaux ont adopté cette démarche. Par exemple, Behnamfar et al. (2022) utilisent un modèle d'apprentissage automatique entraîné à partir de données générées par simulation afin d'estimer les performances d'une politique de contrôle de type Hedging Point Policy. Plus récemment, Assid et al. (2025) proposent une approche intégrant un plan d'expériences, la simulation, l'apprentissage automatique et une phase d'optimisation afin de déterminer dynamiquement

les paramètres d'une politique conjointe de production et de réapprovisionnement. Cette intégration permet d'exploiter le modèle de substitution pour ajuster les paramètres de contrôle en fonction des conditions du système.

Les travaux recensés montrent que l'optimisation basée sur des modèles de substitution constitue aujourd'hui une approche prometteuse pour réduire le coût computationnel des problèmes d'optimisation. Son efficacité dépend toutefois fortement de la qualité du modèle de substitution ainsi que des données utilisées pour son apprentissage. Dans le domaine du contrôle des systèmes manufacturiers non fiables, peu de travaux se sont intéressés à l'application de cette approche sous demande variable, ainsi qu'à l'influence de la stratégie de construction des bases de données d'apprentissage sur les performances du modèle de substitution. Le présent mémoire s'inscrit dans cette perspective en développant une approche combinant simulation, apprentissage automatique et optimisation afin de déterminer efficacement les paramètres de contrôle de tels systèmes.

1.7 Problématique

Dans ce contexte, les questions de recherche abordées dans ce mémoire sont les suivantes :

- Comment les techniques d'intelligence artificielle, notamment l'apprentissage automatique, peuvent-elles être exploitées afin de déterminer efficacement les paramètres de contrôle dans des systèmes de production soumis à différentes sources d'incertitude ?
- Comment construire une base de données d'apprentissage permettant de représenter adéquatement les différentes conditions de fonctionnement du système et quel est l'impact de sa composition sur les performances des modèles d'apprentissage automatique ?
- Dans quelle mesure une approche fondée sur l'apprentissage automatique peut-elle réduire les efforts computationnels associés aux approches traditionnelles tout en maintenant la qualité des décisions de contrôle obtenues ?

- Dans quelle mesure cette approche peut-elle être appliquée à des systèmes de production de complexité croissante, allant d'un système manufacturier non fiable à un système hybride fabrication–refabrication caractérisé par la variabilité de la demande et des retours ?

Ce mémoire vise à répondre à ces questions en développant une méthodologie combinant simulation, apprentissage automatique et optimisation. L'approche est d'abord étudiée dans le contexte d'un système manufacturier non fiable afin d'analyser l'influence de différentes stratégies de construction de la base de données d'apprentissage. Elle est ensuite appliquée sous demande variable avant d'être étendue à un système hybride fabrication–refabrication caractérisé par la variabilité de la demande, des retours et l'incertitude liée à la disponibilité des ressources de production.

1.8 Conclusion du chapitre

Ce chapitre a présenté le contexte général de cette recherche ainsi qu'une revue de la littérature consacrée aux systèmes manufacturiers et fabrication–refabrication non fiables, aux politiques de contrôle de la production et aux applications de l'apprentissage automatique dans les systèmes de production. Les principaux concepts relatifs aux défaillances et réparations des équipements, à la variabilité de la demande et des retours ainsi qu'aux politiques de type HPP ont été examinés.

L'analyse de la littérature a mis en évidence plusieurs limites des approches existantes. D'une part, les méthodes traditionnelles reposent généralement sur des procédures numériques ou des approches d'optimisation basées sur la simulation nécessitant une nouvelle phase de résolution lorsque les conditions du système évoluent. D'autre part, malgré l'intérêt croissant porté à l'apprentissage automatique dans les systèmes de production, son utilisation pour la détermination directe des paramètres de contrôle demeure encore limitée. La revue de littérature a également montré que les questions relatives à la qualité et à la composition des

bases de données d'apprentissage restent encore peu explorées, malgré leur influence potentielle sur les performances des modèles.

Sur la base de ces constats, la problématique de recherche a été formulée autour du développement d'une approche fondée sur l'apprentissage automatique pour la détermination des paramètres de contrôle dans des systèmes de production soumis à différentes sources d'incertitude. Les objectifs de recherche ont été définis en tenant compte à la fois de l'étude de la construction des bases de données d'apprentissage et de l'application de l'approche proposée à des systèmes manufacturiers et fabrication–refabrication de complexité croissante.

Le chapitre suivant est consacré à l'étude d'un système manufacturier non fiable. Il présente le modèle considéré ainsi que l'approche développée pour la génération des données d'apprentissage, l'application des techniques de l'apprentissage automatique et l'analyse de l'influence de la construction de la base de données sur les performances prédictives des modèles.

CHAPITRE 2

APPLICATION DE L'APPRENTISSAGE AUTOMATIQUE AU CONTRÔLE D'UN SYSTÈME MANUFACTURIER NON FIABLE

2.1 Introduction

Les systèmes manufacturiers sujets aux pannes et réparations aléatoires nécessitent la mise en œuvre de politiques de contrôle capables d'assurer un équilibre entre les coûts de stockage et les coûts de pénurie. Parmi les modèles les plus étudiés dans la littérature figure le système M1P1 (une machine, un produit), qui constitue un cadre de référence pour l'analyse des problèmes de contrôle de production dans les systèmes non fiables (Akella et Kumar, 1986). Dans ce contexte, la détermination des paramètres de contrôle optimaux revêt une importance particulière, puisqu'elle influence directement les performances économiques du système.

Bien que des solutions analytiques existent pour certains systèmes relativement simples, comme le système M1P1 soumis à une demande constante, la détermination des paramètres de contrôle devient plus complexe lorsque de nouvelles sources d'incertitude sont introduites, notamment la variabilité de la demande. Dans ces situations, les solutions analytiques ne sont généralement plus disponibles et il devient nécessaire de recourir à des méthodes numériques ou à des approches d'optimisation basées sur la simulation. Ces méthodes permettent d'obtenir des paramètres de contrôle performants, mais elles nécessitent souvent des efforts de calcul importants et doivent être réappliquées chaque fois que les caractéristiques du système évoluent. Cette limitation devient particulièrement importante lorsque plusieurs paramètres du système sont susceptibles de varier simultanément (Yang et al., 2014).

Ce chapitre présente une approche fondée sur l'apprentissage automatique visant à déterminer les paramètres de contrôle du système M1P1. Dans un premier temps, le cas d'un système soumis à une demande constante est étudié. Une base de données est générée à partir de simulations afin d'entraîner différents modèles d'apprentissage automatique capables de prédire le coût total du système ainsi que le niveau de stock de sécurité optimal. Les

performances des modèles développés sont ensuite évaluées en les comparant aux résultats obtenus à partir de la solution analytique disponible pour ce système. Une analyse est également menée afin d'examiner l'impact de différentes stratégies de construction de la base de données d'apprentissage sur la précision des modèles développés.

Dans un second temps, l'approche proposée est étendue au cas d'un système soumis à une demande variable représentée par une distribution normale. Plusieurs analyses de sensibilité sont réalisées afin d'évaluer la capacité des modèles développés à reproduire les performances du système sous différentes conditions opérationnelles. Les résultats obtenus sont ensuite comparés à ceux issus d'une approche d'optimisation basée sur la simulation afin d'évaluer la précision et la robustesse de l'approche proposée.

Enfin, l'approche proposée est appliquée à un environnement caractérisé par une demande saisonnière variable. Dans ce contexte, le modèle d'apprentissage automatique est utilisé pour ajuster dynamiquement le paramètre de contrôle en fonction de l'évolution de la demande au cours du temps. Les résultats obtenus permettent d'évaluer l'intérêt d'une politique de contrôle dynamique par rapport à une politique reposant sur un seuil de contrôle fixe.

2.2 Systèmes manufacturiers non fiables sous demande constante

2.2.1 Description du système de production

Le système étudié est un système manufacturier composé d'une seule machine produisant un seul type de produit afin de satisfaire une demande constante des clients. La machine est sujette à des pannes et réparations aléatoires, ce qui affecte directement la capacité de production du système et l'évolution des niveaux d'inventaire.

Les produits fabriqués sont stockés dans un inventaire destiné à satisfaire la demande des clients. Lorsque le stock disponible devient insuffisant, les demandes non satisfaites sont accumulées sous forme de retard (backlog). Ainsi, le niveau d'inventaire peut prendre des valeurs positives lorsqu'un stock est disponible ou des valeurs négatives lorsque le système se

trouve en situation de pénurie. Les performances du système sont évaluées à partir du coût total moyen à long terme, qui représente la somme des coûts moyens de stockage et des coûts moyens de pénurie. Les coûts de stockage sont associés aux niveaux d'inventaire positifs, tandis que les coûts de pénurie sont liés aux niveaux d'inventaire négatifs correspondant aux demandes non satisfaites.

Le schéma général du système étudié est illustré à la figure suivante.




Figure 2.1 Schéma du système manufacturier MIP1 sous demande constante

2.2.2 Notations et variables du système

Pour le reste de cette section, les notations suivantes seront utilisées :

- $x(t)$: niveau de stock à l'instant t
- $u(t)$: taux de production à l'instant t
- d : demande
- U_{max} : capacité maximale de production de la machine
- $\alpha(t)$: état opérationnel de la machine à l'instant t
- $\alpha(t) = 1$: machine disponible
- $\alpha(t) = 0$: machine en panne
- x^+ : stock positif

- x^- : stock négatif
- C^+ : coût de stockage
- C^- : coût de pénurie
- MTTF : temps moyen avant défaillance (Mean Time To Failure)
- MTTR : temps moyen de réparation (Mean Time To Repair)
- CT : le coût total
- Z : seuil de couverture associé à la politique HPP

Les variables MTTF et MTTR permettent de représenter respectivement les durées moyennes de fonctionnement et de réparation de la machine. Ces paramètres caractérisent le comportement stochastique du système et influencent directement les performances du système de production.

2.2.3 Hypothèses de modélisation

Les principales hypothèses considérées dans les modèles développés sous demande constante sont les suivantes :

- Le système est composé d'une seule machine produisant un seul produit.
- La demande des clients est constante et connue.
- La machine est sujette à des pannes et réparations aléatoires.
- Les réparations sont considérées parfaites.
- Le taux maximal de production est connu.
- Le retard est autorisé lorsque la demande ne peut être satisfaite immédiatement.
- Les coûts de stockage et de pénurie sont connus.
- La production est interrompue durant les périodes de panne.
- Le niveau de stock évolue de manière continue dans le temps.
- Les matières premières sont toujours disponibles.

2.2.4 Dynamique du système

La dynamique du niveau de stock est généralement représentée par une équation différentielle continue reliant le taux de production et le taux de demande. Le niveau de stock évolue selon l'équation suivante :

$$\dot{x} = u(t) * \alpha(t) - d \quad (2.1)$$

Où $u(t) * \alpha(t)$ représente le taux de production effectif du système et d correspond au taux de demande constant.

Lorsque la machine est opérationnelle ($\alpha(t) = 1$), le système produit selon le taux de production défini par la politique de contrôle. En revanche, lorsque la machine est en panne ($\alpha(t) = 0$), la production devient nulle alors que la demande continue d'évoluer, entraînant une diminution du niveau de stock.

Le taux de production est également limité par la capacité maximale de la suivante :

$$0 \leq u(t) \leq U_{max} , \quad (2.2)$$

Dans ce contexte, l'objectif consiste à déterminer une politique de contrôle permettant d'ajuster dynamiquement le taux de production afin de minimiser les coûts globaux du système tout en assurant la satisfaction de la demande malgré les perturbations causées par les défaillances machines.

2.2.5 Politique de contrôle (HPP)

À fin de contrôler l'évolution du niveau d'inventaire dans le système M1P1 étudié, une politique à seuil critique (HPP) est utilisée. Introduite par Akella et Kumar (1986) puis approfondie par Bielecki et Kumar (1988), cette politique repose sur la définition d'un niveau de stock de sécurité noté Z , appelé Hedging Point. Ce seuil permet de protéger le système contre les interruptions de production causées par les défaillances de la machine. Le taux de production est alors ajusté en fonction de la position du niveau d'inventaire par rapport à ce seuil. Bielecki et Kumar (1988) ont montré que la fonction représentant l'évolution du coût

total moyen à long terme en fonction du seuil de couverture Z est convexe. Cette propriété garantit l'existence d'un minimum unique correspondant à la valeur optimale du seuil de couverture et facilite ainsi la détermination de la politique de contrôle optimale.

La structure de la politique HPP sous demande constante est généralement définie comme suit :

$$u(t) = \begin{cases} U_{max} & x(t) < Z \\ d & x(t) = Z \\ 0 & x(t) > Z \end{cases} \quad (2.3)$$

Cette politique peut être interprétée de la manière suivante :

- Lorsque le niveau de stock est inférieur au seuil Z , la machine produit à son taux maximal U_{max} afin de reconstituer rapidement le stock et réduire le risque de pénurie.
- Lorsque le niveau de stock atteint le seuil Z , le taux de production devient égal au taux de demande d , permettant ainsi de maintenir le système autour du niveau de couverture optimal.
- Lorsque le niveau de stock dépasse le seuil Z , la production est arrêtée afin d'éviter une accumulation excessive des inventaires et les coûts de stockage associés.

L'un des principaux avantages de la politique HPP réside dans sa simplicité d'implémentation et sa capacité à représenter efficacement le compromis entre les coûts de stockage et les coûts de pénurie. En maintenant un niveau de stock de sécurité, le système peut continuer à satisfaire la demande durant les périodes de panne, réduisant ainsi les retards et les ruptures de stock. Toutefois, le choix du seuil Z demeure fortement dépendant des paramètres du système, notamment les coûts, les caractéristiques des pannes et la capacité de production.

2.2.6 Approche proposée

L'objectif de ce travail est de développer une approche fondée sur l'apprentissage automatique capable d'assister la détermination des paramètres de contrôle du système manufacturier étudié. L'approche proposée combine la simulation, la génération de données d'apprentissage et l'optimisation afin d'identifier les paramètres de contrôle associés aux meilleures performances économiques. Le système M1P1 est utilisé comme cas d'étude en raison de la

disponibilité d'une solution analytique permettant d'évaluer la précision des résultats obtenus. La figure 2.2 présente les principales étapes de l'approche développée.




Figure 2.2 Structure générale de l'approche proposée

L'approche proposée est structurée en trois phases complémentaires : la génération d'une base de données par simulation, le développement de modèles d'apprentissage automatique et l'optimisation des paramètres de contrôle. Dans un premier temps, le modèle de simulation est utilisé pour générer une base de données regroupant, pour chaque scénario étudié, les différentes variables du système ainsi que le coût total moyen à long terme obtenu par simulation. Cette base de données est ensuite utilisée pour entraîner un modèle d'apprentissage automatique. Dans ce modèle, les différentes variables du système, notamment le seuil critique, constituent les variables d'entrée, tandis que le coût total moyen à long terme représente la variable de sortie à prédire. Le modèle apprend ainsi la relation entre les variables d'entrée et le coût total du système. Une fois entraîné, le modèle est intégré à la phase d'optimisation. L'algorithme d'optimisation génère une première valeur du seuil critique, qui est fournie au modèle d'apprentissage automatique avec les autres variables d'entrée du système. Le modèle prédit alors le coût total correspondant à cette configuration. L'algorithme d'optimisation

génère ensuite une nouvelle valeur de seuil critique, qui est à son tour fournie au modèle d'apprentissage automatique afin de calculer le coût total correspondant. Ce processus est répété de manière itérative jusqu'à ce que l'algorithme identifie la valeur du seuil critique minimisant le coût total moyen à long terme. Ainsi, le modèle d'apprentissage automatique joue le rôle d'une fonction permettant de calculer rapidement le coût total associé à chaque valeur du seuil critique, tandis que l'algorithme d'optimisation est chargé de rechercher la valeur optimale de seuil critique.

2.2.6.1 Phase 1 : Génération des bases de données

La première phase de l'approche proposée consiste à générer les données nécessaires au développement des modèles d'apprentissage automatique. Cette étape repose sur un modèle de simulation permettant de reproduire le comportement dynamique du système manufacturier sous différents scénarios de fonctionnement. Le modèle est développé sous Arena à l'aide du langage SIMAN et prend en compte à la fois les événements discrets associés aux pannes et réparations de la machine ainsi que l'évolution continue du niveau d'inventaire.

Pour un ensemble donné de paramètres du système, plusieurs simulations sont réalisées en faisant varier progressivement la valeur du seuil de couverture Z , tandis que les autres paramètres demeurent constants. Chaque simulation reproduit le fonctionnement du système manufacturier en tenant compte des défaillances, des réparations, de la production, de la satisfaction de la demande ainsi que de l'évolution des niveaux d'inventaire et de pénurie. À l'issue de chaque simulation, le coût total moyen à long terme associé à la valeur du seuil de couverture considérée est calculé. La répétition de cette procédure pour différentes valeurs de Z permet d'obtenir l'évolution du coût total en fonction du seuil de couverture et d'identifier la région dans laquelle se situe le coût minimal. Ces résultats constituent la base de la procédure de détermination de la valeur optimale du seuil de couverture.

Les résultats obtenus à partir des simulations sont utilisés pour construire les ensembles de données servant à l'apprentissage et à l'évaluation des modèles développés. Chaque scénario

est défini par un ensemble de paramètres caractérisant le système, notamment les coûts, les paramètres de fiabilité, la capacité de production et la demande.

2.2.6.2 Phase 2 : Modèle d'apprentissage automatique

La deuxième phase de l'approche proposée est consacrée au développement et à l'évaluation des modèles d'apprentissage automatique. L'objectif est d'identifier l'algorithme le plus approprié pour apprendre les relations entre les paramètres du système, les paramètres de contrôle et les performances obtenues. Une fois entraîné, le modèle retenu pourra être utilisé pour fournir rapidement des estimations pour de nouveaux scénarios de fonctionnement sans nécessiter l'exécution de nouvelles simulations ou procédures d'optimisation.

Trois algorithmes d'apprentissage automatique sont considérés dans cette étude : la forêt aléatoire (Xie, 2024), XGBoost (Zhong et al., 2023) et les réseaux de neurones (Bodendorf et al., 2021). Les bases de données générées lors de la phase précédente sont divisées en ensembles d'entraînement et de test afin d'évaluer les performances prédictives des différents modèles. Une procédure de validation croisée est également utilisée afin d'améliorer la robustesse de l'évaluation et de limiter les risques de surapprentissage.

Les performances prédictives des différents modèles sont évaluées à l'aide de deux indicateurs couramment utilisés dans les problèmes de régression : l'erreur absolue moyenne (MAE) et l'erreur quadratique moyenne (MSE) (Çakıt et Dağdeviren, 2023). La MAE et la MSE quantifient respectivement l'erreur moyenne et l'erreur quadratique entre les valeurs prédites et les valeurs observées.

Les expressions mathématiques utilisées pour calculer ces indicateurs sont présentées ci-dessous :

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (2.4)$$

$$MSE = 1 - \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (2.5)$$

Dans ces expressions, y_i représente la valeur observée, $\hat{y}_i$ la valeur prédite par le modèle et n le nombre d'observations. La MAE et la MSE mesurent respectivement l'erreur moyenne et l'erreur quadratique entre les valeurs observées et les valeurs prédites. Le modèle présentant les valeurs les plus faibles de MAE et de MSE.

2.2.6.3 Phase 3 : Optimisation des paramètres de contrôle

La troisième phase de l'approche proposée correspond au processus d'optimisation des paramètres de contrôle du système manufacturier. L'objectif principal consiste à déterminer la valeur du seuil de couverture Z minimisant le coût total du système.

Afin d'identifier la méthode d'optimisation la plus performante pour le problème étudié, plusieurs métaheuristiques sont évaluées et comparées. Les algorithmes considérés comprennent le recuit simulé (Simulated Annealing), l'algorithme génétique (Genetic Algorithm) et l'optimisation par essaim particulaire (Particle Swarm Optimization). Ces méthodes ont été largement utilisées pour résoudre des problèmes d'optimisation complexes caractérisés par des espaces de recherche étendus et des fonctions objectives non linéaires (Kosanoglu et al., 2024 ; Hu et al., 2025 ; Assid et al., 2025).

Les différentes métaheuristiques sont comparées sur la base de leurs performances afin d'identifier celle offrant les meilleurs résultats pour la détermination des paramètres de contrôle optimaux. L'algorithme retenu est ensuite utilisé conjointement avec le modèle d'apprentissage automatique sélectionné lors de la phase précédente pour rechercher les solutions associées au coût total minimal.

2.2.7 Évaluation des performances

Cette section présente l'évaluation des modèles d'apprentissage automatique développés dans le cadre de l'approche proposée. Les données utilisées sont générées à partir du modèle de simulation décrit précédemment. Les paramètres considérés pour la génération des différents scénarios de fonctionnement sont présentés au tableau 2.1.

Tableau 2.1 Paramètres du système

Paramètre	C^+	C^-	MTTF	MTTR	U_m	d
Valeur	[0.5, 3]	[8, 30]	Exp ([8, 12])	Exp ([0.4,1.2])	120	100

2.2.7.1 Comparaison des modèles d'apprentissage automatique

Cette expérience vise à identifier l'algorithme d'apprentissage automatique le plus approprié pour prédire le coût total du système manufacturier à partir des données générées lors de la phase précédente. Les trois algorithmes présentés dans la section 2.2.6.2, à savoir la forêt aléatoire, XGBoost et les réseaux de neurones, sont évalués et comparés à l'aide des indicateurs MAE et MSE.

Tableau 2.2 Performances des algorithmes

Modèle	MAE	MSE
Réseaux de neurones	7.547	183.21
XGBoost	14.581	686.06
Forêt aléatoire	10.893	571.35

Les résultats présentés au tableau 2.2 montrent que le modèle basé sur les réseaux de neurones présente les meilleures performances parmi les approches étudiées. Ce modèle obtient les valeurs les plus faibles valeurs de MAE et de MSE. Ces résultats indiquent que le réseau de neurones possède une meilleure capacité à reproduire les comportements du système

manufacturier et à prédire avec précision le coût total associé aux différentes configurations opérationnelles.

Le modèle de réseau de neurones retenu est composé d'une couche d'entrée recevant les paramètres du système manufacturier, de trois couches cachées de 64 neurones chacune ainsi que d'une couche de sortie produisant la valeur prédite du coût total CT . Les couches cachées utilisent la fonction d'activation ReLU, permettant de modéliser efficacement les relations non linéaires entre les variables, tandis que la couche de sortie emploie une activation linéaire, adaptée à la prédiction d'une variable continue. Les variables d'entrée comprennent notamment les coûts de stockage et de pénurie, les paramètres associés aux pannes et réparations (MTTF, MTTR), le taux maximal de production U_{max} , la demande ainsi que le seuil de couverture Z . Avant l'apprentissage, les données sont normalisées à l'aide de MinMaxScaler afin d'améliorer la stabilité et la convergence de l'entraînement. La base de données est ensuite répartie en 80 % pour l'apprentissage et 20 % pour les tests. L'entraînement du modèle est réalisé à l'aide de l'optimiseur Adam, sur 1000 époques avec une taille de lot (batch size) de 64, afin d'assurer une convergence efficace du réseau.




Figure 2.3 Structure générale du modèle de réseau de neurones

Les performances du modèle sont également analysées à travers les courbes d'apprentissage obtenues durant la phase d'entraînement. La figure suivante présente l'évolution des erreurs d'apprentissage et de validation au cours des itérations d'entraînement.




Figure 2.4 Évolution des erreurs durant l'entraînement du modèle

Les courbes d'apprentissage montrent une diminution progressive des erreurs sur les ensembles d'entraînement et de validation jusqu'à stabilisation de la fonction de perte. Cette évolution indique que le modèle apprend correctement les relations présentes dans les données tout en conservant une bonne capacité de généralisation.

Afin d'évaluer davantage la capacité prédictive du modèle développé, les valeurs prédites sont comparées aux valeurs réelles obtenues sur l'ensemble de test.




Figure 2.5 Comparaison entre les valeurs prédites et les valeurs réelles

L'alignement des points autour de la diagonale montre que le modèle de réseau de neurones reproduit correctement les comportements du système manufacturier et prédit avec précision les coûts associés aux différentes configurations étudiées.

2.2.7.2 Validation croisée

Afin d'évaluer de manière plus fiable les performances du modèle sélectionné et de vérifier sa capacité de généralisation, une procédure de validation croisée est réalisée. Cette approche consiste à diviser la base de données en plusieurs sous-ensembles (folds). À chaque itération, un sous-ensemble est utilisé pour la validation, tandis que les autres servent à l'entraînement du modèle. Cette opération est répétée jusqu'à ce que chaque sous-ensemble ait été utilisé une fois pour la validation.

Contrairement à une unique séparation entre les données d'apprentissage et de test, la validation croisée permet d'évaluer le modèle sur plusieurs partitions de la base de données.

Elle fournit ainsi une estimation plus représentative de ses performances et permet de vérifier que les résultats obtenus ne dépendent pas d'une partition particulière des données.

Tableau 2.3 Résultats de la validation croisée

Sous-ensembles	MAE	MSE
1	7.5470	183.2149
2	8.5376	200.8688
3	8.9305	182.3220

Les résultats obtenus montrent que le modèle conserve des performances stables pour les différentes partitions de données. Les faibles variations observées entre les différentes valeurs de MAE et MSE indiquent que le modèle présente une bonne capacité de généralisation et fournit des prédictions cohérentes, quelles que soient les données utilisées pour son apprentissage et sa validation. Ces résultats confirment ainsi la robustesse du modèle retenu.

Ainsi, l'évaluation des algorithmes d'apprentissage automatique permet d'identifier les réseaux de neurones comme l'approche la plus adaptée à la modélisation du système étudié. Ce modèle sera donc utilisé dans les étapes suivantes afin de prédire le coût total du système et d'être intégré au processus d'optimisation des paramètres de contrôle.

2.2.7.3 Comparaison des algorithmes d'optimisation

Afin de comparer les performances des différents algorithmes d'optimisation, l'erreur relative est calculée pour le seuil de couverture optimal Z ainsi que pour le coût total CT . L'erreur relative est retenue puisqu'elle normalise l'écart entre les valeurs obtenues par optimisation par simulation et celles prédites par l'approche proposée. Elle tient compte de l'ordre de grandeur des valeurs comparées, ce qui permet d'évaluer de manière plus représentative la précision des résultats pour l'ensemble des scénarios étudiés. Une faible erreur relative traduit une meilleure concordance entre les deux approches.

L'erreur relative est définie par :

$$Erreur\ relative(\%) = \frac{|V_{sim} - V_{pred}|}{V_{sim}} * 100 \quad (2.6)$$

Où V_{sim} représente la valeur obtenue par optimisation par simulation et V_{pred} la valeur prédite par le modèle d'apprentissage automatique.

Tableau 2.4 Comparaison des performances des algorithmes d'optimisation

Algorithme	Erreur relative moyenne sur (Z)	Erreur relative moyenne sur (CT)
PSO	4.775	4.65%
GA	5.025	4.23%
SA	2.75%	3.68%

Les résultats montrent que le recuit simulé (SA) obtient les meilleures performances parmi les algorithmes évalués. En effet, il présente l'erreur relative moyenne la plus faible aussi bien pour la prédiction du seuil optimal (Z) que pour celle du coût total (CT), avec respectivement 2,75 % et 3,68 %. L'algorithme génétique (GA) se classe en deuxième position avec des erreurs relatives moyennes de 5,02 % pour (Z) et de 4,23 % pour (CT). Bien que ses performances demeurent satisfaisantes, elles restent inférieures à celles obtenues par le recuit simulé. L'optimisation par essaim particulaire (PSO) présente les erreurs les plus élevées parmi les trois méthodes évaluées, avec une erreur relative moyenne de 6,77 % pour (Z) et de 4,65 % pour (CT).

Compte tenu de ces résultats, le recuit simulé est retenu comme algorithme d'optimisation dans la suite de l'étude.

2.2.8 Stratégie de structuration des bases de données

Afin d'analyser l'influence de la composition des données sur les performances du modèle prédictif, plusieurs expériences sont réalisées en faisant varier le type et le nombre de

configurations utilisées dans la base d'apprentissage. Dans cette étude, une configuration représente une combinaison des paramètres opérationnels du système manufacturier (C^+ , C^- , MTTF, MTTR, U_{max} , d) ainsi que la valeur correspondante du seuil de couverture Z et du coût total CT obtenu.

Trois catégories principales de configurations sont considérées :

- Les configurations optimales.
- Les configurations faisables.
- Les répliques.

Les configurations optimales correspondent aux solutions obtenues par optimisation basée sur la simulation. Pour chaque ensemble de paramètres du système, plusieurs simulations sont réalisées en faisant varier progressivement la valeur du seuil de couverture Z . Les coûts totaux obtenus permettent de construire la fonction représentant l'évolution du coût total en fonction du seuil de couverture. Conformément aux travaux de Bielecki et Kumar (1988), cette fonction présente une forme convexe caractérisée par un minimum unique. Cette propriété est exploitée afin de déterminer la valeur optimale du seuil de couverture Z^* , correspondant au coût total minimal. Un exemple de l'évolution du coût total moyen à long terme en fonction du seuil de couverture est présenté dans la partie « Optimisation » de la figure 2.2. Pour déterminer cette solution optimale, une fonction quadratique est utilisée afin de décrire l'évolution du coût total en fonction du seuil de couverture. Les coefficients de cette fonction sont ajustés à partir des données générées par simulation afin d'obtenir la fonction décrivant au mieux l'évolution de la fonction coût. Le choix d'une fonction quadratique est motivé par la forme convexe de la fonction coût, pour laquelle une fonction du second degré permet de représenter correctement son évolution et d'en déterminer directement le minimum. Une fois la fonction quadratique obtenue, son minimum est calculé afin d'identifier la valeur optimale du seuil de couverture Z^* , correspondant au coût total minimal. Cette valeur est ensuite comparée aux résultats obtenus par simulation afin de vérifier sa cohérence avec la région du coût minimal observée. Une seule configuration optimale est ainsi retenue pour chaque ensemble de paramètres du système.

Les configurations faisables sont générées en conservant les mêmes paramètres du système que la configuration optimale tout en modifiant progressivement la valeur du seuil de couverture Z . Contrairement aux configurations optimales, ces solutions ne correspondent pas nécessairement au coût minimal du système, mais permettent d'enrichir la base de données avec différents comportements opérationnels associés à plusieurs valeurs du paramètre de contrôle.

La troisième catégorie correspond aux répliques. Une réplique consiste à reproduire plusieurs simulations d'une même configuration en utilisant différentes graines aléatoires. Cette approche permet de représenter la variabilité stochastique du système manufacturier et de réduire l'effet du bruit aléatoire sur les données d'apprentissage.

Par exemple, pour une configuration optimale définie par un ensemble de paramètres $(C^+, C^-, \text{MTTF}, \text{MTTR}, U_{\max}, d)$, le processus d'optimisation permet d'obtenir une valeur optimale du seuil de couverture Z^* ainsi que le coût total associé CT^* . La deuxième catégorie de données consiste ensuite à générer plusieurs configurations faisables en conservant les mêmes paramètres système tout en utilisant différentes valeurs du seuil de couverture autour de Z^* . La troisième catégorie correspond finalement aux répliques réalisées à partir des configurations faisables en utilisant différentes graines aléatoires, produisant ainsi plusieurs valeurs du coût total.

2.2.8.1 Augmentation du nombre de configurations optimales

La première expérience consiste à analyser l'impact de l'augmentation du nombre de configurations optimales sur les performances du modèle prédictif. Dans cette étude, la taille de la base de données est progressivement augmentée de 70 à 200 configurations optimales afin d'évaluer l'évolution de l'erreur relative moyenne de prédiction du coût total.




Figure 2.6 Erreur relative moyenne du coût total en fonction du nombre de configurations optimales

Les résultats présentés à la figure 2.6 montrent que l'augmentation du nombre de configurations optimales améliore progressivement les performances du modèle d'apprentissage automatique. En effet, l'erreur relative moyenne passe de 23,82 % pour une base de données contenant 70 configurations optimales à 18,89 % pour 100 configurations, puis à 17,06 % pour 200 configurations. Cette diminution de l'erreur relative moyenne traduit une amélioration de la capacité du modèle à apprendre les relations entre les paramètres du système et le coût total associé.

Toutefois, les résultats montrent également que l'amélioration devient progressivement moins importante lorsque la taille de la base de données augmente. Cette évolution indique qu'au-delà d'un certain nombre de configurations optimales, les gains obtenus sur la précision des prédictions deviennent plus faibles.

2.2.8.2 Ajout des configurations générées par simulation

La deuxième expérience vise à analyser l'impact de l'intégration des configurations faisables générées par simulation dans la base d'apprentissage. Pour cette analyse, plusieurs bases de données sont construites en ajoutant progressivement des configurations faisables autour des solutions optimales. Pour chaque nombre de solutions optimales considéré (70, 100 et 200), 4 niveaux d'enrichissement sont étudiés en ajoutant respectivement 4, 9, 19 et 49 configurations faisables par solution optimale.




Figure 2.7 Erreur relative moyenne du coût total en fonction du nombre de configurations générées par simulation

Les résultats présentés à la figure 2.7 montrent que l'ajout de configurations faisables améliore significativement la précision des prédictions du modèle d'apprentissage automatique. Par exemple, pour une base de données contenant 70 solutions optimales, l'erreur relative moyenne passe de 23,82 % lorsque seules les solutions optimales sont utilisées à 11,07 % après l'ajout de 4 configurations faisables par solution optimale. Cette amélioration s'explique par le fait que ces configurations enrichissent les données d'apprentissage et permettent au modèle de mieux représenter l'influence du paramètre de contrôle sur les performances du système.

Les résultats montrent également que l'augmentation du nombre de solutions optimales continue d'améliorer les performances du modèle lorsque des configurations faisables sont intégrées. Ainsi, pour un enrichissement de 4 configurations faisables par solution optimale, l'erreur relative moyenne diminue de 11,07 % à 4,17 % lorsque le nombre de solutions optimales passe de 70 à 200.

Toutefois, les gains obtenus deviennent progressivement moins importants à mesure que le niveau d'enrichissement augmente. Dans le cas des bases de données construites à partir de 70 solutions optimales, l'erreur relative moyenne diminue de 23,82 % à 6,84 % avec l'ajout de 19 configurations faisables, puis atteint 6,17 % avec 49 configurations faisables. Une tendance similaire est observée pour les bases de données contenant 100 et 200 solutions optimales. Ces résultats suggèrent qu'au-delà d'un certain niveau d'enrichissement, l'ajout de nouvelles configurations faisables apporte des gains limités en termes de précision prédictive.

2.2.8.3 Ajout des configurations optimales dans une base fixe

Une troisième expérience est réalisée afin d'étudier l'effet de l'intégration progressive des configurations optimales dans une base de données de taille fixe. Pour cette analyse, 4 bases de données contenant chacune 2000 observations sont considérées. La première est constituée uniquement de configurations faisables générées par simulation. Par la suite, 70 de ces configurations sont remplacées par leurs configurations optimales correspondantes. La même procédure est ensuite appliquée afin d'obtenir des bases contenant respectivement 100 et 200 configurations optimales. Cette expérience permet d'évaluer l'influence de la proportion de configurations optimales sur les performances prédictives du modèle tout en maintenant une taille de base de données constante.




Figure 2.8 Erreur relative moyenne du coût total en fonction du nombre de configurations optimales intégrées dans une base fixe

Les résultats présentés à la figure 2.8 montrent que l'intégration des configurations optimales améliore progressivement la précision des prédictions du modèle. Lorsque la base de données ne contient aucune configuration optimale, l'erreur relative moyenne est de 5,20 %. L'intégration de 70 configurations optimales permet de réduire cette erreur à 4,72 %, tandis que l'utilisation de 100 configurations optimales la ramène à 4,26 %. Lorsque leur nombre atteint 200, l'erreur relative moyenne diminue davantage pour atteindre 3,70 %.

Ces résultats montrent que, pour une taille de base de données identique, les configurations optimales apportent une information particulièrement pertinente pour l'apprentissage du modèle. Leur intégration améliore la capacité du modèle à identifier les relations entre les paramètres du système et les performances associées, ce qui se traduit par une amélioration progressive de la précision des prédictions.

2.2.8.4 Impact du nombre de répliques

La dernière expérience vise à étudier l'effet du nombre de répliques sur les performances du modèle d'apprentissage automatique. Pour cette analyse, 8 bases de données sont construites

à partir de deux ensembles initiaux contenant respectivement 100 et 200 configurations optimales associées à 9 configurations faisables générées par simulation. Pour chaque ensemble, 4 bases de données sont générées en faisant varier le nombre de réplifications de chaque configuration faisable. À chaque réplification, une nouvelle graine aléatoire est utilisée afin de reproduire la variabilité stochastique du système.




Figure 2.9 Erreur relative moyenne du coût total en fonction du nombre de réplifications

Les résultats présentés à la figure 2.9 montrent que l'ajout de réplifications améliore la stabilité des prédictions et réduit l'erreur relative moyenne du modèle. Pour les bases de données contenant 100 configurations optimales, l'erreur relative moyenne diminue de 4,26 % avec une seule réplification à 3,25 % lorsque 4 réplifications sont utilisées. Une tendance similaire est observée pour les bases de données contenant 200 configurations optimales, où l'erreur relative moyenne passe de 3,70 % à 2,48 % lorsque le nombre de réplifications augmente de 1 à 4.

Cette amélioration s'explique par le fait que les réplifications permettent de mieux représenter la variabilité stochastique du système manufacturier et de réduire l'influence du bruit aléatoire associé aux résultats de simulation. Toutefois, les résultats indiquent également que les gains obtenus deviennent progressivement moins importants lorsque le nombre de réplifications

augmente. Au-delà de 3 réplications, les améliorations observées demeurent relativement limitées, ce qui suggère qu'une augmentation supplémentaire du nombre de réplications n'entraîne pas nécessairement une amélioration proportionnelle des performances du modèle.

2.2.8.5 Synthèse des résultats et efficacité de l'approche proposée

Les différentes expériences réalisées mettent en évidence l'importance de la composition de la base de données sur les performances du modèle d'apprentissage automatique. Les meilleurs résultats sont obtenus lorsque la base de données combine simultanément des configurations optimales, des configurations faisables générées par simulation ainsi que des réplications. Cette combinaison permet au modèle de mieux représenter les différents comportements du système manufacturier tout en conservant une taille de base de données raisonnable.

Les résultats montrent également que l'intégration de configurations faisables et de réplications améliore significativement la précision des prédictions par rapport à l'utilisation exclusive de configurations optimales. Toutefois, les expériences indiquent qu'au-delà d'un certain niveau d'enrichissement de la base de données, les gains obtenus deviennent progressivement moins importants. Il apparaît ainsi qu'un compromis doit être recherché entre la taille de la base de données et l'amélioration effective des performances du modèle.

Au-delà de la précision des prédictions, l'un des principaux avantages de l'approche proposée réside dans la réduction du temps nécessaire à la détermination des paramètres de contrôle. Une fois le modèle d'apprentissage automatique entraîné, l'évaluation d'un nouveau scénario de fonctionnement ne nécessite plus l'exécution complète d'une procédure d'optimisation basée sur la simulation.

Les résultats obtenus montrent que la détermination des paramètres de contrôle pour un scénario donné nécessite environ 17 secondes avec l'approche proposée, contre près de 15 minutes lorsqu'une procédure d'optimisation basée sur la simulation est utilisée. Cette différence devient particulièrement importante lorsque plusieurs scénarios doivent être

analysés ou lorsque le système étudié présente un niveau élevé de variabilité nécessitant un grand nombre d'évaluations.

L'ensemble des simulations et des calculs réalisés dans cette étude a été effectué sur une station de travail équipée d'un processeur AMD Ryzen 7 et de 32 Go de mémoire vive.

2.2.9 Mécanisme de l'approche proposée

Cette section présente le mécanisme général de l'approche proposée et la manière dont les différentes composantes développées précédemment sont intégrées afin de déterminer les paramètres de contrôle minimisant le coût total du système manufacturier. L'approche repose sur la combinaison de la simulation, de l'apprentissage automatique et de l'optimisation.

Dans le cadre de la politique HPP, le paramètre de contrôle principal correspond au seuil de couverture Z . L'objectif consiste à déterminer la valeur de ce seuil minimisant le coût total pour un ensemble donné de paramètres du système (C^+ , C^- , MTTF, MTTR, U_{max} , d).

Après la génération des données par simulation, les différentes configurations obtenues sont utilisées pour construire la base de données d'apprentissage. Celle-ci sert à entraîner le modèle de réseau de neurones retenu lors des étapes précédentes. Une fois entraîné, ce modèle est capable d'estimer rapidement le coût total associé à une configuration donnée sans recourir à de nouvelles simulations.

Afin de déterminer la valeur optimale du seuil de couverture, l'algorithme de recuit simulé est utilisé conjointement avec le modèle de réseau de neurones. À chaque itération, une nouvelle valeur candidate de Z est générée puis évaluée à l'aide du modèle prédictif. Selon le coût estimé et le mécanisme d'acceptation du recuit simulé, la solution est acceptée ou rejetée jusqu'à satisfaction du critère d'arrêt.

Le mécanisme général de l'approche proposée est illustré à la figure 2.10.




Figure 2.10 Mécanisme général de l'approche proposée

Le processus d'optimisation débute par la génération d'une valeur initiale du seuil de couverture Z . Cette solution est ensuite évaluée à l'aide du modèle de réseau de neurones afin d'obtenir une estimation du coût total correspondant.

À chaque itération, une nouvelle valeur candidate du seuil de couverture Z est générée à partir de la solution courante. Le modèle d'apprentissage automatique est alors utilisé pour prédire le coût total associé à cette nouvelle configuration. Si la solution candidate présente un coût inférieur à celui de la solution courante, elle est automatiquement acceptée. Dans certains cas, une solution présentant un coût plus élevé peut également être acceptée afin d'éviter un blocage prématuré de la recherche dans un optimum local.

Le mécanisme d'acceptation des solutions dépend de la température courante du recuit simulé. Au début du processus, une température élevée favorise l'exploration de l'espace de recherche en autorisant l'acceptation de certaines solutions moins performantes. À mesure que la température diminue, cette probabilité d'acceptation est réduite, orientant progressivement la recherche vers les régions les plus prometteuses de l'espace des solutions.

Le processus itératif se poursuit jusqu'à satisfaction du critère d'arrêt défini. La valeur finale du seuil de couverture correspond alors à la solution produisant le coût total prédit le plus faible pour les conditions opérationnelles considérées.

2.3 Contrôle des systèmes manufacturiers sous demande variable

2.3.1 Introduction à la demande variable

La section précédente a permis de développer et de valider l'approche proposée dans le cas d'un système manufacturier soumis à une demande constante. Toutefois, les systèmes manufacturiers réels évoluent généralement dans des environnements caractérisés par des fluctuations de la demande susceptibles d'affecter les décisions de production et les performances du système.

Dans ce contexte, l'approche développée précédemment est étendue au cas d'une demande variable. L'objectif consiste à évaluer la capacité du modèle d'apprentissage automatique à reproduire les performances du système sous différentes conditions de fonctionnement et à comparer les résultats obtenus avec ceux issus de l'optimisation par simulation.

2.3.2 Modélisation de la demande et adaptation de l'approche

Dans cette étude, la demande est considérée comme une variable aléatoire afin de représenter les fluctuations observées dans les environnements manufacturiers réels. Elle est modélisée par une distribution normale, un choix fréquemment adopté dans la littérature pour représenter l'incertitude associée à la demande (Wang et Gao, 2007 ; Botha, 2017 ; Ouaret, 2022).

La demande à l'instant t est définie par :

$$d(t) \sim N(\mu, \sigma^2) \quad (2.7)$$

Où μ représente la demande moyenne et σ l'écart-type caractérisant son niveau de variabilité.

Pour étudier le comportement du système sous demande variable, l'approche développée dans le cas de la demande constante est adaptée en intégrant les paramètres de la demande dans la construction de la base de données d'apprentissage. Celle-ci est constituée de configurations optimales, de configurations faisables générées autour de ces dernières ainsi que de répliques. Chaque scénario de fonctionnement est défini par un ensemble de paramètres caractérisant le système manufacturier, notamment les coûts de stockage et de pénurie (C^+ , C^-), les paramètres de fiabilité (MTTF, MTTR), la capacité maximale de production U_{max} ainsi que les paramètres de la demande μ et σ . Ces variables constituent les entrées utilisées pour générer les données d'apprentissage et développer les modèles d'apprentissage automatique.

Le système étudié demeurant identique à celui considéré sous demande constante, seule la modélisation de la demande est modifiée. La même procédure de détermination du seuil de couverture optimal est donc appliquée. Une fonction quadratique est utilisée pour décrire l'évolution du coût total en fonction du seuil de couverture, puis ses coefficients sont ajustés à partir des données issues des simulations. Le minimum de cette fonction est ensuite déterminé afin d'obtenir la valeur optimale du seuil de couverture correspondant au coût total minimal pour chaque scénario étudié.

Cette procédure est répétée pour chaque scénario considéré afin de déterminer la valeur optimale du seuil de couverture correspondante. Bien qu'elle permette d'obtenir des solutions de référence de haute qualité, cette démarche nécessite un grand nombre de simulations et d'ajustements successifs, ce qui entraîne un effort computationnel important. En fonction de la complexité du scénario étudié, le temps nécessaire à la détermination d'une seule solution optimale peut atteindre plusieurs dizaines de minutes. Cette contrainte justifie le recours, dans la suite de ce travail, à des modèles d'apprentissage automatique capables de reproduire rapidement les résultats de l'optimisation basée sur la simulation.

2.3.2.1 Comparaison des modèles d'apprentissage automatique

L'objectif de cette étape est d'identifier le modèle d'apprentissage automatique le plus approprié pour prédire les performances du système manufacturier sous demande variable. Trois algorithmes sont évalués dans cette étude : la forêt aléatoire (RF), XGBoost et les réseaux de neurones (NN). Les performances des différents modèles sont évaluées à l'aide de l'erreur absolue moyenne (MAE) et de la racine de l'erreur quadratique moyenne (RMSE). Le RMSE correspond à la racine carrée du MSE présenté dans le chapitre précédent. Le modèle présentant les meilleures performances est retenu pour la phase d'optimisation.

Tableau 2.5 Performances des modèles d'apprentissage automatique sous demande variable

Algorithme	MAE	RMSE
RF	38.684	82.871
XGBoost	40.032	72.43
NN	28.104	50.933

Les résultats montrent que le réseau de neurones artificiels obtient les meilleures performances parmi les algorithmes évalués. Il présente les plus faibles valeurs de MAE (28,104) et de RMSE (50,933). Ces résultats indiquent une meilleure capacité à reproduire les relations entre les

paramètres du système et le coût total. Le modèle de réseau de neurones, comme illustré à la figure 2.11, est donc retenu pour la suite de l'étude.




Figure 2.11 Structure du modèle de réseau de neurones sous demande variable

2.3.2.2 Validation croisée

Afin d'évaluer la robustesse du modèle retenu, une procédure de validation croisée à cinq plis est réalisée. Les résultats obtenus pour chaque pli sont présentés dans le tableau 2.6, tandis que les statistiques globales sont résumées dans le tableau 2.7.

Tableau 2.6 Résultats de la validation croisée du modèle de réseau de neurones

Sous-ensemble	MAE	RMSE
1	34.216	57.4
2	26.7	50.017
3	30.937	56.128
4	32.881	53.228
5	34.051	56.35

Tableau 2.7 Statistiques de la validation croisée du modèle retenu

Indicateur	Moyenne	Écart-type
MAE	31.757	2.786
RMSE	54.625	2.688

Les résultats montrent une grande stabilité des performances du modèle de réseau de neurones. Les erreurs obtenues restent également relativement stables d'un pli à l'autre, avec une MAE moyenne de 31,76 et une RMSE moyenne de 54,62.

Ces résultats confirment la robustesse du modèle développé et sa capacité à reproduire avec précision les relations entre les paramètres du système et le coût total sous demande variable.

2.3.2.3 Comparaison des algorithmes d'optimisation

Afin d'identifier la méthode d'optimisation la plus appropriée dans le contexte de la demande variable, les performances des trois algorithmes considérés dans cette étude, à savoir le recuit simulé (SA), l'algorithme génétique (GA) et l'optimisation par essaim particulaire (PSO), sont comparées à l'aide de l'erreur relative moyenne obtenue sur le seuil de couverture optimal Z et sur le coût total CT. Les résultats obtenus sont présentés dans le tableau 2.8.

Tableau 2.8 Comparaison des performances des algorithmes d'optimisation sous demande variable

Algorithme	Erreur relative moyenne sur (Z)	Erreur relative moyenne sur (CT)
GA	12.5%	5.75%
PSO	12.12%	3.17%
SA	5.38%	2.14%

Les résultats montrent que le recuit simulé obtient les meilleures performances parmi les algorithmes évalués. Il présente les plus faibles erreurs relatives moyennes pour le seuil de couverture optimal Z et le coût total CT, avec respectivement 5,38 % et 2,14 %.

L'optimisation par essai particulaire se classe en deuxième position avec des erreurs relatives moyennes de 12,12 % pour Z et de 3,17 % pour CT , tandis que l'algorithme génétique affiche les erreurs les plus élevées. Ces résultats indiquent que le recuit simulé constitue l'approche la plus appropriée pour la détermination des paramètres de contrôle optimaux dans le contexte de la demande variable.

2.3.3 Évaluation du modèle sous demande variable

Afin d'évaluer les performances de l'approche proposée sous demande variable, plusieurs analyses de sensibilité sont réalisées en faisant varier les principaux paramètres du système manufacturier. Cette étape permet d'analyser la capacité du modèle d'apprentissage automatique à reproduire les performances du système sous différentes conditions opérationnelles.

Dans cette étude, 3 paramètres principaux sont analysés : l'écart type de la demande σ ; le coût de pénurie C^+ et MTTF. L'objectif consiste à comparer les résultats obtenus par simulation à ceux prédits par le modèle d'apprentissage automatique afin d'évaluer la précision des prédictions produites. Les paramètres de référence utilisés dans cette analyse sont présentés dans le tableau 2.9.

Tableau 2.9 Paramètres du système

Paramètre	C^+	C^-	MTTF	MTTR	U_m	μ	σ
Valeur	1.5	10	$\exp(10)$	$\exp(0.75)$	120	100	10

La figure 2.12 présente l'évolution du coût total obtenue par simulation ainsi que celle prédite par le modèle d'apprentissage automatique (ML) lorsque les différents paramètres du système sont modifiés.




Figure 2.12 Analyse de sensibilité du coût total : comparaison entre la simulation et le modèle d'apprentissage automatique (ML)

2.3.3.1 Impact de la variabilité de la demande

La première analyse consiste à étudier l'effet de la variabilité de la demande sur les performances du système manufacturier. Pour cette expérience, la moyenne de la demande est

maintenue constante, tandis que l'écart type σ varie progressivement afin de représenter différents niveaux d'incertitude de la demande.

Les résultats présentés à la figure 2.12 (a) montrent que l'augmentation de la variabilité de la demande entraîne une hausse progressive du coût total du système manufacturier. Lorsque σ augmente de 0 à 20, le coût total obtenu par simulation passe de 310,75 à 746,27. Cette évolution s'explique par l'augmentation de l'incertitude associée à la demande, qui accroît les risques de pénurie et de surstockage.

Le modèle d'apprentissage automatique reproduit correctement cette tendance en prédisant des coûts totaux compris entre 300,96 et 822,22 pour les mêmes conditions de fonctionnement. Les résultats obtenus montrent une forte concordance entre les prédictions du modèle et les résultats de simulation, bien que de légers écarts soient observés pour les valeurs les plus élevées de σ . Ces écarts demeurent limités et confirment la capacité du modèle à reproduire avec précision l'effet de la variabilité de la demande sur les performances du système manufacturier.

2.3.3.2 Impact du temps moyen entre pannes (MTTF)

La deuxième analyse de sensibilité porte sur l'effet du temps moyen entre pannes MTTF sur les performances du système manufacturier.

Les résultats présentés à la figure 2.12 (b) montrent qu'une augmentation du MTTF entraîne une diminution progressive du coût total. Lorsque le MTTF augmente de 9,5 à 10,5, le coût total obtenu par simulation passe de 405,36 à 368,86.

Cette évolution s'explique par l'amélioration de la fiabilité du système manufacturier. Des périodes de fonctionnement plus longues entre les pannes réduisent la fréquence des interruptions de production, ce qui contribue à limiter les coûts associés aux situations de pénurie et aux perturbations du système.

Le modèle d'apprentissage automatique reproduit correctement cette tendance en prédisant une diminution du coût total de 381,19 à 337,45 pour les mêmes conditions de fonctionnement. Malgré de légers écarts observés aux valeurs extrêmes du MTTF, les résultats montrent que l'approche proposée représente correctement l'influence des paramètres de fiabilité sur les performances du système manufacturier.

2.3.3.3 Impact du coût de pénurie

La dernière analyse de sensibilité étudie l'effet du coût de pénurie C^- sur les performances du système manufacturier.

Les résultats présentés à la figure 2.12 (c) montrent que l'augmentation du coût de pénurie entraîne une hausse du coût total du système manufacturier. Lorsque le coût de pénurie augmente de 5 à 15, le coût total obtenu par simulation passe de 267,78 à 459,82. Cette évolution met en évidence l'importance des coûts associés aux situations de pénurie dans les systèmes manufacturiers non fiables.

Le modèle d'apprentissage automatique reproduit correctement cette tendance en prédisant des coûts totaux compris entre 256,54 et 454,00 sur l'intervalle étudié. Les résultats obtenus montrent une forte concordance entre les prédictions du modèle et les résultats de simulation, ce qui confirme la capacité de l'approche proposée à représenter correctement l'influence des paramètres de coût sur les performances du système manufacturier.

2.3.4 Évaluation du modèle sous demande variable

Afin d'évaluer davantage les capacités prédictives du modèle développé, plusieurs configurations supplémentaires non incluses dans la base d'apprentissage sont testées. Pour chaque configuration, les valeurs du seuil de couverture Z ainsi que le coût total CT prédits par le modèle d'apprentissage automatique sont comparés aux résultats obtenus par l'optimisation par simulation. Les résultats obtenus sont présentés dans le tableau 2.10.

Tableau 2.10 Comparaison entre les résultats de simulation et les prédictions du modèle

C^+	C^-	MTTR	MTTF	σ	Z	Z prédit	Erreur relative Z	CT	CT prédit	Erreur relative CT
1.7	18.9	exp(1.1)	exp(9)	17	1253	1260	0.56%	2188.47	2130.47	2.65%
1.2	21.7	exp(0.9)	exp(11.4)	19	869	865	0.46%	1118.96	1084.957	3.04%
2.7	34	exp(1)	exp(11.1)	15	612	606	0.98%	1903.81	1816.191	4.6%
1.8	38.5	exp(1)	exp(10.1)	7	610	600	1.64%	1171.79	1171.907	0.01%
2.7	45.2	exp(1)	exp(8.1)	13	1156	1164	0.69%	2942.45	3019.136	2.61%
1.2	17.4	exp(0.9)	exp(10.9)	8	365	363	0.55%	515.72	503.003	2.47%
1.5	39	exp(0.7)	exp(11.3)	10	313	301	3.83%	543.10	542.633	0.09%
3.3	34.7	exp(1.2)	exp(10.5)	18	1187	1191	0.34%	4246.88	4326.011	1.86%
3.9	46.1	exp(0.8)	exp(11.6)	11	287	286	0.35%	1348.21	1307.578	3.01%
2.7	36.7	exp(0.9)	exp(9.9)	15	578	601	3.98%	1763.54	1776.448	0.73%
2.1	16.5	exp(1)	exp(11)	1	341	324	4.99%	842.461	869.512	3.21%
2.8	28.2	exp(1.1)	exp(11.7)	8	519	526	1.35%	1605.15	1572.737	2.02%
4	46.7	exp(1)	exp(10.2)	15	668	672	0.6%	3001.36	2910.919	3.01%
3.5	30.9	exp(0.8)	exp(9.4)	10	302	307	1.66%	1250.95	1217.427	2.68%
2.5	30.7	exp(1)	exp(11.3)	11	600	588	2%	1403.23	1416.467	0.94%

C^+	C^-	MTTR	MTTF	σ	Z	Z prédit	Erreur relative Z	CT	CT prédit	Erreur relative CT
1.6	17.1	exp(1.2)	exp(9.5)	3	834	840	0.72%	1330.08	1341.21	0.84%
4	21.6	exp(1.1)	exp(8.3)	8	591	612	3.55%	2697.15	2709.94	0.47%
3.3	33.3	exp(0.9)	exp(10.7)	14	432	451	4.4%	1704.35	1663.569	2.39%
1.5	31.3	exp(1.2)	exp(9.5)	13	1556	1604	3.08%	2231.13	2272.013	1.83%
2	41.3	exp(0.8)	exp(9.5)	16	718	691	3.76%	1507.04	1435.11	4.77%

Les résultats montrent que les valeurs prédites par le modèle d'apprentissage automatique demeurent très proches de celles obtenues par l'optimisation par simulation. Les erreurs relatives observées pour le seuil de couverture Z ainsi que pour le coût total CT demeurent faibles pour l'ensemble des configurations étudiées, indiquant une bonne capacité de généralisation du modèle développé.

Afin de compléter cette analyse, une comparaison graphique entre les résultats simulés et les prédictions du modèle est présentée à la figure 2.13.




Figure 2.13 Comparaison entre les résultats simulés et les prédictions du modèle

Les résultats montrent un fort alignement entre les valeurs simulées et les valeurs prédites. La majorité des points se situe à proximité de la diagonale, indiquant que le modèle reproduit correctement les performances du système manufacturier pour différentes conditions opérationnelles.

2.3.5 Contrôle dynamique sous demande saisonnière variable

2.3.5.1 Demande saisonnière et principe de l'approche dynamique

Les analyses précédentes considèrent une demande variable modélisée par une distribution normale dont les paramètres demeurent constants durant toute la simulation. Dans ce contexte, une valeur optimale du seuil de couverture Z est déterminée avant le début de l'horizon de production et reste inchangée pendant toute la période étudiée.

Dans cette section, l'approche développée précédemment est étendue à un environnement dans lequel les caractéristiques de la demande évoluent au cours du temps. Plus précisément, la demande est représentée par une composante saisonnière à laquelle s'ajoutent des fluctuations aléatoires. Ainsi, les paramètres de la distribution de la demande ne sont plus constants, mais varient périodiquement au cours de l'horizon de planification. Cette représentation permet de mieux reproduire les variations observées dans plusieurs contextes industriels, où les besoins du marché fluctuent selon des cycles saisonniers tout en demeurant soumis à une incertitude aléatoire (Mattsson, 2010 ; Alves et Mateus, 2022).

Afin de tenir compte de cette évolution, le modèle d'apprentissage automatique développé précédemment est utilisé pour ajuster dynamiquement le seuil de couverture Z . À chaque mise à jour des paramètres de la demande, une nouvelle valeur de Z est estimée par le modèle, permettant ainsi d'adapter continuellement la politique de production aux conditions de fonctionnement du système. Cette approche conduit à une politique de contrôle dynamique dans laquelle le seuil de couverture évolue au cours du temps en fonction des variations de la demande. Lorsque la demande augmente, le niveau de protection tend à augmenter afin de limiter les risques de pénurie, tandis qu'une diminution de la demande conduit à une réduction du seuil afin de limiter les coûts de stockage. Ce comportement est cohérent avec les résultats rapportés par Polotski et al. (2019), qui montrent que les paramètres de contrôle optimaux évoluent en fonction des variations saisonnières de la demande.

Équation de la moyenne saisonnière :

$$\mu(k) = \mu_0 + A * \sin\left(\frac{2\pi k}{T}\right) \quad (2.8)$$

Où μ_0 représente la demande moyenne de référence, A le niveau de variabilité saisonnière de la demande, k l'indice temporel correspondant à la période de mise à jour de la demande et T la période du cycle saisonnier.

Équation de l'écart-type saisonnier :

$$\sigma(k) = \sigma_0 + B * \sin\left(\frac{2\pi k}{T}\right) \quad (2.9)$$

Où σ_0 représente l'écart-type moyen de référence, B le niveau de variabilité saisonnière de l'écart-type, K l'indice temporel et T c'est la période du cycle saisonnier.

Modélisation de la demande :

$$d(k) \sim N(\mu(k), \sigma(k)^2) \quad (2.10)$$




Figure 2.14 Évolution de la demande saisonnière variable au cours du temps

La figure 2.14 présente l'évolution de la demande générée selon le modèle proposé. La demande suit une tendance saisonnière caractérisée par une succession de phases de croissance et de décroissance. Des fluctuations aléatoires se superposent à cette tendance, ce qui permet de représenter la variabilité inhérente à la demande réelle. Ainsi, la demande observée à une période donnée n'est pas représentée par une valeur déterministe unique, mais par une réalisation aléatoire évoluant autour du niveau saisonnier attendu.

2.3.5.2 Comparaison des approches statique et dynamique

Afin d'évaluer l'intérêt de l'adaptation dynamique du paramètre de contrôle Z , les performances de l'approche proposée sont comparées à celles d'une politique statique dans laquelle une valeur fixe du paramètre Z est déterminée. Pour cette analyse, les paramètres du système manufacturier sont présentés dans le tableau suivant :

Tableau 2.11 Paramètres du système

Paramètre	C^+	C^-	MTTF	MTTR	U_m	μ_0	A	σ_0	B
Valeur	1	25	Exp(12)	Exp(1.2)	120	80	20	8	2

Afin d'évaluer l'influence de l'intensité des variations saisonnières sur les performances des approches étudiées, une analyse de sensibilité est réalisée en faisant varier le paramètre A, qui contrôle l'intensité de cette variabilité. Pour chaque scénario, le gain obtenu par l'approche dynamique est calculé à partir de la réduction relative du coût total moyen à long terme par rapport à la politique statique selon l'expression suivante :

$$Gain(\%) = \frac{|CT_{statique} - CT_{dynamique}|}{CT_{statique}} * 100 \quad (2.11)$$

Où $CT_{statique}$ et $CT_{dynamique}$ représentent respectivement les coûts totaux moyens obtenus avec les approches statique et dynamique.

Tableau 2.12 Comparaison des approches de contrôle statique et dynamique sous demande saisonnière variable

A	Approche	Z	CT	Gain
18	Statique	600	1046.52	7.2%
	Dynamique		971.15	
20	Statique	668	1299.38	10.17%
	Dynamique		1167.17	
22	Statique	1009	1826.76	13.03%
	Dynamique		1588.62	
24	Statique	1606	2747.43	14.62%
	Dynamique		2345.54	




Figure 2.15 Comparaison des coûts totaux moyens obtenus par les approches statique et dynamique pour différents niveaux de variabilité saisonnière de la demande

La figure 2.15 présente l'évolution du coût total moyen à long terme obtenu par les approches statique et dynamique pour différents niveaux de variabilité saisonnière de la demande. Les

résultats montrent que le coût total augmente avec l'intensité de la variabilité saisonnière pour les deux approches. En effet, lorsque le paramètre A passe de 18 à 24, le coût total de la politique statique augmente de 1046,52 à 2747,44, tandis que celui de l'approche dynamique évolue de 971,15 à 2345,54 sur le même intervalle.

Toutefois, l'approche dynamique présente systématiquement de meilleures performances que la politique statique. Pour un niveau de variabilité saisonnière correspondant à $A=18$, le coût total est réduit de 1046,52 à 971,15. Lorsque le niveau de variabilité saisonnière augmente ($A=20$), le coût total passe de 1299,39 à 1167,17. Pour $A=22$, il est réduit de 1826,76 à 1588,62. Enfin, pour le niveau de variabilité saisonnière le plus élevé considéré ($A=24$), le coût total diminue de 2747,44 à 2345,54. Ces résultats montrent que l'écart entre les deux approches s'accroît avec l'augmentation de la variabilité saisonnière de la demande.

Cette amélioration s'explique par le fait que la politique statique repose sur une valeur fixe du seuil de couverture Z utilisée durant toute la simulation. À l'inverse, l'approche dynamique ajuste continuellement ce paramètre en fonction de l'évolution de la demande, ce qui permet de mieux équilibrer les coûts de stockage et les coûts de pénurie. Les gains obtenus atteignent respectivement 7,20 %, 10,18 %, 13,04 % et 14,63 % pour les niveaux de variabilité saisonnière correspondant à $A=18$, $A=20$, $A=22$ et $A=24$. Ces résultats montrent que l'intérêt de l'adaptation dynamique devient plus important à mesure que la variabilité saisonnière de la demande augmente.

2.3.6 Discussion et limites des approches sous demande variable

Les résultats obtenus dans ce chapitre montrent que l'approche proposée permet de reproduire avec précision les performances du système manufacturier sous demande variable. Les comparaisons réalisées entre les résultats issus de l'optimisation par simulation et ceux prédits par le modèle d'apprentissage automatique mettent en évidence de faibles erreurs relatives aussi bien pour le coût total CT que pour le seuil de couverture Z . Les différentes analyses de sensibilité confirment également la capacité du modèle à représenter correctement l'influence

de la variabilité de la demande, des paramètres de fiabilité ainsi que des coûts de pénurie sur les performances du système.

Ces performances sont toutefois étroitement liées à la qualité et à la représentativité de la base de données utilisée pour l'entraînement. Les prédictions demeurent fiables lorsque les nouvelles configurations du système correspondent au domaine de variation des paramètres couvert lors de la génération de cette base de données. Cette observation met en évidence l'importance d'une stratégie de construction de la base d'apprentissage permettant de couvrir de manière adéquate les différentes combinaisons de paramètres susceptibles d'être rencontrées. Une couverture insuffisante de ce domaine pourrait en effet réduire la capacité du modèle à fournir des prédictions précises pour de nouvelles configurations du système.

Les résultats obtenus sous demande saisonnière variable mettent également en évidence l'intérêt d'adapter les paramètres de contrôle à l'évolution de la demande au cours du temps. L'approche dynamique proposée permet d'obtenir des coûts totaux inférieurs à ceux obtenus avec une politique statique reposant sur une valeur fixe du seuil de couverture. Les gains obtenus augmentent avec le niveau de variabilité saisonnière de la demande, atteignant respectivement 7,20 %, 10,18 %, 13,04 % et 14,63 % pour les différents scénarios étudiés.

Malgré ces résultats encourageants, le système étudié dans ce chapitre demeure relativement simple, puisqu'il comporte une seule machine produisant un seul type de produit. Dans les environnements industriels réels, les décisions de production sont souvent influencées par la présence de plusieurs ressources, de plusieurs produits ainsi que par d'autres sources d'incertitude pouvant accroître la complexité du problème de contrôle.

Les résultats obtenus permettent également de montrer qu'une approche fondée sur l'apprentissage automatique peut constituer une alternative efficace aux approches traditionnelles reposant sur l'optimisation basée sur la simulation. Une fois le modèle entraîné, l'évaluation des performances du système est réalisée en un temps très réduit par rapport aux procédures d'optimisation nécessitant des simulations répétées, tout en conservant une

excellente précision dans la prédiction du coût total et du seuil de couverture. Ces résultats démontrent ainsi que l'approche proposée permet de réduire significativement les efforts computationnels sans compromettre la qualité des décisions de contrôle obtenues.

Ces observations conduisent naturellement à l'étude de systèmes plus complexes. Le chapitre suivant s'intéresse ainsi à un système hybride fabrication–refabrication soumis simultanément à une demande variable, à des retours variables ainsi qu'à des défaillances des machines. Cette extension permettra d'évaluer dans quelle mesure l'approche développée pour un système manufacturier simple peut être généralisée à un environnement de production caractérisé par un niveau de complexité supérieur.

2.4 Conclusion du chapitre

Ce chapitre a présenté l'approche proposée pour le contrôle d'un système manufacturier non fiable de type M1P1 reposant sur l'intégration de la simulation, de l'apprentissage automatique et de l'optimisation. L'objectif principal était de développer une méthode permettant de déterminer efficacement les paramètres de contrôle du système tout en réduisant l'effort computationnel associé aux approches traditionnelles fondées sur l'optimisation par simulation.

Dans un premier temps, l'approche a été développée et validée dans le cas d'une demande constante. Les résultats obtenus ont permis d'évaluer différentes stratégies de construction de la base de données ainsi que plusieurs modèles d'apprentissage automatique et algorithmes d'optimisation. Les analyses réalisées ont conduit à l'identification d'une combinaison performante permettant de prédire avec précision le coût total du système et le seuil de couverture optimal.

Dans un second temps, l'approche a été étendue à un environnement caractérisé par une demande variable modélisée par une distribution normale. Les résultats des analyses de sensibilité ont montré que le modèle développé reproduit correctement l'influence des

principaux paramètres du système sur ses performances. Les comparaisons effectuées entre les résultats obtenus par optimisation par simulation et ceux prédits par le modèle ont mis en évidence de faibles erreurs de prédiction, confirmant la capacité de généralisation de l'approche proposée.

Enfin, une extension supplémentaire a été réalisée dans un contexte de demande saisonnière variable. Les résultats obtenus ont montré qu'une adaptation dynamique du seuil de couverture Z , basée sur les prédictions du modèle d'apprentissage automatique, permet de réduire le coût total moyen à long terme par rapport à une politique de contrôle statique. Cette étude a ainsi mis en évidence l'intérêt d'une politique de contrôle capable de s'adapter à l'évolution des caractéristiques de la demande au cours du temps.

Les résultats présentés dans ce chapitre permettent ainsi de répondre à plusieurs des questions de recherche formulées dans ce mémoire. Ils montrent qu'une approche combinant simulation, apprentissage automatique et optimisation permet de déterminer avec précision les paramètres de contrôle d'un système manufacturier non fiable. Les comparaisons réalisées avec l'optimisation basée directement sur la simulation montrent que l'approche proposée fournit des solutions de qualité comparable, caractérisées par de faibles erreurs relatives sur le seuil de couverture optimal et le coût total, tout en réduisant significativement les efforts computationnels associés à la recherche des paramètres de contrôle. Les résultats mettent également en évidence l'importance de la stratégie de construction des bases de données d'apprentissage. Ils montrent qu'une couverture adéquate du domaine de variation des paramètres du système constitue un élément essentiel pour garantir la qualité des prédictions et la capacité de généralisation des modèles développés sous différentes formes de variabilité de la demande.

Dans l'ensemble, les résultats obtenus confirment l'efficacité de l'approche proposée pour le contrôle des systèmes manufacturiers soumis à différentes formes d'incertitude liées à la demande et à la fiabilité des machines. Ils montrent également que l'apprentissage automatique constitue une alternative efficace à l'optimisation basée sur la simulation, en permettant de

réduire significativement les efforts computationnels tout en maintenant une excellente qualité des solutions, dès lors que les nouvelles configurations du système demeurent dans le domaine couvert par les données d'apprentissage. Le chapitre suivant étend cette démarche à un système hybride fabrication–refabrication soumis simultanément à une demande variable et à des retours variables. Cette extension permettra d'évaluer la capacité de l'approche proposée à être appliquée à un système de production de complexité supérieure, répondant ainsi à la dernière question de recherche formulée dans ce mémoire.

CHAPITRE 3

APPLICATION DE L'APPRENTISSAGE AUTOMATIQUE AU CONTRÔLE D'UN SYSTÈME HYBRIDE FABRICATION–REFABRICATION SOUS DEMANDE ET RETOURS VARIABLES

3.1 Introduction

Après avoir présenté dans le chapitre précédent les principaux travaux portant sur le contrôle des systèmes manufacturiers non fiables ainsi que les approches basées sur l'apprentissage automatique développées sous demande constante et variable, ce chapitre est consacré à l'étude d'un système hybride fabrication–refabrication.

Les systèmes hybrides fabrication–refabrication permettent de satisfaire la demande des clients à partir de deux sources de production complémentaires : la fabrication de nouveaux produits et la refabrication de produits retournés après utilisation. L'intégration de ces deux activités offre des avantages économiques et environnementaux importants, mais introduit également une complexité supplémentaire dans les décisions de planification et de contrôle de la production.

Afin de gérer efficacement les différentes interactions présentes dans ce type de système, une politique de contrôle à seuils de couverture est adoptée. L'approche proposée combine la simulation, l'apprentissage automatique et l'optimisation afin de déterminer les paramètres de contrôle permettant de minimiser le coût total du système.

Ce chapitre présente successivement la structure du système étudié, les hypothèses de modélisation retenues, la politique de contrôle appliquée ainsi que les équations décrivant sa dynamique.

3.2 Description du système étudié

Le système étudié dans ce chapitre est un système hybride fabrication–refabrication composé de deux unités de production distinctes permettant de satisfaire la demande des clients à partir de deux sources complémentaires. La première unité est dédiée à la fabrication de nouveaux produits à partir de matières premières, tandis que la seconde est consacrée à la refabrication de produits récupérés après utilisation. Les produits issus des deux unités sont considérés comme identiques du point de vue du client et alimentent un stock commun de produits finis. La figure 3.1 présente la structure générale du système ainsi que les principaux flux de matières intervenant dans son fonctionnement.

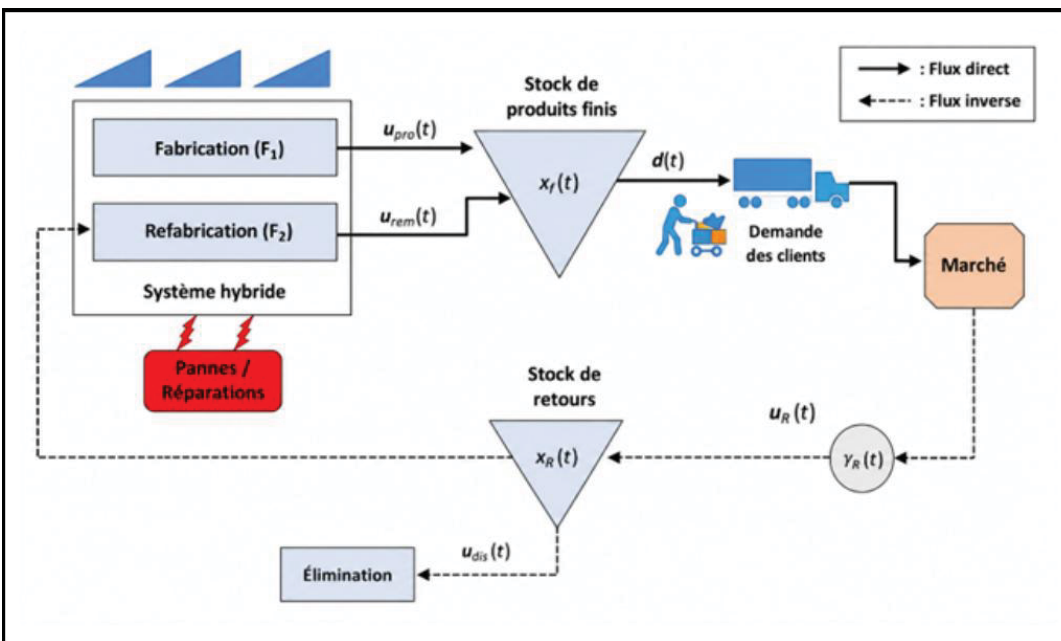


Figure 3.1 Structure générale du système HMRS étudié

La demande est satisfaite à partir du stock de produits finis. Lorsque le niveau de stock devient insuffisant pour répondre aux besoins du marché, les quantités non satisfaites sont enregistrées sous forme de demandes en attente. Cette demande est considérée comme variable et évolue au cours du temps. Cette variabilité représente les fluctuations observées dans de nombreux

environnements industriels et constitue une source importante d'incertitude pour les décisions de production.

Parallèlement, une partie des produits vendus est retournée vers le système après utilisation. Ces produits sont récupérés puis stockés dans un inventaire dédié avant d'être traités par l'unité de refabrication. Les quantités retournées sont également variables. Les retours constituent ainsi une source secondaire d'approvisionnement permettant de produire à nouveau des articles destinés à satisfaire la demande.

Les unités de fabrication et de refabrication sont toutes deux sujettes à des pannes et réparations aléatoires. Leur disponibilité varie donc au cours du temps en fonction de leur état opérationnel. Lorsqu'une unité est en panne, sa production est interrompue jusqu'à la fin de l'opération de réparation. Ces interruptions affectent directement la capacité de production du système et peuvent entraîner des variations importantes des niveaux de stock.

3.3 Notations et paramètres du système

Pour le reste de ce chapitre, les notations suivantes seront utilisées :

- $x_f(t)$: niveau de stock de produits finis à l'instant t
- $x_R(t)$: niveau des stocks de produits retournés à l'instant t
- C_f^+ : coût unitaire de stockage des produits finis
- C_R^+ : coût unitaire de stockage des produits retournés
- C^- : coût unitaire de pénurie des produits finis
- C_{Rejet} : coût unitaire de rejet
- C_{Pro} : coût unitaire de fabrication
- C_{Rem} : coût unitaire de refabrication
- $u_{Pro}(t)$: taux de fabrication à l'instant t
- $u_{Rem}(t)$: taux de refabrication à l'instant t
- $u_R(t)$: taux de retour à l'instant t
- $u_{dis}(t)$: taux de rejet à l'instant t

- $\gamma_R(t)$: coefficient de retour à l'instant t
- μ_γ : moyenne du coefficient de retour
- σ_γ : écart type du coefficient de retour
- $d(t)$: taux de demande à l'instant t
- μ_d : moyenne de la demande
- σ_d : écart type de la demande
- CT : le coût total
- MTTF : temps moyen avant défaillance (Mean Time To Failure)
- MTTR : temps moyen de réparation (Mean Time To Repair)
- $Z_f(t)$: seuil de couverture pour les produits finis à l'instant t
- $Z_R(t)$: seuil de couverture pour les produits retournés à l'instant t
- U_{Pro}^{Max} : capacité maximale de production de la machine de fabrication
- U_{Rem}^{Max} : capacité maximale de production de la machine de refabrication
- $\alpha_1(t)$: état de la machine de fabrication à l'instant t
- $\alpha_2(t)$: état de la machine de refabrication à l'instant t
- x_f^+ : stock positif de produits finis
- x_f^- : backlog ou stock négatif de produits finis

3.4 Hypothèses et paramètres du système

Les principales hypothèses considérées dans les modèles développés sont les suivantes :

- Le système est composé de deux unités de production : une unité de fabrication et une unité de refabrication.
- Les produits fabriqués et les produits refabriqués sont identiques du point de vue du client.
- La demande des clients est variable au cours du temps.
- Les produits retournés alimentent un inventaire dédié servant de source d'approvisionnement pour l'activité de refabrication.
- Les réparations sont considérées parfaites.
- Les taux maximaux de fabrication et de refabrication sont connus.

- Le retard est autorisé lorsque la demande ne peut être satisfaite immédiatement.
- Les coûts de stockage et de pénurie sont connus.
- La production est interrompue durant les périodes de panne.
- Le niveau des stocks de produits finis et de produits retournés évolue de manière continue dans le temps.
- Les matières premières nécessaires à l'activité de fabrication sont toujours disponibles.

3.5 Modélisation mathématique du système

Le système hybride fabrication–refabrication étudié est caractérisé par la présence simultanée de flux de fabrication, de flux de refabrication, de retours de produits, d'une demande variable ainsi que de pannes et réparations aléatoires des machines. Afin de représenter son évolution au cours du temps, l'état du système est défini à partir des niveaux de stock des produits finis et des produits retournés, ainsi que de la disponibilité des unités de fabrication et de refabrication.

À tout instant t , l'état des unités de fabrication et de refabrication est représenté respectivement par les variables $\alpha_1(t)$ et $\alpha_2(t)$. Ces variables prennent la valeur 1 lorsque le système correspondant est opérationnel et la valeur 0 lorsqu'il est indisponible en raison d'une panne ou d'une opération de réparation. Les niveaux de stock sont représentés par $x_f(t)$, correspondant à l'inventaire des produits finis, et $x_R(t)$, correspondant à l'inventaire des produits retournés. Lorsque $x_f(t)$ devient négatif, sa valeur représente une situation de pénurie ou de retard de livraison.

L'évolution de l'inventaire des produits finis dépend des activités de fabrication, des activités de refabrication ainsi que de la demande. Cette dynamique est donnée par :

$$\dot{x}_f(t) = u_{pro}(t) + u_{Rem}(t) - d(t) \quad (3.1)$$

Où $u_{pro}(t)$ représente le taux de fabrication, $u_{Rem}(t)$ le taux de refabrication et $d(t)$ le taux de demande à l'instant t .

L'évolution de l'inventaire des produits retournés dépend des produits retournés au système, des activités de refabrication ainsi que des opérations de rejet. Cette dynamique est exprimée par :

$$\dot{x}_R(t) = u_R(t) - u_{Rem}(t) - u_{dis}(t) \quad (3.2)$$

Où $u_R(t)$ représente le flux de retour et $u_{dis}(t)$ le taux de rejet.

Cette équation indique que l'inventaire des retours augmente avec les produits retournés et diminue lorsque ces produits sont soit refabriqués, soit éliminés du système. Les retours de produits sont proportionnels à la demande et sont modélisés par la relation suivante :

$$u_R(t) = \gamma(t) * d(t) \quad (3.3)$$

Où $\gamma(t)$ représente le coefficient de retour à l'instant t .

Cette variable permet de tenir compte de la variabilité associée aux quantités de produits retournés et constitue une seconde source d'incertitude dans le système étudié.

Les taux de fabrication et de refabrication sont limités par la disponibilité des machines ainsi que par leurs capacités maximales de production. Les contraintes associées au système de fabrication sont données par :

$$0 \leq u_{pro}(t) \leq U_{pro}^{Max} * I_{\{\alpha_1(t)=1\}} \quad (3.4)$$

Où U_{pro}^{Max} représente la capacité maximale du système de fabrication et $I_{\{\alpha_1(t)=1\}}$ est une fonction indicatrice.

Cette contrainte garantit que le taux de fabrication est nul lorsque l'unité est en panne et qu'il ne peut pas dépasser sa capacité maximale lorsqu'elle est disponible.

De manière similaire, les activités de refabrication sont soumises à la contrainte suivante :

$$0 \leq u_{Rem}(t) \leq U_{Rem}^{Max} * I_{\{\alpha_2(t)=1\}} * I_{\{x_R(t)>0\}} \quad (3.5)$$

Où U_{Rem}^{Max} représente la capacité maximale de l'unité de refabrication.

La présence du terme $I_{\{x_R(t)>0\}}$ traduit le fait que les opérations de refabrication ne peuvent être réalisées que lorsqu'il existe des produits retournés disponibles dans l'inventaire $x_R(t)$.

Dans le système étudié, la demande et le coefficient de retour sont considérés comme des variables aléatoires. Le taux de demande à l'instant t , noté $d(t)$, suit une loi normale de moyenne μ_d et d'écart-type σ_d :

$$d(t) \sim N(\mu_d, \sigma_d^2) \quad (3.6)$$

De manière similaire, le coefficient de retour à l'instant t , noté $\gamma_R(t)$, est modélisé par une loi normale de moyenne μ_γ et d'écart-type σ_γ :

$$\gamma_R(t) \sim N(\mu_\gamma, \sigma_\gamma^2) \quad (3.7)$$

Les performances du système sont évaluées à partir du coût total moyen à long terme, qui prend en compte les coûts de stockage des produits finis, les coûts de stockage des produits retournés, les coûts de pénurie, les coûts de rejet ainsi que les coûts associés aux activités de fabrication et de refabrication. La fonction coût est définie par :

$$J = \lim_{T \rightarrow \infty} \frac{1}{T} E \left[\int_0^T (C^+ * x_F^+(t) + C^- * x_F^-(t) + C_{rejet} * u_{dis}(t) + C_{pro} * u_{pro}(t) + C_{rem} * u_{rem}(t)) dt \right] \quad (3.8)$$

Où C^+ représente le coût de stockage, C^- le coût de pénurie, C_{rejet} le coût associé au rejet des produits retournés, C_{pro} le coût unitaire de fabrication et C_{rem} le coût unitaire de refabrication.

Les termes $x_f^+(t)$ et $x_f^-(t)$ représentent respectivement le stock positif de produits finis et la quantité de produits en retard de livraison. Ils sont définis par :

$$x_f^+(t) = \max(x_f(t), 0) \quad (3.9)$$

$$x_f^-(t) = \max(0, -x_f(t)) \quad (3.10)$$

L'objectif consiste alors à déterminer les décisions de contrôle permettant de minimiser le coût total moyen à long terme du système.

3.6 Politique de contrôle appliquée

Afin de répondre au problème de planification et de contrôle de la production dans le système hybride fabrication–refabrication étudié, une politique de contrôle intégrée est mise en œuvre afin de coordonner dynamiquement les activités de fabrication, de refabrication et de gestion des retours. Cette politique est basée sur le principe de la politique à seuils de couverture, largement utilisée dans la littérature pour le contrôle des systèmes de production sujets aux pannes et réparations aléatoires (Polotski et al., 2019).

La politique proposée repose sur deux paramètres de contrôle principaux : le seuil de couverture des produits finis $Z_f(t)$ et le seuil de couverture des produits retournés $Z_R(t)$. Le seuil $Z_f(t)$ représente le niveau cible de stock de produits finis à maintenir à l'instant t , tandis que $Z_R(t)$ définit le niveau admissible de produits retournés dans le système à ce même instant.

Les décisions de fabrication, de refabrication et de rejet sont définies à partir des lois de commande suivantes.

Le taux de fabrication est donné par :

$$u_{pro}(t) = \begin{cases} U_{Pro}^{Max} & \text{si } x_f(t) < Z_f(t) \\ d(t) - u_{Rem}(t) & \text{si } x_f(t) = Z_f(t) \\ 0 & \text{sinon} \end{cases} \quad (3.11)$$

Cette politique indique que lorsque le niveau de stock des produits finis est inférieur au seuil $Z_f(t)$, le système de fabrication fonctionne à sa capacité maximale afin de reconstituer rapidement le stock. Lorsque le niveau de stock atteint la valeur cible $Z_f(t)$, le taux de fabrication est ajusté afin de compenser uniquement la partie de la demande qui n'est pas satisfaite par le système de refabrication. Enfin, lorsque le niveau de stock dépasse ce seuil, la fabrication est interrompue.

Le taux de refabrication est défini par :

$$u_{Rem}(t) = \begin{cases} U_{Rem}^{Max} & \text{si } x_R(t) > 0 \\ u_R(t) & \text{si } x_R(t) = 0 \\ 0 & \text{sinon} \end{cases} \quad (3.12)$$

Lorsque des produits retournés sont présents, la machine de refabrication fonctionne à sa capacité maximale afin d'alimenter le stock de produits finis. Lorsque l'inventaire des retours est nul, le taux de refabrication est limité par le flux de retour entrant.

Afin d'éviter une accumulation excessive des produits retournés, une politique de rejet est également introduite. Le taux de rejet est donné par :

$$u_{dis}(t) = \begin{cases} u_R(t) & \text{si } x_R(t) > Z_R(t) \\ 0 & \text{sinon} \end{cases} \quad (3.13)$$

Cette politique permet de contrôler le niveau de l'inventaire des produits retournés. Lorsque l'inventaire des retours dépasse le seuil $Z_R(t)$, une partie des retours entrants est éliminée afin de maintenir un niveau de stock acceptable et d'éviter une accumulation excessive des produits retournés dans le système.

Les paramètres de contrôle $Z_f(t)$ et $Z_R(t)$ jouent ainsi un rôle central dans le fonctionnement du système. Le seuil $Z_f(t)$ permet d'ajuster les décisions de fabrication en fonction du niveau du stock de produits finis, tandis que le seuil $Z_R(t)$ contrôle l'accumulation des produits retournés dans l'inventaire de retours. Ces paramètres influencent directement les coûts de stockage, les coûts de pénurie, les coûts de rejet ainsi que le niveau d'utilisation des produits retournés. La détermination des valeurs optimales de $Z_f(t)$ et $Z_R(t)$ constitue donc le principal problème de contrôle étudié dans ce chapitre.

3.7 Approche proposée

La détermination des paramètres de contrôle $Z_f(t)$ et $Z_R(t)$ constitue un problème complexe en raison de la présence simultanée de plusieurs sources d'incertitude, notamment la variabilité

de la demande, la variabilité des retours ainsi que les pannes et réparations des unités de fabrication et de refabrication.

Comme dans le chapitre précédent, l'approche proposée combine la simulation, l'apprentissage automatique et l'optimisation afin de déterminer les paramètres de contrôle minimisant le coût total moyen à long terme du système.

La démarche générale est identique à celle présentée au chapitre 2. Elle repose sur trois étapes successives : (i) la génération d'une base de données par simulation, (ii) le développement d'un modèle d'apprentissage automatique permettant de prédire le coût total du système et (iii) l'utilisation de ce modèle au sein d'un algorithme d'optimisation afin de rechercher les paramètres de contrôle optimaux.

La principale différence par rapport au système manufacturier étudié précédemment concerne la phase d'optimisation. Alors que le chapitre 2 visait à déterminer une seule variable de contrôle, le système hybride fabrication–refabrication nécessite l'optimisation simultanée de deux paramètres de contrôle, Z_f et Z_R . Le problème d'optimisation devient ainsi bidimensionnel et la fonction coût est représentée sous la forme d'une surface de réponse reliant le coût total moyen à long terme aux deux paramètres de contrôle. Une représentation de cette surface est présentée dans la partie « Optimisation » de la figure 3.2.

Pour déterminer les valeurs optimales des deux seuils de couverture, un plan d'expériences est d'abord utilisé afin de générer les scénarios de simulation couvrant l'espace de recherche. Les résultats obtenus sont ensuite exploités pour construire une surface de réponse (Response Surface Methodology – RSM) décrivant l'évolution du coût total en fonction des paramètres Z_f et Z_R . Cette surface permet d'identifier la combinaison des deux seuils minimisant le coût total moyen à long terme.

La qualité du modèle de surface de réponse est ensuite évaluée avant son utilisation dans le processus d'optimisation. Cette évaluation repose sur une analyse de variance (ANOVA)

permettant de vérifier la significativité statistique du modèle, ainsi que sur plusieurs indicateurs de performance, notamment le coefficient de détermination, le coefficient de détermination ajusté et l'erreur absolue moyenne (MAE). Une analyse des résidus est également réalisée afin de vérifier la qualité de l'ajustement et la validité du modèle obtenu. Une fois cette étape de validation réalisée, la surface de réponse est utilisée pour déterminer la combinaison des seuils minimisant le coût total moyen à long terme.

Comme dans le chapitre précédent, cette procédure doit être répétée pour chaque scénario étudié. Bien qu'elle permette d'obtenir des solutions de référence, elle nécessite un nombre important de simulations, ce qui entraîne des temps de calcul élevés lorsque le nombre de scénarios augmente. Cette contrainte justifie l'utilisation de modèles d'apprentissage automatique capables d'apprendre les relations entre les paramètres du système et le coût total afin de reproduire rapidement les résultats de l'optimisation basée sur la simulation.




Figure 3.2 Représentation de la phase d'optimisation pour le système hybride fabrication–refabrication

La figure 3.2 présente la structure générale de l'approche proposée ainsi que les principales interactions entre les différentes phases.

3.8 Évaluation des performances

3.8.1 Comparaison des modèles d'apprentissage automatique

Le tableau 3.1 présente les performances prédictives obtenues pour les quatre algorithmes d'apprentissage automatique étudiés.

Tableau 3.1 Comparaison des performances des algorithmes

Model	MAE	RMSE
NN	109.91	172.72
kNN	79.65	142.29
XGBoost	76.68	117.64
FA	48.96	87.99

Le modèle de réseau de neurones NN présente les performances les plus faibles parmi les approches étudiées, avec un MAE de 109.91 et un RMSE de 172.72. Les erreurs obtenues restent supérieures à celles observées pour les autres modèles.

L'algorithme k plus proche voisin kNN améliore les résultats obtenus par le réseau de neurones. Avec un MAE de 79.65 et un RMSE de 142.29, il fournit des prédictions plus précises. Néanmoins, ses performances restent inférieures à celles des méthodes basées sur les arbres de décision.

Le modèle XGBoost présente également de très bonnes performances avec un MAE de 76.68, un RMSE de 117.64. Ces résultats confirment sa capacité à modéliser les relations non linéaires existant entre les paramètres du système et le coût total. Toutefois, malgré ces bonnes performances, XGBoost demeure légèrement moins précis que le modèle de forêt aléatoire (FA).

Afin de compléter cette analyse, la figure 3.3 présente la comparaison entre les valeurs réelles obtenues par simulation et les valeurs prédites par le modèle de forêt aléatoire sur l'ensemble des données de test.




Figure 3.3 Comparaison entre les valeurs réelles et prédites obtenues avec le modèle de forêt aléatoire

L'alignement des points autour de la diagonale montre que les prédictions produites par le modèle sont très proches des valeurs observées. Cette forte corrélation confirme la capacité du modèle à fournir des estimations fiables du coût total pour de nouvelles configurations du système.

Compte tenu de ses performances supérieures selon les 3 indicateurs considérés, le modèle de forêt aléatoire (FA) est retenu pour la suite de l'étude et sera utilisé dans la phase d'optimisation des paramètres de contrôle $Z_f(t)$ et $Z_R(t)$.

3.8.2 Ajustement des hyperparamètres et validation croisée

Bien que le modèle de forêt aléatoire (FA) ait obtenu les meilleures performances parmi les algorithmes étudiés, des améliorations supplémentaires peuvent être obtenues en ajustant correctement ses hyperparamètres. Cette étape vise à identifier la configuration du modèle permettant de maximiser la précision des prédictions tout en conservant une bonne capacité de généralisation.

L'ajustement des hyperparamètres a été réalisé à l'aide d'une procédure de recherche systématique (Grid Search). Cette méthode consiste à tester différentes combinaisons des principaux paramètres du modèle afin d'identifier la configuration minimisant l'erreur de prédiction. Les paramètres étudiés comprennent notamment le nombre d'arbres de décision, la profondeur maximale des arbres ainsi que le nombre minimal d'observations nécessaires pour effectuer une division ou constituer une feuille terminale. Les performances du modèle avant et après ajustement des hyperparamètres sont présentées dans le tableau 3.2.

Tableau 3.2 Performances du modèle de forêt aléatoire avant et après ajustement des hyperparamètres

Configuration	MAE	RMSE
Avant ajustement	48.96	87.99
Après ajustement	48.03	83.97

Les résultats montrent que l'ajustement des hyperparamètres permet d'améliorer les performances du modèle. Une diminution des valeurs de MAE et RMSE est observée. Cette amélioration confirme l'intérêt de calibrer les paramètres du modèle avant son utilisation dans la phase d'optimisation.

Le modèle de forêt aléatoire retenu est constitué de 200 arbres de décision (`n_estimators = 200`), dont la profondeur n'est pas limitée (`max_depth = None`) afin de permettre une modélisation plus flexible des relations entre les variables. Pour limiter le surapprentissage tout en conservant une bonne capacité de généralisation, chaque division d'un nœud nécessite un minimum de 5 échantillons (`min_samples_split = 5`), tandis qu'une feuille terminale doit contenir au moins un échantillon (`min_samples_leaf = 1`). De plus, l'ensemble des variables d'entrée est considéré lors de chaque division (`max_features = 1.0`), ce qui permet à chaque arbre d'exploiter toute l'information disponible. Cette configuration, obtenue après ajustement des hyperparamètres, offre un compromis entre précision prédictive, robustesse et capacité de généralisation du modèle.

Afin d'évaluer la robustesse du modèle ajusté, une procédure de validation croisée à 5 plis (5-Fold Cross-Validation) a également été réalisée. Cette méthode consiste à diviser la base de données en 5 sous-ensembles de taille équivalente. À chaque itération, 4 sous-ensembles sont utilisés pour l'apprentissage, tandis que le cinquième est utilisé pour la validation. Le processus est répété 5 fois de manière à ce que chaque sous-ensemble soit utilisé une fois comme ensemble de validation. Les résultats obtenus pour les 5 plis sont présentés dans le tableau 3.3.

Tableau 3.3 Résultats de la validation croisée à 5 plis du modèle de forêt aléatoire

Sous-ensembles	MAE	RMSE
1	47.33	83.55
2	54.83	103.40
3	47.30	76.81
4	47.22	79.63
5	45.40	77.47
Moyenne	48.42	84.17

L'analyse de ces résultats montre une faible dispersion des indicateurs de performance entre les différents plis de validation. Les valeurs du MAE et du RMSE demeurent relativement stables d'un pli à l'autre.

Les résultats obtenus confirment ainsi la robustesse du modèle de forêt aléatoire. Ce modèle est retenu comme composante prédictive de l'approche proposée et sera utilisé dans la phase d'optimisation présentée dans la section suivante.

3.8.3 Comparaison des algorithmes d'optimisation

Après la sélection du modèle d'apprentissage automatique, une comparaison des algorithmes d'optimisation est réalisée afin d'identifier la méthode la plus performante pour la détermination des paramètres de contrôle optimaux.

Tableau 3.4 Comparaison des performances des algorithmes d'optimisation sous demande variable

Algorithme	Erreur relative Z_f (%)	Erreur relative Z_R (%)	Erreur relative CT (%)
GA	13.8	3.34	7.54
PSO	7.67	8.07	5.29
SA	5.98	1.65	0.8

Les résultats présentés dans le tableau 3.4 montrent des différences significatives entre les 3 algorithmes d'optimisation évalués. L'algorithme génétique (GA) présente les écarts les plus importants pour le paramètre Z_f et pour le coût total CT, avec des erreurs relatives de 13,80 % et 7,54 %, respectivement. L'optimisation par essaim particulaire (PSO) améliore ces résultats en réduisant l'erreur relative associée à Z_f à 7,67 % et celle du coût total à 5,29 %. Toutefois, son erreur relative pour Z_R demeure relativement élevée (8,07 %). Le recuit simulé (SA) obtient les meilleures performances globales. Il présente les plus faibles erreurs relatives pour Z_R et pour le coût total, avec respectivement 1,65 % et 0,80 %. L'erreur relative associée à Z_f est également la plus faible parmi les 3 méthodes comparées. Ces résultats montrent que le recuit simulé est la méthode la plus adaptée au problème étudié.

3.9 Expériences numériques

3.9.1 Scénario de base

Afin d'évaluer les performances de l'approche proposée et de disposer d'un point de référence pour les différentes analyses réalisées dans ce mémoire, un scénario de base est défini. Ce scénario représente une condition de fonctionnement typique du système hybride fabrication–refabrication soumis à une demande variable, à des retours variables ainsi qu'à des pannes et réparations aléatoires des machines de fabrication et de refabrication. Les valeurs retenues pour les différents paramètres sont présentées dans le tableau 3.5.

Tableau 3.5 Paramètres du scénario de base

Paramètre	C_f^+	C_R^+	C^-	C_{Rejet}	MTTF	MTTR	$d(t)$	$\gamma_R(t)$	U_{Pro}^{Max}	U_{Rem}^{Max}	C_{Pro}	C_{Rem}
Valeur	2	1.5	150	1000	Log (60, 6)	Log (10, 5)	Normal (80, 10)	Normal (0.4, 0.1)	80	70	30	5

Le scénario de base constitue le point de départ des expériences numériques présentées dans ce chapitre. Les analyses comparatives et les études de sensibilité sont réalisées à partir de cette configuration afin d'évaluer l'impact des variations des différents paramètres sur les seuils optimaux Z_f et Z_R ainsi que sur le coût total moyen à long terme du système.

3.9.2 Résultats du scénario de base

Cette section présente les résultats obtenus pour le scénario de base à l'aide de l'approche proposée. Les résultats obtenus pour les 2 approches sont présentés dans le tableau 3.6. Pour chaque méthode, le coût total moyen obtenu est reporté ainsi que les paramètres de contrôle correspondants lorsqu'ils sont disponibles.

Tableau 3.6 Comparaison des résultats obtenus par optimisation basée sur la simulation et par l'approche proposée

Méthode	Z_f	Z_R	Coût total
Optimisation basée sur la simulation	985	522	5490.15
Approche proposée (ML + SA)	—	—	4775.07

L'analyse des résultats montre que l'approche proposée permet d'obtenir un coût total inférieur à celui obtenu par l'optimisation basée sur la simulation. Alors que la méthode de référence conduit à un coût total de 5490.15, l'approche combinant l'apprentissage automatique et le recuit simulé obtient un coût de 4775.07. Une réduction relative d'environ 13.02 % du coût total est observée. Cette amélioration met en évidence l'efficacité de l'approche proposée pour la détermination des paramètres de contrôle du système hybride fabrication–refabrication.

Au-delà de l'amélioration des performances économiques, ces résultats montrent qu'il est possible d'utiliser un modèle prédictif pour remplacer un grand nombre d'évaluations par simulation au cours du processus d'optimisation. Cette caractéristique permet de réduire considérablement le temps de calcul nécessaire à la recherche des paramètres optimaux tout en maintenant un niveau élevé de performance.

Les résultats obtenus pour le scénario de base constituent une première validation de l'approche développée. Afin d'évaluer sa robustesse sous différentes conditions opérationnelles, plusieurs analyses de sensibilité sont présentées dans les sections suivantes.

3.9.3 Analyse de sensibilité

Après avoir évalué les performances de l'approche proposée dans le scénario de base, une analyse de sensibilité est réalisée afin d'étudier son comportement sous différentes conditions opérationnelles. L'objectif de cette analyse est d'évaluer l'impact de différents paramètres sur les performances du système et de vérifier que l'approche proposée reproduit correctement les tendances observées à l'aide de l'optimisation basée sur la simulation. Cette étape permet également d'évaluer la capacité de la politique dynamique à adapter les seuils de contrôle aux variations des conditions de fonctionnement.

L'analyse porte sur plusieurs paramètres susceptibles d'influencer les performances du système hybride fabrication–refabrication. Ces paramètres comprennent notamment le coût de pénurie,

la disponibilité des machines de fabrication et de refabrication, la variabilité de la demande ainsi que la variabilité du coefficient de retour.

La disponibilité des machines constitue un facteur important influençant les performances du système étudié. Elle représente la proportion du temps pendant laquelle une machine est opérationnelle et peut être exprimée par :

$$A\% = \frac{MTTF}{MTTF + MTTR} * 100 \quad (3.14)$$

Pour chaque expérience, un seul paramètre est modifié tandis que les autres conservent les valeurs du scénario de base. Cette démarche permet d'isoler l'effet du paramètre étudié sur les seuils de contrôle optimaux ainsi que sur le coût total moyen à long terme du système.

Les résultats obtenus à l'aide de l'approche proposée sont systématiquement comparés à ceux issus de l'optimisation basée sur la simulation.

3.9.3.1 Effet du coût de pénurie sur le coût total

Le coût de pénurie constitue l'un des paramètres les plus importants dans les systèmes de production soumis à une demande variable. Il représente la pénalité associée à l'incapacité du système à satisfaire immédiatement la demande des clients et reflète les pertes économiques engendrées par les retards de livraison ou les ruptures de stock. Afin d'évaluer l'influence de ce paramètre sur les performances du système, une analyse de sensibilité est réalisée en faisant varier le coût de pénurie tout en conservant les autres paramètres à leurs valeurs de base.




Figure 3.4 Variation du coût total en fonction du coût de pénurie

La figure 3.4 présente l'évolution du coût total moyen en fonction du coût de pénurie pour l'approche basée sur la simulation et l'approche dynamique proposée (ML).

Les résultats montrent que l'augmentation du coût de pénurie entraîne une augmentation du coût total dans les 2 cas. Pour l'optimisation basée sur la simulation, le coût total passe de 4975,03 à 5490,15, puis à 5726,77 lorsque le coût de pénurie augmente de 100 à 150 puis à 200. De manière similaire, le coût total obtenu par l'approche proposée évolue de 4606,32 à 4775,07, puis à 4975,03.

Toutefois, l'approche proposée fournit systématiquement des coûts inférieurs à ceux obtenus par l'optimisation basée sur la simulation. Cette différence s'explique par la capacité de la politique dynamique à ajuster les seuils de contrôle $Z_f(t)$ et $Z_R(t)$ en fonction de l'évolution des conditions de fonctionnement du système, permettant ainsi une meilleure gestion des stocks de produits finis et des produits retournés.

Par ailleurs, l'écart entre les 2 approches tend à augmenter lorsque le coût de pénurie devient plus élevé. La réduction relative du coût total passe d'environ 7,41 % lorsque le coût de pénurie est égal à 100 à près de 13,13 % lorsqu'il atteint 200. Ce résultat montre que les avantages de la politique dynamique deviennent plus importants dans les environnements où les ruptures de stock sont fortement pénalisées.

3.9.3.2 Effet de la disponibilité des machines sur le coût total

La disponibilité des machines de fabrication et de refabrication influence directement les performances du système étudié. Afin d'évaluer l'effet de ce paramètre, une analyse de sensibilité est réalisée en faisant varier la disponibilité des machines tout en conservant les autres paramètres à leurs valeurs de base.




Figure 3.5 Variation du coût total en fonction de la disponibilité de la machine

La figure 3.5 présente l'évolution du coût total moyen en fonction de la disponibilité des machines pour l'optimisation basée sur la simulation et pour l'approche dynamique proposée (ML).

Les résultats montrent que l'augmentation de la disponibilité entraîne une diminution du coût total dans les 2 cas. Pour l'optimisation basée sur la simulation, le coût total passe de 6717,10 à 5490,15, puis à 5051,84 lorsque la disponibilité augmente respectivement de 83 % à 85,5 % puis à 88 %. Une évolution similaire est observée pour l'approche proposée, où le coût total diminue de 4977,18 à 4775,07, puis à 4732,34.

Cette diminution s'explique par le fait qu'une meilleure disponibilité réduit les interruptions de production causées par les pannes. Les machines de fabrication et de refabrication sont alors capables de satisfaire plus efficacement la demande, ce qui contribue à réduire les coûts de pénurie et les coûts de stockage associés aux fluctuations des inventaires.

Cette comparaison met également en évidence que l'approche proposée fournit systématiquement des coûts inférieurs à ceux obtenus par l'optimisation basée sur la simulation. La réduction relative du coût total est d'environ 25,9 % lorsque la disponibilité est de 83 %, de 13,0 % pour une disponibilité de 85,5 % et de 6,3 % lorsque la disponibilité atteint 88 %.

Ces résultats montrent que les bénéfices de la politique dynamique sont particulièrement importants lorsque le système est fortement affecté par les pannes. Lorsque la disponibilité augmente et que le système devient plus stable, les performances des 2 approches tendent à se rapprocher, bien que l'approche proposée conserve les meilleurs résultats pour l'ensemble des configurations étudiées.

3.9.3.3 Effet de la variabilité de la demande sur le coût total

La variabilité de la demande constitue l'une des principales sources d'incertitude dans les systèmes hybrides fabrication–refabrication. Afin d'évaluer l'impact de ce paramètre sur les performances du système, une analyse de sensibilité est réalisée en faisant varier l'écart-type de la demande tout en conservant les autres paramètres à leurs valeurs de base.




Figure 3.6 Variation du coût total en fonction d'écart type de la demande

La figure 3.6 présente l'évolution du coût total moyen en fonction de l'écart-type de la demande pour l'optimisation basée sur la simulation et pour l'approche dynamique proposée (ML).

Les résultats montrent que l'augmentation de la variabilité de la demande entraîne une augmentation du coût total dans les deux cas. Pour l'optimisation basée sur la simulation, le coût total passe de 4654,64 à 5490,15, puis à 7120,17 lorsque l'écart-type de la demande augmente respectivement de 5 à 10, puis à 15. Une évolution similaire est observée pour l'approche proposée, où le coût total augmente de 4560,23 à 4775,07, puis à 5957,67.

Cette augmentation s'explique par le fait qu'une demande plus variable rend plus difficile l'adaptation des décisions de fabrication et de refabrication aux besoins réels du système. Les

fluctuations plus importantes de la demande entraînent une hausse des situations de surstockage ou de pénurie, ce qui se traduit par une augmentation des coûts de stockage et des coûts de pénurie.

Cette comparaison met également en évidence que l'approche proposée fournit systématiquement des coûts inférieurs à ceux obtenus par l'optimisation basée sur la simulation. La réduction relative du coût total est d'environ 2,0 % lorsque l'écart-type est de 5, de 13,0 % pour un écart-type de 10 et de 16,3 % lorsque l'écart-type atteint 15.

Ces résultats montrent que les avantages de la politique dynamique deviennent plus importants à mesure que l'incertitude de la demande augmente. La capacité de l'approche proposée à ajuster les seuils de contrôle Z_f et Z_R en fonction des variations de la demande, lui permet de mieux gérer les fluctuations du système et de limiter l'augmentation du coût total dans les environnements fortement incertains.

3.9.3.4 Effet de la variabilité du coefficient de retour

Le coefficient de retour constitue un paramètre important dans les systèmes hybrides fabrication–refabrication, puisqu'il détermine la proportion des produits demandés qui reviennent dans le système pour être refabriqués. Afin d'évaluer l'influence de ce paramètre sur les performances du système, une analyse de sensibilité est réalisée en faisant varier l'écart-type du coefficient de retour tout en conservant les autres paramètres à leurs valeurs de base.




Figure 3.7 Variation du coût total en fonction d'écart type du coefficient de retour

La figure 3.7 présente l'évolution du coût total moyen en fonction de l'écart-type du coefficient de retour pour l'optimisation basée sur la simulation et pour l'approche dynamique proposée (ML).

Les résultats montrent que l'augmentation de la variabilité du coefficient de retour entraîne une augmentation du coût total dans les deux cas. Pour l'optimisation basée sur la simulation, le coût total passe de 4350,39 à 5490,15, puis à 7887,50 lorsque l'écart-type du coefficient de retour augmente respectivement de 0,05 à 0,10, puis à 0,15. Une évolution similaire est observée pour l'approche proposée, où le coût total augmente de 4192,39 à 4775,07, puis à 6289,20.

Cette augmentation s'explique par le fait qu'une plus grande variabilité du coefficient de retour rend plus incertaine la quantité de produits retournés disponible pour la refabrication. Cette incertitude complique la planification des activités de fabrication et de refabrication, ce qui peut entraîner des déséquilibres entre les capacités de production, les niveaux de stock et la

demande à satisfaire. Il en résulte une augmentation des coûts de stockage, de pénurie ainsi que des coûts associés à la gestion des retours.

Cette comparaison met également en évidence que l'approche proposée fournit systématiquement des coûts inférieurs à ceux obtenus par l'optimisation basée sur la simulation. La réduction relative du coût total est d'environ 3,6 % lorsque l'écart-type est de 0,05, de 13,0 % pour un écart-type de 0,10 et de 20,3 % lorsque l'écart-type atteint 0,15.

Ces résultats montrent que les bénéfices de la politique dynamique deviennent plus importants à mesure que la variabilité du coefficient de retour augmente. Lorsque les retours sont relativement stables, les performances des deux approches restent proches. En revanche, lorsque les quantités de produits retournés deviennent plus imprévisibles, l'approche proposée s'adapte plus efficacement aux variations du système et permet de limiter davantage l'augmentation du coût total.

3.9.3.5 Discussion des résultats

Les analyses de sensibilité réalisées montrent que les performances du système sont fortement influencées par les paramètres liés à l'incertitude opérationnelle. L'augmentation du coût de pénurie, de la variabilité de la demande et de la variabilité du coefficient de retour entraîne une hausse du coût total, tandis qu'une amélioration de la disponibilité des machines contribue à réduire ce coût.

Les résultats obtenus montrent également que l'approche dynamique proposée surpasse systématiquement l'optimisation basée sur la simulation pour l'ensemble des configurations étudiées. Les gains observés deviennent particulièrement importants lorsque le niveau d'incertitude augmente, notamment en présence d'une forte variabilité de la demande ou de coûts de pénurie élevés. De plus, l'approche proposée conserve de meilleures performances lorsque la variabilité du coefficient de retour devient plus importante, ce qui met en évidence sa capacité à s'adapter aux fluctuations du flux de produits retournés. Ces résultats soulignent

ainsi l'intérêt d'ajuster dynamiquement les seuils de contrôle aux conditions de fonctionnement du système plutôt que d'utiliser des seuils fixes.

Par ailleurs, les analyses de sensibilité mettent en évidence que l'approche proposée reproduit les mêmes tendances générales que celles observées avec l'optimisation basée sur la simulation. Les variations des différents paramètres conduisent aux mêmes évolutions du coût total, ce qui confirme la cohérence des solutions obtenues et la capacité de l'approche développée à représenter correctement le comportement du système.

Les bonnes performances observées doivent toutefois être interprétées dans le domaine de validité du modèle d'apprentissage automatique. Les prédictions demeurent fiables lorsque les nouvelles configurations du système correspondent à des combinaisons de paramètres couvertes par la base de données d'entraînement. En revanche, lorsque les paramètres du système s'écartent significativement des plages de variation utilisées lors de la génération de cette base, la qualité des prédictions peut diminuer et conduire à des estimations moins représentatives du comportement réel du système. Cette limitation met en évidence l'importance de la stratégie de construction de la base de données, qui constitue l'un des éléments clés de l'approche proposée. Une couverture adéquate du domaine de variation des paramètres du système est essentielle pour garantir la qualité des prédictions et la capacité de généralisation du modèle d'apprentissage automatique.

L'approche développée met également en évidence les avantages de l'apprentissage automatique comme outil d'aide à la décision pour les systèmes de production complexes. Contrairement au système manufacturier étudié au chapitre précédent, où un seul seuil de couverture devait être déterminé, le système hybride fabrication–refabrication nécessite l'optimisation simultanée de deux paramètres de contrôle Z_f et Z_R . Cette augmentation de la dimension du problème accroît considérablement l'espace de recherche ainsi que le nombre de simulations nécessaires pour identifier la combinaison optimale. La détermination des paramètres optimaux par optimisation basée sur la simulation peut ainsi nécessiter plusieurs dizaines de minutes pour un seul scénario. Une fois le modèle d'apprentissage automatique

entraîné, l'évaluation des performances du système et la recherche des paramètres optimaux sont réalisées en quelques secondes seulement, tout en conservant une excellente précision des solutions obtenues. Ces résultats démontrent ainsi que l'approche proposée permet de réduire significativement les efforts computationnels sans compromettre la qualité des décisions de contrôle.

Enfin, les résultats obtenus montrent que l'approche développée pour un système manufacturier simple peut être étendue avec succès à un système hybride fabrication–refabrication caractérisé par la présence simultanée de demandes variables, de retours variables et de défaillances des machines. Cette généralisation met en évidence la capacité de l'approche proposée à traiter des environnements de production de complexité croissante tout en conservant de bonnes performances prédictives et décisionnelles.

3.10 Conclusion du chapitre

Ce chapitre a présenté l'application de l'approche proposée au contrôle d'un système hybride fabrication–refabrication soumis à des demandes variables, à des retours variables ainsi qu'à des pannes et réparations aléatoires des machines de fabrication et de refabrication. L'objectif principal était d'évaluer la capacité de l'approche combinant simulation, apprentissage automatique et optimisation à déterminer efficacement les paramètres de contrôle Z_f et Z_R permettant de minimiser le coût total moyen à long terme du système.

Dans un premier temps, plusieurs algorithmes d'apprentissage automatique ont été évalués afin d'identifier le modèle le plus approprié pour la prédiction du coût total. Les résultats obtenus ont montré que le modèle de forêt aléatoire (FA) offre les meilleures performances selon les indicateurs MAE et RMSE. Ce modèle a ainsi été retenu comme composante prédictive de l'approche proposée.

Dans un second temps, les performances de l'approche dynamique développée ont été comparées à celles d'une optimisation basée sur la simulation reposant sur des seuils fixes. Les

résultats ont montré que l'approche proposée permet d'obtenir systématiquement des coûts inférieurs à ceux de la politique statique de référence. Les gains observés sont particulièrement marqués dans les environnements caractérisés par un niveau élevé d'incertitude, notamment en présence de coûts de pénurie élevés, d'une forte variabilité de la demande, d'une forte variabilité du coefficient de retour ou d'une faible disponibilité des machines.

Les résultats obtenus dans ce chapitre permettent ainsi de compléter la validation de l'approche proposée en démontrant qu'elle peut être appliquée à un système de production plus complexe que le système manufacturier M1P1 étudié au chapitre précédent. Malgré l'intégration simultanée de plusieurs sources d'incertitude, notamment la variabilité de la demande, la variabilité des retours ainsi que les défaillances des machines, l'approche développée conserve une excellente capacité de prédiction et permet de déterminer efficacement les paramètres de contrôle du système. Ces résultats apportent ainsi une réponse à la question de recherche finale en confirmant que cette approche peut être généralisée à des systèmes de production de complexité croissante.

Les résultats obtenus confirment ainsi le potentiel de l'approche proposée pour le contrôle de systèmes de production soumis à de multiples sources d'incertitude. Bien que ces résultats soient encourageants, l'approche développée pourrait être étendue à des contextes décisionnels encore plus complexes intégrant d'autres contraintes opérationnelles et d'autres sources d'incertitude. L'étude de ces extensions permettrait d'évaluer davantage sa robustesse et son potentiel d'application dans des environnements industriels variés.

CONCLUSION

Ce mémoire s'est intéressé à l'application de l'apprentissage automatique au contrôle de systèmes de production soumis à différentes sources d'incertitude, notamment les pannes des machines, la variabilité de la demande et la variabilité des retours de produits. L'objectif principal consistait à développer une approche combinant simulation, apprentissage automatique et optimisation afin de déterminer efficacement les paramètres de contrôle minimisant le coût total moyen à long terme du système. Cette problématique s'inscrit dans le contexte des systèmes de production modernes, où les approches traditionnelles peuvent nécessiter des efforts computationnels importants lorsque les caractéristiques du système évoluent ou lorsque plusieurs paramètres sont susceptibles de varier simultanément.

La revue de la littérature réalisée dans le premier chapitre a permis de mettre en évidence l'importance des problématiques de contrôle dans les systèmes manufacturiers et fabrication–refabrication soumise à des pannes, à des réparations aléatoires ainsi qu'à des variations de la demande et des retours. Cette analyse a également montré que, malgré l'intérêt croissant porté à l'apprentissage automatique dans le domaine de la production, son utilisation pour la détermination des paramètres de contrôle demeure encore relativement limitée. Elle a enfin permis d'identifier le rôle important que peut jouer la qualité des données d'apprentissage dans les performances des modèles développés.

Dans un premier temps, l'approche proposée a été appliquée à un système manufacturier non fiable de type M1P1. Les résultats obtenus ont permis d'évaluer différentes stratégies de construction des bases de données d'apprentissage ainsi que plusieurs modèles d'apprentissage automatique. Les analyses réalisées ont montré que la stratégie de construction de la base de données influence directement les performances prédictives des modèles développés. Les résultats ont également permis d'identifier les modèles les plus performants pour la prédiction du coût total du système et du seuil de couverture optimal. L'approche a ensuite été étendue à des environnements caractérisés par une demande variable, puis par une demande saisonnière. Les résultats obtenus ont montré que le modèle développé reproduit correctement l'influence

des principaux paramètres du système sur ses performances et ont mis en évidence l'intérêt d'une adaptation dynamique du seuil de couverture en fonction de l'évolution de la demande.

Dans un second temps, l'approche a été appliquée à un système hybride fabrication–refabrication soumis simultanément à des demandes variables, à des retours variables ainsi qu'à des pannes et réparations aléatoires. Les résultats ont montré que l'approche proposée est capable de reproduire avec précision le comportement du système et de déterminer efficacement son coût total moyen à long terme. Parmi les modèles évalués, la forêt aléatoire s'est révélée la plus performante pour la prédiction du coût total. Son intégration au sein du processus d'optimisation a permis de déterminer efficacement les paramètres de contrôle associés aux activités de fabrication et de refabrication. Les comparaisons réalisées avec les approches reposant directement sur l'optimisation par simulation ont confirmé la capacité de l'approche proposée à fournir des solutions de qualité tout en réduisant considérablement le temps nécessaire à la recherche des paramètres optimaux. Les résultats ont également montré que les gains obtenus deviennent plus importants lorsque le niveau d'incertitude du système augmente.

Les résultats obtenus permettent également de répondre aux questions de recherche formulées dans ce mémoire. Ils montrent tout d'abord qu'une approche combinant simulation, apprentissage automatique et optimisation permet de déterminer efficacement les paramètres de contrôle de systèmes de production soumis à différentes sources d'incertitude. Les analyses réalisées ont également mis en évidence l'influence de la stratégie de construction des bases de données d'apprentissage sur les performances des modèles développés. Elles montrent qu'une couverture adéquate du domaine de variation des paramètres du système constitue une condition essentielle pour garantir la qualité des prédictions et la capacité de généralisation des modèles d'apprentissage automatique. Par ailleurs, les comparaisons effectuées avec l'optimisation basée sur la simulation démontrent que l'approche proposée réduit significativement les efforts computationnels tout en maintenant une excellente qualité des solutions obtenues. Enfin, les résultats obtenus sur le système manufacturier M1P1 puis sur le système hybride fabrication–refabrication montrent que cette approche peut être appliquée

avec succès à des systèmes de production de complexité croissante, tout en conservant de bonnes performances prédictives et décisionnelles.

Dans l'ensemble, les résultats obtenus confirment le potentiel de l'apprentissage automatique comme outil d'aide à la décision pour le contrôle des systèmes de production soumis à l'incertitude. Les travaux réalisés démontrent qu'il est possible d'exploiter les données générées par simulation afin de construire des modèles prédictifs capables de reproduire efficacement le comportement du système, de réduire les efforts computationnels liés à l'optimisation et de faciliter la recherche des paramètres de contrôle optimaux. Ils mettent également en évidence que la qualité des modèles développés dépend directement de la représentativité de la base de données d'apprentissage. Les résultats obtenus soulignent ainsi l'importance de couvrir de manière adéquate le domaine de variation des paramètres du système afin de garantir la fiabilité des prédictions et la robustesse de l'approche proposée.

Plusieurs perspectives de recherche peuvent être envisagées à la suite de ce travail. L'approche proposée repose sur des bases de données générées par simulation, ce qui permet de contrôler précisément les différents scénarios étudiés. Une première perspective consisterait à intégrer des données issues de systèmes industriels réels afin d'évaluer la capacité des modèles développés à généraliser leurs prédictions dans un contexte opérationnel et à améliorer leur robustesse face aux incertitudes rencontrées en pratique. L'approche proposée pourrait également être étendue à des systèmes de production plus complexes comportant plusieurs machines et plusieurs produits. L'intégration d'autres dimensions décisionnelles, telles que les politiques de maintenance, les décisions d'approvisionnement ainsi que la prise en compte de la qualité des retours de produits, constituerait également une extension intéressante. Enfin, l'exploration d'autres techniques d'intelligence artificielle, notamment les approches d'apprentissage par renforcement, représente une voie de recherche pertinente pour le développement de mécanismes de contrôle capables de s'ajuster aux variations des conditions de fonctionnement.

LISTE DE RÉFÉRENCES BIBLIOGRAPHIQUES

- ABB. (2023). Value of reliability survey report 2023: Industry's perspective on maintenance and reliability. *ABB Motion Services*.
- Afshar-Bakeshloo, M., A. Bozorgi-Amiri, S. M. Sajadi, and F. Jolai. (2025). A Multi-objective Environmental Hedging Point Policy with Customer Satisfaction Criteria. *Journal of Cleaner Production* 179:478–494. <https://doi.org/10.1016/j.jclepro.2018.01.041>
- Akella, R., & Kumar, P. R. (1986). Optimal control of production rate in a failure-prone manufacturing system. *IEEE Transactions on Automatic Control*, 31(2), 116–126. <https://doi.org/10.1109/TAC.1986.1104206>
- Alves, J. C., & Mateus, G. R. (2022). Multi-echelon supply chains with uncertain seasonal demands and lead times using deep reinforcement learning. *arXiv*. <https://doi.org/10.48550/arXiv.2201.04651>
- Arboretti, R., Ceccato, R., Pegoraro, L., Salmaso, L., (2021). Design of Experiments and machine learning for product innovation: A systematic literature review. *Qual Reliab Eng Int* 38, 1131–1156. <https://doi.org/10.1002/qre.3025>
- Asic, I., Asic, J., Hilletoft, P., Pimenta, M. L., & Hilmola, O.-P. (2022). An evaluation of critical capabilities and improvement areas for competitive manufacturing in a developed-country environment. *Sustainability*, 14(11), 6678. <https://doi.org/10.3390/su14116678>
- Assid, M., A. Gharbi, and A. Hajji. (2019). Production Planning of an Unreliable Hybrid Manufacturing–Remanufacturing System under Uncertainties and Supply Constraints. *Computers & Industrial Engineering* 136:31–45. <https://doi.org/10.1016/j.cie.2019.06.061>
- Assid, M., Gharbi, A., & Pellerin, R. (2025). Machine learning-based dynamic production planning and control in unreliable manufacturing systems with supply disruptions. *International Journal of Production Research*. <https://doi.org/10.1080/00207543.2025.2536195>
- Behnamfar Reza, Seyed Mojtaba Sajadi, Mahshid Tootoonchy (2022). Developing environmental hedging point policy with variable demand: A machine learning approach. *Int. J. Production Economics* 254 108640. <https://doi.org/10.1016/j.ijpe.2022.108640>
- Behret, H., & Korugan, A. (2009). Performance analysis of a hybrid system under quality impact of returns. *Computers & Industrial Engineering*, 56(2), 507–520. <https://doi.org/10.1016/j.cie.2007.11.001>
- Berthaut, F., Gharbi, A., & Pellerin, R. (2009). Joint hybrid repair and remanufacturing systems and supply control. *International Journal of Production Research*, 48(14), 4101–4121. <https://doi.org/10.1080/00207540902933148>
- Bhosekar, A., & Ierapetritou, M. (2018). Advances in surrogate based modeling, feasibility analysis, and optimization: A review. *Computers & Chemical Engineering*, 108, 250–267. <https://doi.org/10.1016/j.compchemeng.2017.09.017>
- Bielecki, T., and P. R. Kumar. (1988). Optimality of Zero-Inventory Policies for Unreliable Manufacturing Systems. *Operations Research* 36 (4): 532–541. <https://doi.org/10.1287/opre.36.4.532>

- Bodendorf, F., Merkl, P., & Franke, J. (2021). Artificial neural networks for intelligent cost estimation – A contribution to strategic cost management in the manufacturing supply chain. *International Journal of Production Research*, 60(21), 6637–6658. <https://doi.org/10.1080/00207543.2021.1998697>
- Botha, A. E. J. (2017). A system dynamics simulation for strategic inventory management in the South African automotive industry.
- Çakıt, E., & M. Dağdeviren. (2023). Comparative Analysis of Machine Learning Algorithms for Predicting Standard Time in a Manufacturing Environment. *Artificial Intelligence for Engineering Design, Analysis and Manufacturing* 37:e2. <https://doi.org/10.1017/S0890060422000245>
- Chan, K. C., Rabaev, M., & Pratama, H. (2022). Generation of synthetic manufacturing datasets for machine learning using discrete-event simulation. *Production & Manufacturing Research*, 10(1), 337–353. <https://doi.org/10.1080/21693277.2022.2086642>
- Cheng, Z. (2022). Stochastic dynamic production planning in hybrid manufacturing and remanufacturing system with random usage durations. *International Journal of Production Research*, 62(7), 2331–2349. <https://doi.org/10.1080/00207543.2022.2117870>
- Corsini, R. R. (2023). Adaptive production control of two-product closed-loop supply chain dynamics under disruptions. *Journal of Industrial and Production Engineering*, 40(8), 638–660. <https://doi.org/10.1080/21681015.2023.2256962>
- De Brito, M. P., Dekker, R., & Flapper, S. D. P. (2004). Reverse logistics: A review of case studies. In A. Langevin & D. Riopel (Eds.), *Distribution logistics* (pp. 243–281). Springer. <https://doi.org/10.1007/978-3-642-17020-1>
- Dekker, R., Fleischmann, M., Inderfurth, K., & Van Wassenhove, L. N. (Eds.). (2004). Reverse logistics: Quantitative models for closed-loop supply chains. Springer. <https://doi.org/10.1007/978-3-540-24803-3>
- Dhahri, A., A. Gharbi, and M. Ouhimmou. (2022). Integrated Production-Transshipment Control Policy for a Two-Location Unreliable Manufacturing System. *International Journal of Production Economics* 247:108440. <https://doi.org/10.1016/j.ijpe.2022.108440>
- Domingos, P. (2012). A Few Useful Things to Know about Machine Learning. *Communications of the Acm* 55 (10):78–87. <https://doi.org/10.1145/2347736.2347755>
- El Filali, A., Ben Lahmer, E. H., El Filali, S., Kasbouya, M., Ajouary, M. A., & Akantous, S. (2022). Machine Learning Applications in Supply Chain Management: A Deep Learning Model Using an Optimized LSTM Network for Demand Forecasting. *Qual Reliab Eng Int* 36, 1837–1848. <https://doi.org/10.22266/ijies2022.0430.42>
- Esmacilian, B., Behdad, S., & Wang, B. (2016). The evolution and future of manufacturing: A review. *Journal of Manufacturing Systems*, 39, 79–100. <https://doi.org/10.1016/j.jmsy.2016.03.001>
- Fleischmann, M., Bloemhof-Ruwaard, J. M., Dekker, R., Van der Laan, E., Van Nunen, J. A. E. E., & Van Wassenhove, L. N. (1997). Quantitative models for reverse logistics: A review. *European Journal of Operational Research*, 103(1), 1–17. [https://doi.org/10.1016/S0377-2217\(97\)00230-0](https://doi.org/10.1016/S0377-2217(97)00230-0)

- Fontana, R., Molena, A., Pegoraro, L., & Salmaso, L. (2023). Design of experiments and machine learning with application to industrial experiments. *Statistical Papers*, 64, 1251–1274. <https://doi.org/10.1007/s00362-023-01437-w>
- Forrester, A. I. J., Sóbester, A., & Keane, A. J. (2008). Engineering Design via Surrogate Modelling: A Practical Guide. *John Wiley & Sons*. <https://doi.org/10.1002/9780470770801>
- Freiesleben, J., Keim, J., Grutsch, M., (2020). Machine learning and Design of Experiments: Alternative approaches or complementary methodologies for quality improvement? *International Journal of Intelligent Engineering and Systems*, 15(2), 464–478. <https://doi.org/10.1002/qre.2579>
- Gharbi, A., Kenné, J.-P., Kuegoua Takengny, A. L., & Assid, M. (2024). Joint emission-dependent optimal production and preventive maintenance policies of a deteriorating manufacturing system. *Sustainability*, 16(14), 6146. <https://doi.org/10.3390/su16146146>
- Gershwin, S.B. (2018). The future of manufacturing systems engineering. *Int J Prod Res* 56, 224–237. <https://doi.org/10.1080/00207543.2017.1395491>
- Govindan, K., Soleimani, H., & Kannan, D. (2015). Reverse logistics and closed-loop supply chain: A comprehensive review to explore the future. *European Journal of Operational Research*, 240(3), 603–626. <https://doi.org/10.1016/j.ejor.2014.07.012>
- Hajjej, Z., Rezg, N., & Gharbi, A. (2020). Maintenance on leasing sales strategies for manufacturing/remanufacturing system with increasing failure rate and carbon emission. *International Journal of Production Research*, 58(21), 6616–6637. <https://doi.org/10.1080/00207543.2019.1683254>
- Han, S., Ma, W., Zhao, L., Zhang, X., Lim, M. K., Yang, S., & Leung, S. C. H. (2016). A robust optimisation model for hybrid remanufacturing and manufacturing systems under uncertain return quality and market demand. *International Journal of Production Research*, 54(17), 5056–5072. <https://doi.org/10.1080/00207543.2016.1145815>
- Hu, Y., Dong, H., Liu, J., Zhuang, C., & Zhang, F. (2025). A learning-guided hybrid genetic algorithm and multi-neighborhood search for the integrated process planning and scheduling problem with reconfigurable manufacturing cells. *Robotics and Computer-Integrated Manufacturing*, 93, 102919. <https://doi.org/10.1016/j.rcim.2024.102919>
- Jin, Y. (2011). Surrogate-assisted evolutionary computation: Recent advances and future challenges. *Swarm and Evolutionary Computation*, 1(2), 61–70. <https://doi.org/10.1016/j.swevo.2011.05.001>
- Kim, Y. H., Ye, W., Kumar, R., Bail, F., Dvorak, J., Tan, Y., May, M. C., Chang, Q., Athinarayanan, R., Lanza, G., Sutherland, J. W., Li, X., & Nath, C. (2024). Unlocking the potential of remanufacturing through machine learning and data-driven models—A survey. *Algorithms*, 17(12), 562. <https://doi.org/10.3390/a17120562>
- Kimemia, J., & Gershwin, S. B. (1983). An Algorithm for the Computer Control of a Flexible Manufacturing System. *IIE Transactions*, 15(4), 353–362. <https://doi.org/10.1080/05695558308974659>
- Kosanoglu, F., Atmis, M., & Turan, H. H. (2024). A deep reinforcement learning assisted simulated annealing algorithm for a maintenance planning problem. *Annals of Operations Research*, 339, 79–110. <https://doi.org/10.1007/s10479-022-04612-8>

- Koziel, S., & Leifsson, L. (Eds.). (2013). *Surrogate-Based Modeling and Optimization: Applications in Engineering*. Springer. <https://doi.org/10.1007/978-1-4614-7551-4>
- Lolli, F., E. Balugani, A. Ishizaka, R. Gamberini, B. Rimini & A. Regattieri (2019). Machine learning for multi-criteria inventory classification applied to intermittent demand. *Production Planning & Control*, 30:1, 76-89. <https://doi.org/10.1080/09537287.2018.1525506>
- Mattsson, S.-A. (2010). Inventory control in environments with seasonal demand. *Operations Management Research*, 3(3-4), 138-145. <https://doi.org/10.1007/s12063-010-0035-1>
- Mitra, S. (2012). Inventory management in a two-echelon closed-loop supply chain with correlated demands and returns. *Computers & Industrial Engineering*, 62(4), 870-879. <https://doi.org/10.1016/j.cie.2011.12.008>
- Ndhaief, N., R. Nidhal, A. Hajji, and O. Bistorin. (2020). Environmental Issue in an Integrated Production and Maintenance Control of Unreliable Manufacturing/Remanufacturing Systems. *International Journal of Production Research* 58(14):4182-4200. <https://doi.org/10.1080/00207543.2019.1650212>
- Ouaret, S., Polotski, V., Kenné, J.-P., & Gharbi, A. (2013). Optimal production control of hybrid manufacturing/remanufacturing failure-prone systems under diffusion-type demand. *Applied Mathematics*, 4(3), 550-559. <https://doi.org/10.4236/am.2013.43079>
- Ouaret, S., Kenné, J.-P., & Gharbi, A. (2018). Production and replacement policies for a deteriorating manufacturing system under random demand and quality. *European Journal of Operational Research*, 264(2), 623-636. <https://doi.org/10.1016/j.ejor.2017.06.062>
- Ouaret, S. (2022). Production control problem with semi-Markov jump under stochastic demands and deteriorating inventories. *Applied Mathematical Modelling Volume 107*, Pages 85-102 <https://doi.org/10.1016/j.apm.2022.01.036>
- Park, J., Datta-Gupta, A., Singh, A., & Sankaran, S. (2021). Hybrid physics and data-driven modeling for unconventional field development and its application to US onshore basin. *Journal of Petroleum Science and Engineering*, 206, 109008. <https://doi.org/10.1016/j.petrol.2021.109008>
- Pasupathy, R., & Ghosh, S. (2014). Simulation optimization: A concise overview and implementation guide. *INFORMS Tutorials in Operations Research*, 2014, 122-150. <https://doi.org/10.1287/educ.2013.0118>
- Pedrozo, H. A., Zamarripa, M. A., Uribe-Rodríguez, A., Panagakos, G., Diaz, M. S., & Biegler, L. T. (2025). Surrogate model optimization: A comparison case study with pooling problems of CO₂ point sources. *Computers & Chemical Engineering*, 200, 109199. <https://doi.org/10.1016/j.compchemeng.2025.109199>
- Perkins, J. R., & Srikant, R. (2001). Optimal control of production systems with unknown demand and service time distributions.
- Polotski, V., Kenne, J.-P., & Gharbi, A. (2019). Production control of hybrid manufacturing-remanufacturing systems under demand and return variations. *International Journal of Production Research*, 57:1, 100-123. <https://doi.org/10.1080/00207543.2018.1461272>
- Polotski, V. (2022). Production policy optimization in systems with perishable products under seasonal demand. *IFAC-PapersOnLine*, 55(10), 2689-2694. <https://doi.org/10.1016/j.ifacol.2022.10.116>

- Polotski, V., Kenne, J.-P., & Gharbi, A. (2023). Estimation-based production control of manufacturing–remanufacturing systems with uncertain seasonal return and imprecise demand and inventory. *International Journal of Production Research*, 62(13), 4595–4622. <https://doi.org/10.1080/00207543.2023.2269275>
- Ponghah, P. M., Kibouka, G.-R., Kenné, J.-P., & Hof, L. A. (2022). Production, maintenance and quality inspection planning of a hybrid manufacturing/remanufacturing system under production rate-dependent deterioration. *International Journal of Advanced Manufacturing Technology*, 121, 1289–1314. <https://doi.org/10.1007/s00170-022-09078-3>
- Priore, P., B. Ponte, R. Rosillo, and D. de la Fuente. (2018). Applying Machine Learning to the Dynamic Selection of Replenishment Policies in Fast-Changing Supply Chain Environments. *International Journal of Production Research* 57(11):3663–3677. <https://doi.org/10.1080/00207543.2018.1552369>
- Rabaev, M., Pratama, H., & Chan, K. C. (2024). Leveraging synthetic data and machine learning for shared facility scheduling. *Proceedings of International Conference on Information Technology and Applications (ICITA 2023), Lecture Notes in Networks and Systems*, 839, 401–410. https://doi.org/10.1007/978-981-99-8324-7_34
- Rezg, N., S. Dellagi, and A. Chelbi. (2008). Joint Optimal Inventory Control and Preventive Maintenance Policy. *International Journal of Production Research* 46 (19): 5349–5365. <https://doi.org/10.1080/00207540802273942>
- Rivera-Castro, R., Nazarov, I., Xiang, Y., Maksimov, I., Pletnev, A., & Burnaev, E. (2019). An industry case of large-scale demand forecasting of hierarchical components. 2019 18th IEEE International Conference on Machine Learning and Applications (ICMLA), Boca Raton, FL, USA, 1723–1730. <https://doi.org/10.1109/ICMLA.2019.00029>
- Sajadi, S. M., Seyedesfahani, M. M., & Sörensen, K. (2010). Production control in a network-failure prone manufacturing system with stochastic demand using improved response surface methodology. *Proceedings of the 40th International Conference on Computers & Industrial Engineering (CIE), Awaji, Japan*, 1–6. <https://doi.org/10.1109/ICCIE.2010.5668204>
- Salviano, O., & Andres, F. (2020). Chance-constrained LQG production planning problem under partially observed forward-backward inventory systems. *IFAC-PapersOnLine*, 53(2), 10828–10835. <https://doi.org/10.1016/j.ifacol.2020.12.2869>
- Shah, P., Gosavi, A., & Nagi, R. (2008). A machine learning approach to optimise the usage of recycled material in a remanufacturing environment. *International Journal of Production Research*, 47(4), 933–955. <https://doi.org/10.1080/00207540802452157>
- Siemens AG. (2024). The true cost of downtime 2024. *Siemens Digital Industries*. https://assets.new.siemens.com/siemens/assets/api/uuid:1b43afb5-2d07-47f7-9eb7-893fe7d0bc59/TCOD-2024_original.pdf
- Souza, G. C. (2012). Closed-loop supply chains: A critical review, and future research. *Decision Sciences*, 44(1), 7–38. <https://doi.org/10.1111/j.1540-5915.2012.00394.x>
- Turki, S., Sauvey, C., & Rezg, N. (2018). Modelling and optimization of a manufacturing/remanufacturing system with storage facility under carbon cap and trade policy. *Journal of Cleaner Production*, 193, 441–458. <https://doi.org/10.1016/j.jclepro.2018.05.057>

- Wang, Y., & Gao, J. (2007). Profit models and optimisation for a multi-item-multi-echelon distribution system. *International Journal of Services Operations and Informatics*, 1(4), 380–392. <https://doi.org/10.1504/IJSOI.2006.012163>
- Wang, X., & Han, S. (2020). Optimal operation and subsidies/penalties strategies of a multi-period hybrid system with uncertain return under cap-and-trade policy. *Computers & Industrial Engineering*, 150, 106892. <https://doi.org/10.1016/j.cie.2020.106892>
- Wang, X., & Chen, Q. (2024). Stochastic optimal control for dynamic pricing and production in fashion retailing: An economic sustainability approach. *Discrete Dynamics in Nature and Society*, 2024, 4854557. <https://doi.org/10.1155/ddns/4854557>
- Xie, F., & Yu, W. (2024). Logistics cost prediction based on a random forest model. *Academic Journal of Computing & Information Science*, 7(2), 102–106. <https://doi.org/10.25236/AJCIS.2024.070215>
- Xu, Y., Conrad, F., Xing, X., Loeprecht, O., & Moeckel, M. (2024). Small dataset acquisition for machine learning analysis with possible uncertainties: Benchmarking sampling strategies for regression tasks using Auto-sklearn. *ResearchGate*. https://www.researchgate.net/publication/378259933_Small_Dataset_Acquisition_for_Machine_Learning_Analysis_with_Possible_Uncertainties_benchmarking_sampling_strategies_for_regression_tasks_using_Auto-sklearn
- Yan, H.-S., Jiang, T.-H., Meng, X.-G., & Shi, W.-W. (2017). Hedging-point control policy for a failure-prone manufacturing system. *Proceedings of the Institution of Mechanical Engineers, Part B: Journal of Engineering Manufacture*, 231(8), 1479–1487. <https://doi.org/10.1177/0954405415598941>
- Yang, X. S., Koziel, S., & Leifsson, L. (2014). Computational optimization, modelling and simulation: Past, present and future. *Procedia Computer Science*, 29, 754–758. <https://doi.org/10.1016/j.procs.2014.05.067>
- Zhong, J., Hu, X., Alghamdi, O. A., Elattar, S., & Sulaie, S. A. (2023). XGBoost with Q-learning for complex data processing in business logistics management. *Information Processing & Management*, 60(5), 103466. <https://doi.org/10.1016/j.ipm.2023.103466>