



Titre: Prédiction des retards des ordres de réapprovisionnement dans un
Title: système de production géré par DDMRP

Auteur: Karim Djedidi
Author:

Date: 2025

Type: Mémoire ou thèse / Dissertation or Thesis

Référence: Djedidi, K. (2025). Prédiction des retards des ordres de réapprovisionnement dans
Citation: un système de production géré par DDMRP [Mémoire de maîtrise, Polytechnique
Montréal]. PolyPublie. <https://publications.polymtl.ca/65779/>

 **Document en libre accès dans PolyPublie**
Open Access document in PolyPublie

URL de PolyPublie: <https://publications.polymtl.ca/65779/>
PolyPublie URL:

**Directeurs de
recherche:** Maha Ben Ali
Advisors:

Programme: Mathématiques appliquées
Program:

POLYTECHNIQUE MONTRÉAL

affiliée à l'Université de Montréal

**Prédiction des retards des ordres de réapprovisionnement dans un système de production
géré par DDMRP**

KARIM DJEDIDI

Département de mathématiques et de génie industriel

Mémoire présenté en vue de l'obtention du diplôme de *Maîtrise ès sciences appliquées*

Génie industriel

Mars 2025

POLYTECHNIQUE MONTRÉAL

affiliée à l'Université de Montréal

Ce mémoire intitulé :

Prédiction des retards des ordres de réapprovisionnement dans un système de production géré par DDMRP

présenté par **Karim DJEDIDI**

en vue de l'obtention du diplôme de *Maîtrise ès sciences appliquées*

a été dûment accepté par le jury d'examen constitué de :

Camélia DADOUCHI, présidente

Maha BEN ALI, membre et directrice de recherche

Pierre BAPTISTE, membre et codirecteur de recherche

Antoine LEGRAIN, membre

DÉDICACE

"Que cette recherche puisse, à son échelle, contribuer à enrichir les connaissances et à apporter des améliorations bénéfiques pour le progrès scientifique et technique."

REMERCIEMENTS

Ce mémoire est l'aboutissement d'un travail de deux ans et demi, marqué par des défis, des apprentissages et une profonde implication. Sa réalisation n'aurait pas été possible sans ma foi et sans le soutien inestimable de nombreuses personnes à qui j'adresse ici toute ma gratitude.

Tout d'abord, je tiens à exprimer ma reconnaissance sincère à mes directeurs prof. Maha Ben Ali et prof. Pierre Baptiste pour le temps précieux et l'énergie qu'ils ont consacrés à l'encadrement de ce projet. Leur expertise, leur patience, leurs conseils avisés et leur engagement ont été des piliers fondamentaux de cette recherche. Je leur suis également très reconnaissant pour leur soutien financier, qui a contribué de manière significative à l'aboutissement de mon travail.

Je souhaite aussi adresser mes remerciements à mon collègue au doctorat, Lucas Alves, pour son aide, sa disponibilité ainsi que ses encouragements, qui m'ont permis d'avancer dans le projet.

Un immense merci également à mes parents et mes frères, dont le soutien indéfectible, tant à distance qu'en présentiel, ainsi que leurs encouragements constants, m'ont permis d'avancer avec sérénité, même dans les moments de doute. Leur confiance et leur présence ont été une source inestimable de motivation.

Je souhaite aussi remercier ma compagne, qui a su être à mes côtés durant les périodes les plus exigeantes de ce mémoire. Son soutien inébranlable, sa patience et sa bienveillance m'ont aidé à surmonter les défis rencontrés tout au long de ce parcours.

Enfin, je tiens à remercier les membres du jury pour le temps et l'effort qu'ils consacreront à corriger ce mémoire et à me faire parvenir leurs commentaires. Je suis également reconnaissant envers l'ensemble de mes enseignants, collègues et le personnel de l'École Polytechnique, qui ont, d'une manière ou d'une autre, contribué à la réussite de cette maîtrise.

À tous, merci du fond du cœur.

RÉSUMÉ

La méthode DDMRP (Demand-Driven Material Requirements Planning) est reconnue pour sa capacité à optimiser la gestion des stocks, l'organisation de la production et la satisfaction des clients dans des conditions normales. Cependant, en période de pics de demande, il est parfois impossible d'éviter des retards de commandes. Dans ces situations, il devient crucial de fournir aux clients une estimation fiable des retards des ordres de réapprovisionnement pour maintenir leur satisfaction et éviter des pertes de ventes.

Cette étude propose une solution d'apprentissage automatique permettant de prédire ces délais dans une ligne de production gérée par DDMRP. L'objectif est d'identifier les informations essentielles pour obtenir des prévisions précises. Pour ce faire, une simulation a été utilisée pour générer les données d'entraînement et de test nécessaires aux modèles d'apprentissage automatique, en particulier pour des scénarios de forte demande.

Les résultats montrent que ces modèles, en particulier XGBoost, sont très performants pour estimer les retards des ordres de réapprovisionnement. Une autre découverte importante de cette étude est que les informations liées à l'état du système, telles que le travail en cours dans toute l'usine et la quantité de produit en commande sur les machines, ont un impact plus significatif sur la précision des prédictions que les caractéristiques directement liées aux commandes clients.

ABSTRACT

The DDMRP (Demand-Driven Material Requirements Planning) method is recognised for its ability to optimise stock management, production organisation and customer satisfaction under normal conditions. However, during periods of peak demand, it is sometimes impossible to avoid customer order delays. In these situations, it becomes crucial to provide customers with a reliable estimate of backorder times to maintain their satisfaction and avoid lost sales.

This study proposes a machine learning solution for predicting backorder times in a DDMRP production line. The aim is to identify the essential information needed to obtain accurate predictions. To do this, a simulation was used to create the training and test data required for the machine learning models, particularly for high-demand scenarios.

The results show that these models, in particular XGBoost, perform very well in predicting backorder time. Another important finding of this study is that information related to the state of the system, such as the work in progress throughout the factory and the quantity of product on order on the machines, has a more significant impact on the accuracy of predictions than features directly related to customer orders.

TABLE DES MATIÈRES

DÉDICACE	III
REMERCIEMENTS	IV
RÉSUMÉ	V
ABSTRACT	VI
TABLE DES MATIÈRES	VII
LISTE DES TABLEAUX	X
LISTE DES FIGURES	XI
LISTE DES SIGLES ET ABRÉVIATIONS	XII
LISTE DES ANNEXES	XIII
CHAPITRE 1 INTRODUCTION.....	1
1.1 Mise en contexte et problématique.....	1
1.2 Objectifs.....	2
1.3 Structure du mémoire	3
CHAPITRE 2 REVUE DE LITTÉRATURE.....	4
2.1 Introduction.....	4
2.2 La méthode DDMRP et son fonctionnement.....	4
2.2.1 Présentation générale.....	4
2.2.2. Fonctionnement.....	5
2.2.3. DDMRP et les demandes irrégulières	8
2.3 Apprentissage automatique dans la gestion de la chaîne d'approvisionnement.....	10
2.4 Apprentissage automatique pour la prédiction des retards dans les systèmes manufacturiers	11
2.5 Gap de la littérature	12

CHAPITRE 3	APPROCHE MÉTHODOLOGIQUE	14
3.1	Revue de la littérature.....	14
3.2	Modélisation du système de simulation et des expériences.....	15
3.2.1.	Reproduction d'une chaîne de production gérée en DDMRP	15
3.2.2.	Test du modèle avec différents scénarios	17
3.2.3.	Choix du cas d'étude	18
3.3	Génération de données d'entraînement et de test.....	18
3.4	Procédure d'apprentissage	19
3.5	Évaluation des performances et de l'importance des variables	21
3.6	Conclusion	21
CHAPITRE 4	ARTICLE 1 : BACKORDER TIME PREDICTION IN A DDMRP MANAGED PRODUCTION SYSTEM	23
4.1	Introduction.....	25
4.2	Related Literature.....	26
4.2.1	DDMRP Concepts.....	26
4.2.2	DDMRP and Irregular Demand	28
4.2.3	Backorder Prediction.....	29
4.2.4	Manufacturing Delay Prediction using Machine Learning	30
4.2.5	Paper contribution	31
4.3	Methodology	32
4.3.1	Generating knowledge using simulation	33
4.3.2	Learning Process	37
4.3.3	Prediction Accuracy Evaluation	40
4.3.4	Feature Importance and Feature Selection	41
4.4	Results analysis	41

4.4.1 Analysis of the data generated by the simulation	42
4.4.2 Comparison of the predictive performance of the different models	44
4.4.3 Residual analysis.....	46
4.4.4 Feature Importance	47
4.5 Discussion.....	48
4.6 Conclusion	49
CHAPITRE 5 DISCUSSION GÉNÉRALE.....	51
5.1 Principales réalisations	51
5.2 Implications managériales	53
5.2.2. Amélioration de la satisfaction des clients	53
5.2.3. Réduction des coûts opérationnels	53
5.3 Contributions du projet.....	53
CHAPITRE 6 CONCLUSION.....	55
6.1 Synthèse des travaux	55
6.2 Limitations de la solution proposée.....	55
6.3 Améliorations futures	56
RÉFÉRENCES.....	57
ANNEXES	60

LISTE DES TABLEAUX

Tableau 1.1 L'utilisation des méthodes d'aide à la décision avec de l'apprentissage automatique.	9
Tableau 1.2 Niveaux de LT en fonction du taux de chargement.....	14
Table 4.1: Examples of papers using ML to predict delays in manufacturing systems	30
Table 4.2: Average Daily Usage (units)	35
Table 4.3: Processing times (seconds) of Lucas. et al. (2024).....	35
Table 4.4: Lead time levels according to the loading rate [22].....	36
Table 4.5: Input Features Description	37
Table 4.6: Hyperparameter configurations explored for each model.....	39
Table 4.7: Feature selection between Case 1 and Case 2	44
Table 4.8: Predictive performance of the different models	44
Table 4.9: Performance improvement of the best models compared to the average-based approach	45

LISTE DES FIGURES

Figure 2.1 : Les 3 étapes et les 5 composantes de la mise en œuvre du DDMRP [6]	5
Figure 2.2 : Dimensionnement des zones d'un stock tampon de stock DDMRP [4]	7
Figure 3.1 : Méthodologie générale	14
Figure 3.2 : Schéma explicatif du fonctionnement de DDMRP sous SIMIO.....	15
Figure 3.3 : Diagramme en boîte du pourcentage de commandes à temps par scénario	18
Figure 3.4 : Exemple d'extraction de données sur SIMIO	19
Figure 4.1: Buffer zones [8].....	27
Figure 4.2: General methodology.....	33
Figure 4.3: The simulation model	34
Figure 4.4: 5-Fold Cross-Validation Process [30]	40
Figure 4.5: Distribution of the backorder time generated by simulation.....	42
Figure 4.6: Correlation matrix	43
Figure 4.7: Residual distribution.....	46
Figure 4.8: Feature importance	48

LISTE DES SIGLES ET ABRÉVIATIONS

ADU	Average Daily Usage
ANN	Artificial Neural Network
CMJ	Consommation Moyenne par Jour
DDMRP	Demand Driven Material Requirements Planning
DLT	Decoupled Lead Time
DT	Decision Tree
EFN	Équation de Flux Net
FD	Facteur de Délai
FV	Facteur de Variabilité
LTF	Lead Time Factor
MAE	Mean Absolute Error
ML	Machine Learning
MOQ	Minimum Order Quantity
NFP	Net Flow Position
OSH	Order Spike Horizon
OST	Order Spike Threshold
RL	Reinforcement Learning
RMSE	Root Mean Square Error
RT	Random Tree
SHAP	SHapley Additive exPlanations
SVM	Support Vector Machine
TOG	Top of Green
VF	Variability Factor
WIP	Work In Progress

LISTE DES ANNEXES

Annexe A Performance des modèles d'apprentissage pour les cas 1 et cas 2 sur les données d'entraînement et de test.....	59
---	----

CHAPITRE 1

INTRODUCTION

1.1 Mise en contexte et problématique

Dans un environnement économique marqué par une concurrence accrue et une instabilité croissante, les entreprises doivent s'adapter à des attentes clients de plus en plus exigeantes, notamment en matière de réactivité et de respect des délais de livraison. Si la qualité des produits reste essentielle, la capacité à livrer les commandes à temps est devenue un facteur clé pour garantir la satisfaction des clients et maintenir leur fidélité. Pour répondre à ces exigences, des méthodologies modernes telles que le Demand-Driven Material Requirements Planning (DDMRP) se sont imposées comme des outils puissants. En combinant les stratégies "push" et "pull", le DDMRP offre une meilleure gestion des flux et une agilité accrue face aux fluctuations de la demande [1].

Cependant, dans les situations où la demande excède durablement la capacité opérationnelle, le système DDMRP atteint ses limites. Il est important de distinguer ici deux types de pics : les pics de commande, qui sont ponctuels et imprévisibles, et les pics de demande, qui désignent une hausse soutenue et relativement prévisible de la demande sur le moyen ou long terme. Ce mémoire se concentre exclusivement sur les pics de demande prolongés, qui exercent une pression continue sur le système et peuvent générer des goulots d'étranglement, des retards dans le traitement des ordres internes, ainsi qu'une accumulation de commandes en attente.

Ces perturbations internes menacent directement la ponctualité des livraisons et la satisfaction client. Pour les anticiper, il devient crucial de pouvoir prédire les retards des ordres de réapprovisionnement. Dans un système DDMRP, les demandes des clients sont généralement satisfaites à partir des stocks tampons. Toutefois, si les ordres de réapprovisionnement des stocks tampons ne peuvent être exécutés à temps en raison de longues files d'attente de production ou de contraintes de capacité, les niveaux des stocks tampons peuvent devenir insuffisants, ce qui risque d'empêcher de satisfaire la demande des clients.

Dans ce projet, nous définissons le retard d'un ordre de réapprovisionnement dans un système DDMRP comme « le temps écoulé entre la date d'échéance d'un ordre de réapprovisionnement des stocks tampons et la réception de la quantité totale requise ». L'objectif de ce projet est donc de

prédire le temps d'attente associé à ces retards des de réapprovisionnement, afin de détecter les situations critiques en amont et d'améliorer la visibilité sur les délais internes.

Les jumeaux numériques, bien qu'ils ne soient pas directement utilisés dans ce projet, représentent une solution avancée largement évoquée dans la littérature pour modéliser les systèmes complexes. Ces répliques virtuelles permettent d'analyser en temps réel les performances des systèmes, de prévoir les retards et d'identifier les inefficacités dans la chaîne de production. Toutefois, leur mise en œuvre pose plusieurs défis majeurs, notamment la complexité d'intégrer des données en temps réel, la gestion de volumes d'information importants, l'interopérabilité entre systèmes, et les coûts élevés liés à leur développement et leur maintenance [2]. Ces inconvénients limitent leur adoption dans certaines entreprises, particulièrement lorsque des solutions plus simples et ciblées, comme la simulation traditionnelle, peuvent suffire pour répondre aux besoins immédiats.

Ce projet a pour but de développer une approche permettant à un décideur d'estimer les retards des ordres de réapprovisionnement dans un système DDMRP, en s'appuyant sur un ensemble limité d'informations sur l'état du système, sans recourir à un jumeau numérique. Le projet adresse les problématiques suivantes :

- Comment prévoir les retards de réapprovisionnement d'un système DDMRP qui fait face à une période de pics de demande ?
- Quelles variables clés doivent être capturées afin de pouvoir prédire les retards de réapprovisionnement avec un niveau de précision acceptable ?

1.2 Objectifs

L'objectif principal du projet est de développer une approche d'apprentissage pour prédire les retards des ordres de réapprovisionnement dans une chaîne de production gérée en DDMRP. Ceci permettrait de fournir des prédictions fiables pour anticiper les retards et communiquer les délais réalistes aux clients. Afin d'atteindre cet objectif général, ce mémoire se fixe les objectifs spécifiques suivants :

1. Générer des données en relation avec le comportement d'un système de simulation d'une chaîne DDMRP faisant face à une demande élevée.
2. Identifier les variables pertinentes pour la prédiction des retards des ordres de réapprovisionnement.

3. Identifier une (des) méthodes permettant de réaliser une précision de prédiction acceptable.

1.3 Structure du mémoire

Ce mémoire est structuré en six chapitres. Le premier chapitre introduit le contexte du projet, expose la problématique et définit les objectifs poursuivis. Le deuxième chapitre propose une revue de littérature détaillée présentant la méthode DDMRP, son fonctionnement, ainsi que l'application de l'apprentissage automatique dans la gestion de la chaîne d'approvisionnement et la prédiction des retards. Le troisième chapitre décrit l'approche méthodologique adoptée pour mener à bien ce projet. Le quatrième chapitre est consacré à la présentation du modèle testé, en détaillant les différentes étapes qui ont permis de prédire les retards des ordres de réapprovisionnement. Enfin, les cinquième et sixième chapitre traitent respectivement de la discussion générale des résultats obtenus et de la conclusion, avec des perspectives pour de futurs travaux.

CHAPITRE 2

REVUE DE LITTÉRATURE

2.1 Introduction

Ce chapitre explore un ensemble de thématiques issues de la littérature, essentielles pour aborder la problématique de la prédiction des retards des ordres de réapprovisionnement. Tout d'abord, la méthode DDMRP est présentée en détail pour permettre une compréhension approfondie de ses concepts fondamentaux et de son fonctionnement, ainsi que pour préparer le lecteur à appréhender les dynamiques liées aux pics de demande. Ensuite, ce chapitre met en lumière les différentes applications de l'apprentissage automatique dans la prise de décision, avec un focus particulier sur son utilisation pour la prédiction des retards dans les systèmes manufacturiers. Ces analyses offrent un cadre conceptuel clair et permettent d'établir des bases solides pour comprendre les approches méthodologiques adoptées dans ce projet.

2.2 La méthode DDMRP et son fonctionnement

2.2.1 Présentation générale

De prime abord, la méthode DDMRP a été créée au début du 21^{ème} siècle dans la troisième version du livre Orlicky's [3]. Cette méthode est appelée hybride parce qu'elle combine deux approches la première en flux poussé et la seconde en flux tiré. Elle fusionne Materials Requirements Planning (MRP) qui représente la méthode de flux poussé. Cette méthode est basée sur des prévisions de vente pour définir à l'avance à quel moment, combien de produit fini et de composant à fabriquer ainsi que la matière première à acheter [4]. Cette Méthode facilite la planification et la synchronisation depuis l'arrivée de l'informatique et des progiciels de gestion intégrés. Cependant, cette dernière n'est pas toujours fiable puisqu'elle se repose sur des prévisions. De ce fait, il existe de fortes possibilités d'avoir un surstock ou de produire moins. De plus, la synchronisation rend les composants de la nomenclature dépendants ce qui aboutit à un approvisionnement en avance [3]. Le terme Demand Driven dans le DDMRP désigne le flux tiré où chaque nouvelle demande déclenche une actualisation des données pour ajuster les réapprovisionnements en fonction des besoins réels. Contrairement au flux poussé, cette méthode permet de réduire les stocks et répondre exactement à la demande. Dessevre [4] explique le principe de cette combinaison : Dans la nomenclature, il sera à positionner des points de découplage ou des stocks tampons qui sont gérés

en flux tiré dans le but d'éliminer les fluctuations dans le système. Les éléments autres que les points de découplage sont gérés en flux poussé. La méthode DDMRP se repose sur une stratégie qui minimise les délais en harmonisant les actions avec les besoins du marché. Cela nécessite une planification méticuleuse et une synchronisation entre la planification et l'exécution en fonction de la consommation des matériaux. En valorisant la réactivité face à la demande plutôt que le stockage excessif, le DDMRP offre aux entreprises une meilleure capacité d'adaptation aux fluctuations du marché [5]. L'implémentation de la méthode DDMRP est principalement composée de cinq étapes majeures : Les trois premières phases représentent la modélisation de l'environnement, la quatrième et la cinquième phase établie les éléments opérationnels du système DDMRP, notamment la planification et la mise en œuvre comme présentés dans la Figure 2.1.

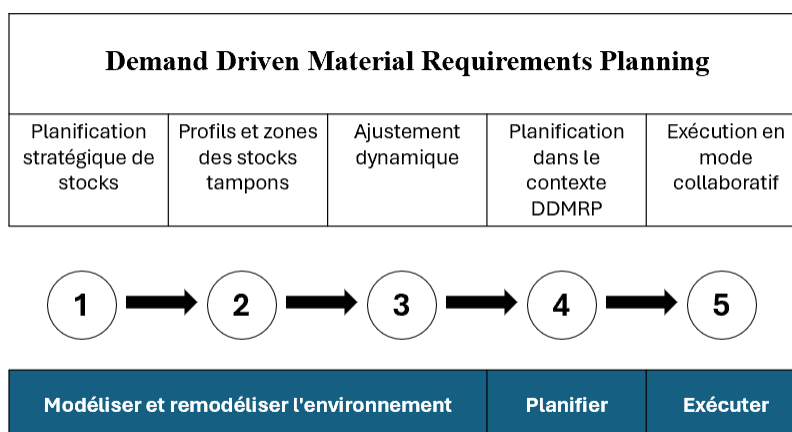


Figure 2.1 : Les 3 étapes et les 5 composantes de la mise en œuvre du DDMRP [6]

2.2.2. Fonctionnement

- **Planification stratégique des stocks**

Le premier élément est le positionnement stratégique. L'idée derrière DDMRP est de mettre en place des stocks tampons. Avec la méthode traditionnelle, l'accent était mis sur la quantité de stocks à maintenir contrairement à cette méthode qui cherche à déterminer le positionnement optimal des stocks. Ce changement est crucial pour protéger la chaîne d'approvisionnement contre les fluctuations de la demande des clients et la variabilité de l'offre. En outre, la détention de stocks de matières premières et d'articles intermédiaires peut faciliter la réduction des délais cumulés et améliorer la stabilité globale. Ce choix est stratégique puisqu'il détermine le plus long délai pour reconstituer chaque stock d'un élément de la nomenclature [5].

- **Profils de stocks tampons et zones des stocks tampons**

Le deuxième élément de la modélisation vise à déterminer les profils de stocks tampons et les zones des stocks tampons. Les zones tampons sont calculées pour les articles fabriqués, achetés et distribués. Trois zones tampons sont à déterminer : verte, jaune et rouge. Le vert signifie qu'aucune action n'est requise, le jaune indique la zone de réapprovisionnement ou de reconstruction, et le rouge signifie qu'une attention particulière est nécessaire.

Pour ce faire, il est nécessaire de prendre en compte des facteurs tels que [4]:

- La Consommation Moyenne Journalière (CMJ), déterminé à partir des ventes antérieures ou/et des prévisions.
- Le Facteur de Variabilité (FV) est un paramètre intrinsèque directement lié à la variabilité de la demande et des performances des fournisseurs. Il est utilisé pour ajuster la taille du stock de sécurité dans les stocks tampons. Ce facteur peut varier de 0 % à 100 %, en fonction du niveau de variabilité observé.
- Le Facteur de Délai (FD) est un paramètre clé de la méthode DDMRP, utilisé pour déterminer la taille minimale des lots et le nombre d'ordres de réapprovisionnement en cours. Les auteurs recommandent de catégoriser les stocks tampons selon les délais de réapprovisionnement (DLT) et de choisir un FD entre 20 % et 100 %. La règle à suivre est la suivante : plus le DLT est long, plus le FD doit être faible, favorisant ainsi des lots plus petits pour les produits à délais importants. Il convient de souligner que le facteur de délai est utilisé pour dimensionner à la fois la zone verte et la zone rouge. Cependant, sa valeur peut varier légèrement (tout en restant proche, selon les auteurs de la méthode DDMRP) entre les deux zones. Pour cette raison, il est représenté par FD1 et FD2 dans la Figure 2.2.
- Le Decoupled Lead Time (DLT) : C'est le plus long délai pour reconstituer chaque stock d'un élément de la nomenclature.

Une fois les facteurs sont déterminés, la représentation des zones tampons est comme suit :




Figure 2.2 : Dimensionnement des zones d'un stock tampon de stock DDMRP [4]

EFN représente l'équation de flux net qui sera expliquée en plus de détails dans une section ultérieure.

- **Ajustement dynamique**

Le troisième élément de la phase de modélisation de l'environnement est l'ajustement dynamique. Le DDMRP intègre les ajustements recalculés, planifiés et manuels dans son modèle, lesquels sont déclenchés par des événements externes ou des modifications des unités d'analyse des besoins CMJs.

- **La planification dans le contexte du DDMRP**

Le quatrième élément est la planification dans le contexte du DDMRP. Cette étape introduit l'Équation du Flux Net (EFN) qui constitue un mécanisme essentiel dans la priorisation et la synchronisation des actions à entreprendre. Il opère en déclenchant le réapprovisionnement lorsque nécessaire. Le concept de découplage intervient pour limiter l'explosion des nomenclatures en maintenant un stock tampon. Ainsi, la génération d'un réapprovisionnement pour un article stratégique, doté d'un tel stock tampon, est initiée uniquement lorsque le calcul du Stock Disponible Net identifie un besoin à combler. Cette approche permet d'optimiser la gestion des stocks en concentrant les efforts sur les articles essentiels et en évitant les excès inutiles.

L'Équation de Flux Net est la suivante :

$$\text{Stock Disponible Net} = \text{Stock physique} + \text{En - cours} - \text{Demande Qualifié} \quad (2.1)$$

Pour calculer la demande qualifiée, il est nécessaire de définir les paramètres OST (*Order Spike Threshold*) et OSH (*Order Spike Horizon*), définis respectivement comme la quantité minimale de demande cumulée considérée comme un pic de commande, et l'horizon temporel sur lequel cette demande est évaluée [6].

Pour un stock tampon donné, un ordre de réapprovisionnement est lancé lorsque l'EFN passe en dessous du sommet du jaune afin d'attendre le sommet du vert. En outre, une priorité de commande est requise et calculée à partir du rapport entre la position du stock et le seuil de réapprovisionnement du haut du jaune. Plus ce rapport est élevé, plus la priorité de commande est faible [7].

- **L'exécution en mode collaboratif**

Le cinquième et le dernier élément est l'exécution en mode collaboratif. Le DDMRP intègre un système d'alerte avancé qui résout le problème de la priorisation par date d'échéance traditionnelle du MRP en émettant des alertes basées sur les niveaux des tampons, tout en tenant compte des dates d'échéance comme une source supplémentaire d'information. Les alertes sont déclenchées en fonction de l'état des tampons de chaque pièce concernée. Une collaboration efficace est essentielle pour établir des règles de décision claires basées sur ces niveaux de tampons.

2.2.3. DDMRP et les demandes irrégulières

La littérature sur le DDMRP se réfère à la demande irrégulière principalement comme des pics de commande, qui sont des augmentations soudaines et à court terme de la demande causées par des commandes de clients inattendues. Ptak and Smith [6] définissent les pics de commandes comme « des commandes quotidiennes futures qui génèrent une poussée écrasante, compromettant potentiellement l'intégrité du tampon si elle n'est pas prise en compte ». Ils suggèrent que seuls les pics de commandes qualifiés soient pris en compte dans le calcul de l'EFN, où un pic de commandes qualifié est défini comme une quantité qualifiée de demande quotidienne cumulée connue dans une fenêtre temporelle qualifiée qui menace l'intégrité du tampon. Cela nécessite la définition de deux paramètres : le seuil de pic d'ordres (OST) et l'horizon de pic d'ordres (OSH).

Peu d'études ont abordé la gestion des pics de commande, offrant des approches distinctes pour optimiser les systèmes DDMRP. Damand, et al. [8] proposent un cadre de simulation et

d'optimisation pour définir des paramètres statiques tels que l'OST et l'OSH. En traitant ces paramètres dans le cadre d'un modèle d'optimisation multi-objectifs, l'étude propose d'équilibrer les niveaux de stocks disponibles avec les taux de livraison à temps. Le modèle suppose que la demande est connue à l'avance, ce qui limite son adaptabilité dans des environnements très dynamiques, où la demande peut fluctuer de manière imprévisible. Pour surmonter cette limitation, Duhem et al. (2023) présentent une approche dynamique qui utilise l'apprentissage par renforcement (RL) pour ajuster l'OST et l'OSH.

Les auteurs utilisent un réseau Q duel ramifié pour ajuster dynamiquement ces paramètres en fonction des fluctuations en temps réel. L'apprentissage continu permet au système de gérer les pics de commandes fréquents et imprévisibles avec une plus grande précision. Contrairement à l'approche de Damand, et al. [8], celle de Duhem et al. (2023) se caractérise par sa capacité à s'adapter à l'évolution des conditions au fur et à mesure que le système fonctionne. L'agent RL a démontré une performance supérieure dans la gestion des charges de travail élevées et des pics fréquents, permettant de réduire les niveaux de stock tout en maintenant la satisfaction du client.

Considérant un système DDMRP réel, Dessevre and Benali [1] utilisent la simulation pour comparer la performance de différentes approches de gestion de la capacité face à une demande irrégulière. L'étude montre qu'une approche dynamique qui anticipe la charge de travail surpasse deux approches de la littérature en maximisant l'utilisation des ressources tout en maintenant un niveau de service client élevé. Cependant, le module d'anticipation de la charge de travail proposé dans cette étude est spécifique à l'étude de cas et ne peut pas être généralisé à d'autres cas.

Duhem et al. (2023) et Damand et al. (2023) considèrent la demande avec des pics de commande qui sont différents des pics de demande étudiés dans ce document. Par « pics de demande » dans ce projet, nous entendons les augmentations prévisibles et à long terme de la demande qui suivent des schémas prévisibles, tels que les fluctuations saisonnières ou les tendances du marché. Alors que les pics de demande posent des problèmes liés à la planification à long terme, à l'allocation des capacités et à l'optimisation des stocks sur de longues périodes, les pics de demande sont imprévisibles et nécessitent des ajustements immédiats pour maintenir la stabilité du système. La littérature spécialisée propose peu de recherches sur l'impact des pics de demande prolongés sur l'efficacité de la production et la gestion des stocks dans un système DDMRP. De plus, il n'existe pas d'outil permettant aux entreprises d'anticiper les retards afin de réduire les interventions

réactives comme les commandes urgentes ou les ajustements de priorité. Dans cette étude, les pics de demande ne sont pas considérés comme entièrement prévisibles. Ils sont modélisés comme des hausses importantes et durables de la charge mais avec des effets clairs sur la performance du système. L'objectif n'est donc pas de prévoir quand la demande va augmenter, mais de prédire les retards qui apparaissent lorsque le système est déjà en surcharge.

2.3 Apprentissage automatique dans la gestion de la chaîne d'approvisionnement

Une revue de littérature approfondie a permis d'identifier des références clés explorant l'utilisation de l'apprentissage automatique en combinaison avec des méthodes de prise de décision dans le domaine de la chaîne d'approvisionnement. Ces travaux mettent en évidence comment des approches hybrides, intégrant des techniques d'optimisation, des systèmes multi-agents, et des simulations, peuvent contribuer à modéliser efficacement les systèmes de production, générer des informations exploitables, et sélectionner des données pertinentes pour l'apprentissage automatique. Par la suite, ces modèles d'apprentissage permettent de résoudre des problématiques spécifiques liées à la gestion des chaînes de production, telles que l'optimisation des ressources, la prédiction des événements ou la formulation de solutions stratégiques. Le Tableau 1.1 résume les contributions des différents articles identifiés, en mettant en avant les méthodes d'apprentissage automatique et de prise de décision employées, ainsi que leurs objectifs respectifs.

Tableau 2.1 : L'utilisation des méthodes d'aide à la décision avec de l'apprentissage automatique

Références	Apprentissage automatique		Aide à la décision	
	Méthode	Objectif	Méthode	Objectif
López-Ortega, et al. [9]	Apprentissage supervisé	Déterminer la machine appropriée pour fabriquer le produit	Systèmes multi-agents	Modéliser la planification de la production
Wang and Usher [10]	Apprentissage par renforcement	Permettre à un agent d'accroître son intelligence en temps réel	Systèmes multi-agents	Faciliter la négociation entre agents pour la production
Han and Zhang [11]	Réseau de neurones à propagation arrière	Réaliser une analyse des risques et formuler des recommandations	Optimisation	Améliorer l'efficacité opérationnelle

Abbasi, et al. [12]	Apprentissage par classification et par régression	Reproduire les solutions optimales d'un solveur complexe	Optimisation stochastique	Pour entraîner un modèle d'apprentissage automatique
Priore, et al. [13]	Apprentissage inductif	Déterminer la règle optimale de réapprovisionnement	Simulation	Générer les exemples d'entraînement et de test
Ren, et al. [14]	Apprentissage par renforcement	Optimiser simultanément la longueur de l'itinéraire et l'heure d'arrivée du véhicule	Simulation par multi-agents	Sélectionner le nombre optimal de véhicules
Kumar and Sharma [15]	Apprentissage supervisé	Prédire les risques et événements dans la chaîne d'approvisionnement	Modèle SCOR	Identifier les facteurs et causes des risques

2.4 Apprentissage automatique pour la prédiction des retards dans les systèmes manufacturiers

De nombreux travaux scientifiques ont exploré l'utilisation des méthodes d'apprentissage automatique pour prédire les retards dans divers systèmes de production, soulignant l'importance des caractéristiques liées aux commandes et à la production. Les caractéristiques liées aux commandes, telles que la taille des commandes, les délais de livraison et la disponibilité des composants, offrent des informations sur la demande et les spécificités des ordres. En parallèle, les caractéristiques liées à la production, notamment l'utilisation des machines, les encours de production (WIP), la longueur des files d'attente et les goulets d'étranglement, permettent de mieux comprendre l'état et les contraintes du système manufacturier. Alenezi, et al. [16] et Schneckenreither, et al. [17] se sont penchés sur la prédiction des temps de flux dans des systèmes Make-to-Order, en comparant des modèles traditionnels à des techniques avancées telles que la machine à vecteurs de support (SVM) et les réseaux neuronaux pour améliorer la précision des dates d'échéance. Burggräf, et al. [18] ont abordé les retards causés par l'indisponibilité de composants dans des systèmes Engineer-to-Order, en s'appuyant sur des algorithmes comme les forêts aléatoires et les arbres de décision pour réduire les perturbations. Dans la production par petits lots, Rokoss, et al. [19] ont utilisé le gradient boosting et les machines à vecteurs de support

(SVM) pour prédire les temps de livraison dès les premières étapes, permettant des ajustements en temps réel dans la planification. De plus, Yang, et al. [20] ont appliqué l'algorithme Orthogonal Kernel Least Squares dans des ateliers dynamiques pour affiner l'attribution des dates de livraison. Ces études démontrent la polyvalence et l'efficacité de l'apprentissage automatique dans la résolution des défis liés aux retards en production, en combinant des données spécifiques aux commandes et aux systèmes de production pour optimiser les flux et améliorer les performances globales. Bien que la littérature actuelle traite du DDMRP et des défis associés aux pics de demande, comme discuté précédemment dans la section 2.2.3, elle ne propose pas de solutions pour la prédiction des retards des ordres de réapprovisionnement dans les systèmes gérés par DDMRP. Les travaux recensés dans la littérature traitent principalement de la prédiction des retards dans des environnements de production de type Make-to-Order (MTO), Engineer-to-Order (ETO) ou Make-to-Stock (MTS). Ces systèmes se distinguent du DDMRP par leur logique de gestion des flux et de planification. À ce jour, la littérature ne propose pas de méthode spécifique pour prédire les retards des ordres de réapprovisionnement générés par DDMRP, ce qui constitue une véritable opportunité de recherche. En effet, la prédiction des retards dans un tel contexte est essentielle pour répondre aux attentes des clients et éviter les perturbations opérationnelles. Ce projet vise à combiner la simulation et l'apprentissage automatique pour répondre à cette problématique. La simulation permettra de modéliser les comportements du système sous des scénarios de forte demande prolongée, dans lesquels la charge dépasse durablement la capacité nominale. Ce type de scénario ne repose pas sur une demande strictement prévisible ou cyclique, mais représente plutôt une situation de stress opérationnel réaliste observée dans certaines industries. L'apprentissage automatique sera utilisé pour prédire les retards des ordres de réapprovisionnement lorsque le système est saturé. Ces prédictions visent à être communiquées aux clients ou aux gestionnaires afin de prévenir l'insatisfaction liée aux délais, tout en maximisant la performance et la stabilité du système. Ces prédictions pourront être communiquées aux clients pour prévenir leur insatisfaction, tout en maximisant les performances et les revenus du système. En comblant ce vide dans la littérature, cette approche contribuera à enrichir les connaissances sur les systèmes DDMRP et à fournir des solutions concrètes pour améliorer leur gestion en période de forte demande.

2.5 Gap de la littérature

La littérature actuelle met en évidence l'utilisation de l'apprentissage automatique pour prédire les retards dans divers systèmes manufacturiers. Cependant, elle reste largement axée sur des

environnements traditionnels tels que les systèmes Make-to-Order ou Engineer-to-Order, et très peu d'études se concentrent sur les chaînes de production gérées par le DDMRP. Bien que le DDMRP soit reconnu pour son efficacité à gérer les stocks et à répondre aux fluctuations de la demande, peu de recherches ont exploré les cas où une forte demande prolongée engendre des retards des ordres de réapprovisionnement internes. Contrairement aux approches statistiques comme ARIMA, qui sont conçues pour modéliser des séries temporelles univariées et prédire l'évolution de la demande dans le temps [21], cette étude se concentre sur la prédiction des retards à partir de l'état global du système au moment où un ordre est en souffrance. Dans ce contexte, les retards dépendent de multiples variables simultanées (files, quantités en attente, commandes en cours, etc.), avec des relations souvent non linéaires. Cela rend les modèles d'apprentissage automatique plus appropriés que les approches statistiques classiques. Cette lacune représente un domaine de recherche encore sous-exploité. Dans ce projet, une attention particulière est portée à la sélection des variables pertinentes pour l'apprentissage automatique, essentielle pour obtenir des prédictions fiables. La pertinence des variables, qu'elles soient liées aux commandes clients ou à la production, est déterminée par une analyse approfondie et l'évaluation des performances des modèles d'apprentissage automatique. La résolution du problème repose sur une approche itérative, où les résultats de chaque itération permettent d'ajuster les modèles, d'affiner les données utilisées et de mieux comprendre les facteurs influençant les retards. Cette démarche assure une amélioration progressive de la précision des prédictions, tout en renforçant la capacité des systèmes DDMRP à anticiper les retards dans des conditions de forte demande. Ce projet vise ainsi à combler ce vide dans la littérature en proposant une solution innovante qui combine simulation et apprentissage automatique pour fournir des outils d'aide à la décision dans les systèmes gérés par DDMRP.

CHAPITRE 3

APPROCHE MÉTHODOLOGIQUE

La méthodologie générale, présentée dans la Figure 3.1, est divisée en cinq étapes principales. Chaque étape contribue à l'étape suivante et, en fin de compte, à l'objectif du projet présenté dans le premier chapitre.

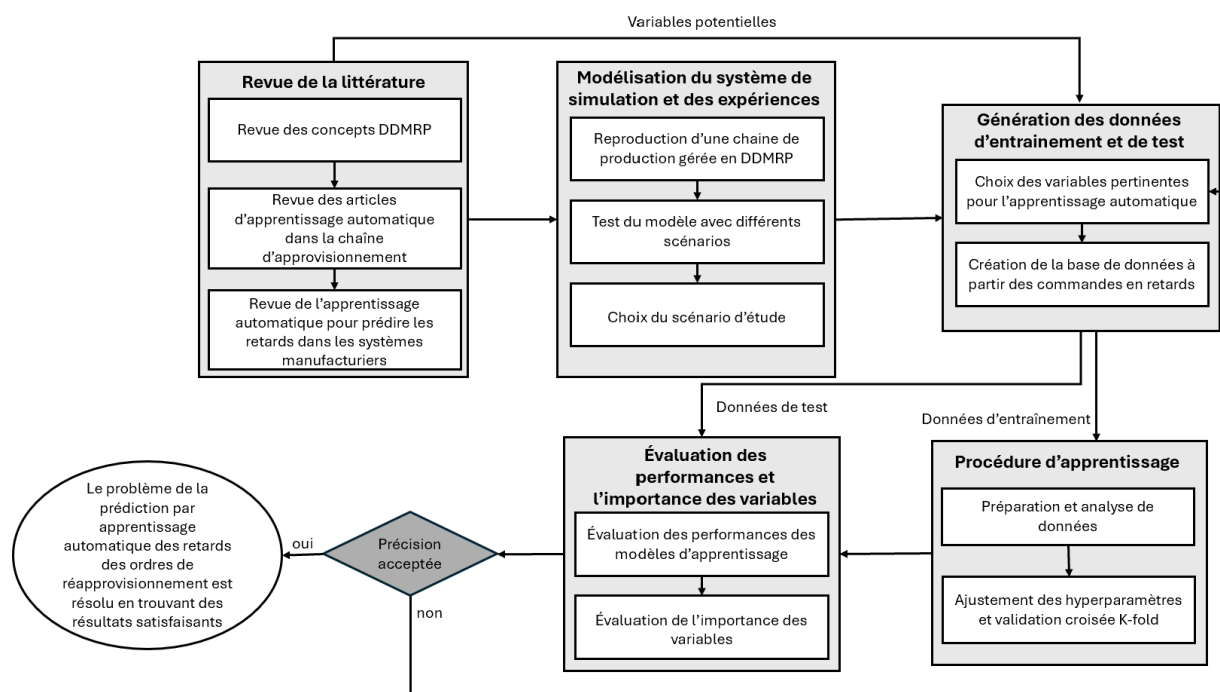


Figure 3.1 : Méthodologie générale

3.1 Revue de la littérature

Pour appréhender l'approche adoptée dans ce projet visant à prédire les retards des ordres de réapprovisionnement dans un contexte de DDMRP, cette revue de littérature s'est articulée autour de plusieurs étapes. Dans un premier temps, les concepts fondamentaux de la méthode DDMRP ont été étudiés afin de comprendre ses principes clés, son fonctionnement, ainsi que la manière dont cette approche traite les pics de demande, tels que décrits dans les articles analysés. Ensuite, une analyse des articles portant sur l'application de l'apprentissage automatique dans la gestion des chaînes d'approvisionnement a été réalisée, afin d'identifier les méthodes employées et d'élaborer une stratégie de modélisation pour résoudre le problème. Enfin, une attention particulière a été portée sur l'utilisation de l'apprentissage automatique pour la prédiction des retards dans les

systèmes manufacturiers, dans le but de sélectionner les variables pertinentes pour la construction du modèle et d'identifier les techniques d'apprentissage les plus adaptées. Cette démarche a permis d'établir une base solide pour concevoir une solution adaptée au problème étudié.

3.2 Modélisation du système de simulation et des expériences

3.2.1. Reproduction d'une chaîne de production gérée en DDMRP

Le système de simulation inspiré de Alves., et al. [22] représente une chaîne de production gérée en DDMRP. Ce modèle a été reproduit à l'aide de SIMIO, un logiciel doté d'une fonctionnalité préconfigurée spécifiquement pour le DDMRP comme le montre la Figure 3.2. Cette fonctionnalité facilite la définition des tailles de zones tampons et le calcul de la position de flux net. De plus, SIMIO offre une interface utilisateur conviviale sous forme de tableaux de bord interactifs, permettant de visualiser l'évolution des stocks ainsi que la position de flux net, ce qui aide à suivre et analyser les performances du système en temps réel.

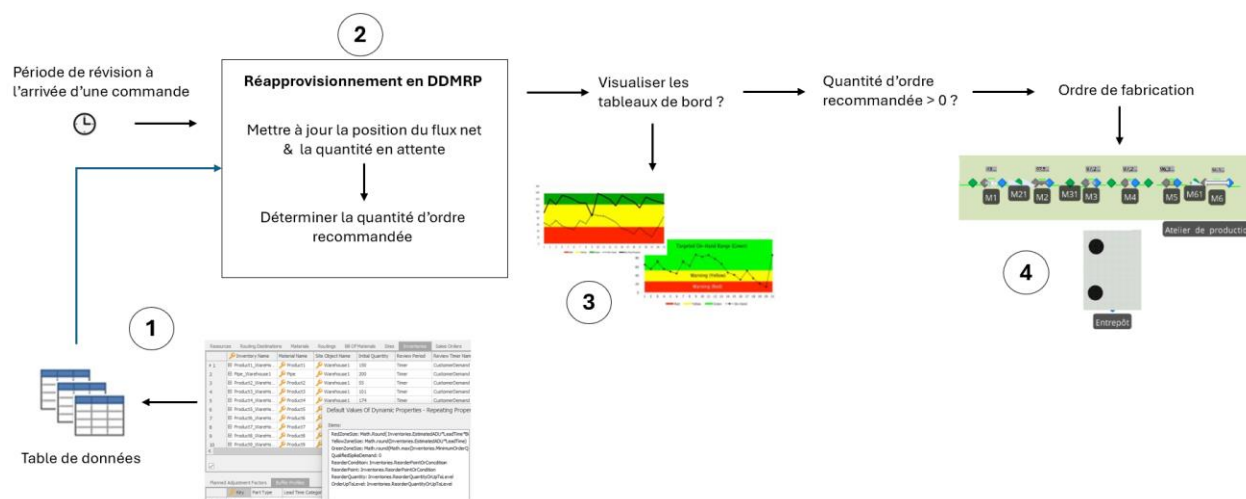


Figure 3.2 : Schéma explicatif du fonctionnement de DDMRP sous SIMIO

La Figure 3.2 décrit le fonctionnement du modèle de simulation développé sur SIMIO, tandis que le cas d'étude est détaillé dans le chapitre quatre. L'utilisation de SIMIO se présente comme suit :

(1) Définition des tables de données et des processus : Nous définissons les tables d'entrées et de sorties, qui contiennent des informations essentielles telles que la nomenclature des produits, les données associées (méthode de réapprovisionnement, consommation journalière moyenne,

tailles des zones tampons), les profils de tampons, ainsi que la table des commandes et la table de définition des ressources. Parmi les tables de sorties figurent la table des ordres de fabrication générés au cours de la simulation et, bien évidemment, la table contenant les variables pertinentes qui vont être utilisées dans l'apprentissage. Dans cette étape, nous définissons également les processus de réapprovisionnement, le cheminement des ordres et le calcul des différentes sorties du système.

(2) Mise à jour lors de l'arrivée d'une commande : Lorsqu'une commande arrive, le mécanisme de réapprovisionnement en DDMRP met à jour la position de flux net et la quantité en attente, et calcule la quantité d'ordre recommandée.

(3) Personnalisation des tableaux de bord : À ce stade, SIMIO offre une fonctionnalité avancée permettant de personnaliser les tableaux de bord pour une visualisation intuitive des données. Ces tableaux permettent de suivre les zones tampons, d'analyser l'évolution de la position de flux net et de surveiller le stock actuel de manière claire et interactive.

(4) Génération et traitement de l'ordre de fabrication : Si la position de flux net passe sous le seuil supérieur de la zone jaune, une quantité d'ordre recommandée positive est générée, entraînant l'émission d'un ordre de fabrication vers l'atelier de production. Une fois l'ordre traité et la quantité produite, la commande est finalisée et un délai d'attente est attribué.

Dans cette étude, les pics de commande ponctuels (Order spikes) ne sont pas pris en compte. L'étude adresse seulement les situations de pics de demande, soit une augmentation prolongée et prévisible de la demande où il est courant d'avoir des retards des ordres de réapprovisionnement. Par conséquent, la demande qualifiée correspond à la quantité des commandes du jour même et des commandes en souffrance. Ces dernières, appelées retards des ordres de réapprovisionnement représentent des ordres de réapprovisionnement de tampons qui ne peuvent être exécutées à temps en raison de longues files d'attente dans la production. Les commandes en souffrance sont traitées dès qu'un réapprovisionnement devient disponible.

3.2.2. Test du modèle avec différents scénarios

Les expériences sont basées sur le cas étudié par Alves., et al. [22], présenté dans le Tableau 3.1, et comportent un total de 9 scénarios expérimentaux : trois niveaux de taux de charge (80 %, 90 % et 95 %). Pour atteindre ces niveaux, un coefficient de multiplication est appliqué à chaque machine afin d'augmenter le taux de charge global de l'atelier de production. De plus, pour chaque taux de charge, trois niveaux de Lead Time (LT) sont définis : faible, moyen et élevé. Les valeurs correspondantes ont été directement reprises du cas d'étude de Lucas. Par exemple, comme illustré dans le Tableau 1.2, avec un taux de charge de 90 %, les Lead Times de 9,72 heures, 11,64 heures et 13,20 heures sont respectivement utilisés pour les niveaux faible, moyen et élevé.

Tableau 3.1 : Niveaux de LT en fonction du taux de chargement

	Taux de charge		
Lead Time	80%	90%	95%
Faible	8.12h	9.72h	11.36
Moyen	9.52h	11.64h	13.76h
Élevé	10.64h	13.20h	16.08h

Pour chaque expérimentation, 30 répliques ont été effectuées sur une période de simulation de 130 jours, en considérant que l'atelier fonctionne 24 heures sur 7 jours. Une période de warm-up de 11 jours a été appliquée, et les résultats ont été analysés avec un intervalle de confiance de 95%. Les résultats obtenus lors de ces expérimentations sont illustrés dans la Figure 3.3.

Les expérimentations réalisées ont été rigoureusement validées en se basant sur les résultats obtenus par Alves., et al. [22]. Cette validation confirme que, quel que soit le scénario envisagé, des retards apparaissent systématiquement dans les ordres de réapprovisionnement. En d'autres termes, chaque configuration testée montre une incapacité à respecter les délais prévus pour le réapprovisionnement, ce qui pourrait avoir des implications importantes sur la chaîne logistique.

La Figure 3.3 offre une analyse détaillée en présentant, pour chaque scénario, le pourcentage de commandes livrées dans les délais. Ce graphique permet de visualiser clairement les variations de

performance entre les différents scénarios et d'identifier ceux qui, malgré la présence de retards, parviennent à garantir un taux relativement élevé de commandes ponctuelles.




Figure 3.3 : Diagramme en boîte du pourcentage de commandes à temps par scénario


3.2.3. Choix du cas d'étude

Le cas d'étude se concentre sur l'ensemble des scénarios analysés lors des expérimentations, permettant d'identifier avec précision les situations dans lesquelles apparaissent des retards d'ordre de réapprovisionnement. En examinant ces différents cas, l'objectif est de mieux comprendre les conditions et les facteurs qui favorisent l'accumulation des retards dans les commandes et d'évaluer leur impact sur l'ensemble de la chaîne d'approvisionnement. Par ailleurs, ces scénarios ont pour vocation de générer un ensemble de données riche et diversifié, destiné à servir d'entraînement et de test pour des modèles d'apprentissage automatique. En simulant diverses conditions de réapprovisionnement et en capturant les occurrences de retards, cette approche offre une base de données représentative de la complexité du système, facilitant ainsi l'élaboration d'algorithmes capables de prédire les retards.

3.3 Génération de données d'entraînement et de test

À partir des scénarios effectués, plusieurs répliques ont été générées pour obtenir les données d'entraînement et de test nécessaires. Ces données excluent les commandes livrées à temps et se

concentrent uniquement sur celles en retard ou impliquant un retard d'ordre de réapprovisionnement. Les commandes livrées à temps ont été volontairement exclues du jeu de données utilisé pour l'apprentissage automatique, car l'objectif de cette étude est de prédire la durée du retard lorsqu'un retard est présent, et non de déterminer si une commande sera livrée en retard ou à temps. La génération des données et la sélection des variables ont été réalisées de manière itérative. Au début, les variables ont été sélectionnées à partir de la littérature puis l'exécution des modèles d'apprentissage et l'évaluation des performances des modèles ont été faites. Plusieurs itérations ont été faites pour atteindre des résultats satisfaisants. Dans le chapitre 4 section 4.3.1.4, le tableau 4.7 explique les variables finales sélectionnées. La Figure 3.4 fournit une capture d'écran des variables sélectionnées dans le logiciel SIMIO. La section suivante abordera les différentes méthodes d'apprentissage utilisées, ainsi que les cas d'étude étudiés à chaque itération de génération de données. Une comparaison des résultats permettra de démontrer comment la qualité des données a été améliorée au fil des itérations.

DDMRP Review																
Time	MaterialName	Net Flow Position	Quantity In Stock	Quantity On Order	Quantity Backordered	▼	Lmax	WIP	M1	M2	M3	M4	M5	M6		
02/12/2022 20:22:26	Product18	135	11	167	43	46	3358	43	41	0	40	0	43	44		
02/12/2022 20:22:26	Product20	140	11	265	136	46	3358	0	182	0	0	39	44			
02/12/2022 20:22:26	Product21	73	4	105	36	46	3358	0	36	0	51	0	18			
02/12/2022 20:22:26	Product22	120	7	179	66	46	3358	0	77	0	52	0	50			
02/12/2022 20:22:26	Product25	114	5	184	75	46	3358	0	49	0	26	28	81			
02/12/2022 20:22:26	Product26	77	2	110	35	46	3358	0	16	19	18	19	38			
02/12/2022 20:22:26	Product27	66	2	105	41	46	3358	0	62	0	0	17	26			
02/12/2022 20:22:26	Product28	90	9	159	78	46	3358	0	24	27	25	0	83			
02/12/2022 20:22:26	Product29	115	8	130	23	46	3385	0	28	0	26	27	49			
02/12/2022 20:22:26	Product30	107	4	230	127	46	3385	0	73	25	28	26	78			


Orders								
Materials.MaterialName	Quantity	ReleaseDate	▲	Ship Date	Status	▼	BackorderTime	
Product22	12	07/12/2022 17:56:25		07/12/2022 20:38:34	Late		2,7	▲
Product22	13	07/12/2022 19:53:38		07/12/2022 20:38:34	Late		0,749	
Product19	21	07/12/2022 20:13:39		07/12/2022 21:02:43	Late		0,818	
Product26	8	08/12/2022 02:23:40		08/12/2022 02:57:03	Late		0,556	
Product3	63	08/12/2022 03:23:34		08/12/2022 05:09:45	Late		1,77	
Product26	9	08/12/2022 05:41:08		08/12/2022 05:48:57	Late		0,13	
Product17	27	08/12/2022 06:13:54		08/12/2022 06:56:59	Late		0,718	
Product25	12	08/12/2022 06:40:30		08/12/2022 09:28:40	Late		2,8	
Product25	14	08/12/2022 07:37:37		08/12/2022 09:28:40	Late		1,85	
Product20	26	08/12/2022 07:53:19		08/12/2022 11:43:09	Late		3,83	
Product25	15	08/12/2022 11:06:15		08/12/2022 14:03:31	Late		2,95	▼

Figure 3.4 : Exemple d'extraction de données sur SIMIO

3.4 Procédure d'apprentissage

Cette section se divise en deux parties, s'appuyant sur les travaux présentés dans la section précédente pour construire une approche méthodique et rigoureuse. Dans un premier temps, une sélection de variables pertinentes a été réalisée, suivie de la génération des données, comme

expliqué précédemment. Des étapes essentielles de prétraitement ont ensuite été mises en œuvre, incluant le nettoyage des données pour éliminer les incohérences, la transformation des types de variables pour les adapter aux modèles d'apprentissage, et une analyse approfondie des corrélations afin d'identifier les relations significatives entre les variables. Ces étapes visaient à garantir une qualité optimale et une cohérence des données, conditions indispensables à des prédictions fiables.

Bien que les données utilisées soient issues d'un modèle de simulation, leur qualité a été assurée par une stratégie rigoureuse. Le modèle de simulation a été construit indépendamment de l'étape d'apprentissage automatique, et aucune adaptation des scénarios simulés n'a été effectuée en fonction des résultats des modèles prédictifs. Les ensembles d'entraînement et de test ont été strictement séparés, et toutes les métriques de performance (RMSE, MAE, R^2) ont été calculées sur des données de test indépendantes. Cette séparation garantit que les prédictions ne sont pas biaisées par un sur-ajustement aux données simulées et assure une évaluation objective de la capacité de généralisation des modèles. Dans un second temps, différentes méthodes d'apprentissage automatique ont été utilisées pour prédire les retards des ordres de réapprovisionnement. Cette phase a impliqué un ajustement systématique des hyperparamètres, combiné à une validation croisée en K-fold. Bien que le système DDMRP évolue dans le temps, les données utilisées pour l'entraînement des modèles sont structurées sous forme d'observations indépendantes du temps. Chaque ligne représente une photographie ponctuelle de l'état du système à un moment donné sans relation temporelle directe avec les observations précédentes. De ce fait, l'utilisation d'une validation croisée aléatoire de type K-Fold est justifiée. Elle permet de tester la robustesse du modèle sur des combinaisons diverses de configurations du système, sans introduire de biais temporel. Cette validation croisée a permis de diviser les données d'entraînement en plusieurs sous-ensembles afin de tester les performances des modèles sur des configurations variées. L'objectif était d'explorer et d'évaluer plusieurs combinaisons de paramètres pour chaque méthode d'apprentissage automatique, permettant ainsi de sélectionner les hyperparamètres optimaux tout en réduisant les risques de surapprentissage. L'application rigoureuse de cette approche a permis de déterminer les modèles les plus performants pour la tâche spécifique de prédiction des retards, tout en mettant en lumière les limites éventuelles des différentes configurations testées. Les détails des hyperparamètres ajustés, les résultats des modèles, et leur évaluation comparative sont décrits en détail dans le chapitre 4 et l'annexe A. Cette démarche

méthodologique contribue à établir une base solide pour l'intégration des prédictions dans un cadre décisionnel adapté à la gestion des systèmes DDMRP.

3.5 Évaluation des performances et de l'importance des variables

Cette étape constitue un point essentiel du processus, car elle ne se limite pas à l'évaluation des performances des modèles et de l'importance des variables, mais elle jette également les bases d'une sélection plus précise et réfléchie des variables. Une évaluation approfondie a été menée pour identifier la méthode offrant les prédictions les plus fiables. Comme détaillé dans le chapitre 4, cette évaluation inclut les techniques d'apprentissage utilisées ainsi que les approches adoptées pour mesurer et comparer les performances des modèles. Dans un premier temps, les performances des modèles ont été comparées à une Baseline simple, basée sur la prédiction de la moyenne des temps de retard. Ce choix permet d'établir une référence minimale permettant de quantifier l'amélioration réelle apportée par les modèles d'apprentissage automatique. Bien que cette approche soit simpliste, elle permet d'interpréter facilement les gains obtenus en termes de MAE ou de RMSE. Une fois cette analyse complétée, les résultats ont été soigneusement examinés pour déterminer si des améliorations dans la sélection des variables étaient nécessaires et si le modèle pouvait être jugé suffisamment performant pour prédire les retards des ordres de réapprovisionnement. Dans cette optique, une analyse de l'importance des variables a été effectuée pour identifier celles ayant un impact significatif sur le modèle. Cette étape a permis d'évaluer quelles variables pourraient influencer positivement la performance du modèle et, par conséquent, de prioriser leur intégration. Sur cette base, une nouvelle sélection de variables a été réalisée, intégrant des variables clés identifiées comme essentielles pour améliorer la précision et la robustesse des prédictions. Cette approche itérative, reposant sur l'évaluation continue des modèles et l'ajustement des variables, garantit une optimisation progressive des performances tout en assurant une meilleure adéquation avec les spécificités et les exigences du système étudié.

3.6 Conclusion

En résumé, ce chapitre met en lumière la méthodologie adoptée pour répondre aux objectifs définis dans l'introduction de ce projet de recherche. Structurée en cinq étapes distinctes, soigneusement détaillées, cette méthodologie couvre une revue approfondie de la littérature, la modélisation du système à l'aide de simulations et d'expériences, la génération des données d'entraînement et de test, la procédure d'apprentissage, ainsi que l'évaluation des performances des modèles et de

l'importance des variables. Le chapitre suivant, consacré à la présentation du modèle, décrira en détail les étapes spécifiques de la méthodologie appliquée. Enfin, une discussion générale clôturera ce document, permettant d'analyser les résultats obtenus, de confronter ces derniers à la problématique initiale et d'apporter des solutions aux enjeux identifiés.

CHAPITRE 4 ARTICLE 1 : BACKORDER TIME
PREDICTION IN A DDMRP MANAGED PRODUCTION SYSTEM

Cet article a été soumis au journal Computers In Industry en mars 2025.

La version présentée dans cette section est identique à la version soumise.

Les auteurs de cet article sont : Karim Djedidi^a, Maha Benali^{a,*}, Pierre Baptiste^a

^a Département de mathématiques et génie industriel, Polytechnique Montréal, 2500 Chemin de Polytechnique, Montréal, H3T 1J4, Québec, Canada

Résumé

La littérature indique que, dans des conditions normales, la méthode DDMRP (Demand-Driven Material Requirements Planning) est efficace pour gérer les stocks, rationaliser la production et améliorer la satisfaction des clients. Toutefois, les commandes en souffrance sont une réalité inévitable lorsque les pics de demande augmentent temporairement les taux de chargement. Dans ce cas, les clients doivent être informés des retards de commandes approximatifs afin d'éviter tout mécontentement et toute perte de chiffre d'affaires. Cette étude vise à développer une approche basée sur l'apprentissage pour prédire les retards des ordres de réapprovisionnement dans une ligne de production gérée par DDMRP et à identifier les informations pertinentes nécessaires pour obtenir des prédictions précises. La simulation est utilisée pour générer des données d'entraînement et de test pour les modèles d'apprentissage automatique. Les résultats démontrent que les modèles de régression sont efficaces pour prédire les retards des ordres de réapprovisionnement pendant les périodes de forte demande et montrent que XGBoost est le plus performant. En outre, cette étude souligne que les variables décrivant l'état du système ont un impact plus important sur la précision de la prédiction que les variables liées aux commandes des clients.

Mots-clés : DDMRP, retards des ordres de réapprovisionnement, temps d'attente, apprentissage automatique, simulation.

Abstract

The literature indicates that under normal conditions, Demand-Driven Material Requirements Planning (DDMRP) is effective in managing inventory, streamlining production, and improving customer satisfaction. However, backlogs are an inevitable fact of life when peaks in demand temporarily increase loading rates. In these cases, customers need to be informed of the approximate backorder times to avoid dissatisfaction and lost sales. This study aims to develop a learning-based approach to predicting backorder times in a DDMRP-managed production line and to identify the relevant information needed to achieve accurate predictions. Simulation is used to generate training and test data for machine learning models. Results demonstrate that regression models are effective in predicting customer backorder times during periods of high demand and show that XGBoost performs best. In addition, this study highlights that variables describing the system state have a greater impact on prediction accuracy than variables related to customer orders.

Keywords: DDMRP, Backorder Time, Waiting time, Machine Learning, Simulation.

4.1 Introduction

In today's dynamic market environment, customer satisfaction has become a critical factor in a company's success and competitiveness. It depends not only on the quality of products, but also on the reliability of services and, above all, on the ability to meet promised delivery times. To achieve these expectations, companies are increasingly adopting advanced planning methodologies, such as Demand-Driven Material Requirements Planning (DDMRP). DDMRP is a hybrid planning and execution method that combines elements of both push and pull strategies to optimize inventory and production flows Ptak and Smith [6]. Designed to improve supply chain visibility, reduce lead times, and ensure that the right inventory is available in the right place at the right time, DDMRP helps companies better respond to real-time demand signals rather than traditional predict-based planning methods [23]. Protecting critical points with strategically placed inventory buffers makes the DDMRP method particularly effective in environments characterized by high demand variability [5].

Despite its benefits, DDMRP faces several challenges, especially in scenarios where high customer demand triggers multiple production orders simultaneously. Such situations can cause sudden spikes in production loads, resulting in temporary capacity bottlenecks, extended waiting times, and ultimately backorders. In a DDMRP system, customer orders are typically fulfilled from inventory buffers. However, if buffer replenishment orders cannot be completed on time due to long production queues or capacity constraints, buffer levels may fall short, risking the inability to meet customer orders.

In this paper, we define a backorder time in a DDMRP system as *“the time from the due date of a buffer replenishment order until the full required quantity is received”*. One of the major limitations identified in the DDMRP literature is the lack of effective methods for accurately predicting waiting times and estimating delivery dates under high load conditions. While digital twins can be powerful tools for predicting delays in production systems, developing a digital twin requires a substantial initial investment, which can vary widely depending on several factors. These factors include the difficulty of integrating real-time data, managing large amounts of information, achieving seamless system interoperability, ensuring data security and privacy, and the need for significant computational resources to handle complex simulations [2].

This paper aims to propose an alternative to digital twins for predicting backorder times in a DDMRP-managed production system. The objective is to provide decision-makers with a tool that estimates backorder times using a limited set of DDMRP system state information, without relying on a full digital twin, in order to support reliable delivery date commitments. To this goal, we propose to develop a learning-based approach that can predict backorder times in a DDMRP system. The study begins by generating knowledge through a model of a DDMRP-managed flow shop where various production scenarios with heterogeneous orders and high load conditions are simulated to replicate real-world complexity. Discrete event simulation enables us to gather valuable data during peak demand periods. The data generated from these scenarios is then used to train and test Machine Learning (ML) models to predict backorder times. Finally, results analysis evaluates the effectiveness of these models by comparing predicted and actual backorder times. The results provide valuable insights into the potential of integrating ML and simulation techniques to predict performance metrics in complex manufacturing environments.

The paper is structured as follows. Section 4.2 presents the related literature, introducing the concepts of DDMRP, how DDMRP handles demand peaks, and providing an overview of studies on backorder time, and the use of ML to predict delays in manufacturing systems. Section 4.3 explains the simulation model and the experiments conducted to generate data, along with a detailed step-by-step description of the learning process for backorder time prediction. Section 4.4 presents an analysis of the results. Section 4.5 provides a discussion of the findings and their broader implications. Finally, Section 4.6 presents a general conclusion.

4.2 Related Literature

4.2.1 DDMRP Concepts

Introduced by Ptak and Smith in 2011, the DDMRP is a comprehensive, multi-tiered approach to both planning and execution. What sets DDMRP apart is its integration of both push and pull methodologies. It works by strategically positioning inventory buffers throughout the supply chain to ensure a continuous flow of materials and information [23].

In the DDMRP methodology, tricolor inventory buffer zones (Red, Yellow, and Green zones) are critical for effectively managing inventory to adapt to fluctuations in supply and demand. Each zone serves a unique function and is calculated using key parameters, as shown in Figure 4.1. These key parameters are:

- Average Daily Usage (ADU): represents the average daily consumption of an item and is the basis for calculating buffer size;
- Decoupled Lead Time (DLT): indicates the longest cumulative lead time between the buffer and upstream supply chain points, guiding the buffer stock required to manage potential delays;
- Lead Time Factor (LTF): reflects the level of lead time variability. Expressed as a percentage (20% to 100%), it is used to adjust buffer quantities;
- Variability Factor (VF): reflects the level of demand and supply variability. Expressed as a percentage (0% to 100%), it helps to scale buffer sizes to match variability;
- Minimum Order Quantity (MOQ): is the minimum quantity that can be purchased in a single order, affecting replenishment frequency and order sizes.




Figure 4.1: Buffer zones [8]

The Green Zone is the top level and serves as a reserve for unexpected demand surges, ensuring that sufficient stock is available to meet unforeseen increases in demand. The Yellow Zone, located below the Green Zone, represents the typical demand buffer. This zone ensures to maintain a balanced flow by meeting regular demand without overstocking. The Red Zone is the most critical buffer level to account for demand and supply variability. This zone acts as the last line of defense against stockouts, triggering urgent replenishment when stock levels fall too low [24]. The Net Flow Position (NFP), calculated as *the sum of the Quantity On hand, the Quantity On order, minus the Qualified demand*, provides a real-time snapshot of inventory status in relation to these buffer

zones. *Qualified demand* is the sum of sales orders past due, sales orders due today, and qualified spikes. A qualified spike is a qualifying quantity of known cumulative daily demand within a qualifying time window that threatens the integrity of the buffer [6].

Ptak and Smith [6] propose to generate replenishment orders based on NFP. Each time the NFP is computed for each buffer, it will dictate whether a replenishment order will be recommended. When the NFP drops below the Top of Yellow, it signals that stock is running low and a replenishment order is initiated to restore stock levels to the Top of Green level. This dynamic system ensures that enough inventory is available to meet future demand while preventing overstocking [23]. Additionally, the buffer zones help prioritize replenishment orders based on inventory status relative to demand. As stock approaches the Red Zone, the priority for replenishment increases, reducing the risk of stockouts and ensuring that critical customer orders are fulfilled on time. This adaptive approach, driven by carefully parameterized buffers, enables DDMRP to manage demand variability effectively while maintaining optimal inventory levels [6].

4.2.2 DDMRP and Irregular Demand

The DDMRP literature refers to irregular demand primarily as order spikes, which are sudden, short-term increases in demand caused by unexpected customer orders. Ptak and Smith [6] define order spikes as “*future daily orders that generate an overwhelming surge, potentially compromising the buffer integrity if not taken into account*”. They suggest that only qualified order spikes should be considered in the NFP calculation, where a qualified order spike is defined as a qualifying quantity of known cumulative daily demand within a qualifying time window that threatens the integrity of the buffer. This requires the definition of two parameters: the Order Spike Threshold (OST) and Order Spike Horizon (OSH).

Few studies have addressed order spike management, offering distinct approaches to optimizing DDMRP systems. Damand, et al. [8] propose a simulation-optimization framework to set static parameters such as OST and OSH. By treating these parameters as part of a multi-objective optimization model, the study offers to balance on-hand inventory levels with on-time delivery rates. The model assumes that demand is known in advance, which limits its adaptability in highly dynamic environments, where demand can fluctuate unpredictably. To overcome this limitation, Duhem, et al. [25] present a dynamic approach that uses Reinforcement Learning (RL) to adjust OST and OSH. The authors use a branching dueling Q-Network to dynamically adjust these

parameters based on real-time fluctuations. Continuous learning enables the system to handle frequent and unpredictable order spikes with greater accuracy. In contrast to Damand, et al. [8]'s approach, Duhem, et al. [25]'s approach is characterized by its ability to adapt to evolving conditions as the system operates. The RL agent demonstrated superior performance in handling high workloads and frequent spikes, achieving reduced stock levels while maintaining customer satisfaction.

Considering a real DDMRP system, Dessevre and Benali [1] use simulation to compare the performance of different capacity management approaches when faced with irregular demand. The study shows that a dynamic approach that anticipates the workload outperforms two approaches from the literature by maximizing resource utilization while maintaining a high level of customer service. However, the workload anticipation module proposed in this study is specific to the case study and cannot be generalized to other cases.

Duhem, et al. [25] and Damand, et al. [8] consider demand with order spikes that are different from the demand peaks studied in this paper. By demand peaks, we refer to longer-term, predictable increases in demand that follow predictable patterns, such as seasonal fluctuations or market trends. While demand peaks present challenges related to long-term planning, capacity allocation, and inventory optimization over extended periods of time, order spikes are unpredictable and require immediate adjustments to maintain system stability. There is a lack of research in the literature on the impact of peak demand on the efficiency of production and inventory management within DDMRP. In addition, no study has provided tools to ensure customer satisfaction without frequent reactive actions.

4.2.3 Backorder Prediction

Several studies have approached the problem of backorder prediction as a classification problem, where the goal is to determine whether a product will be backordered or not. For instance, Ali, et al. [26], Ntakolia, et al. [27], and Islam and Amin [28] have all tackled this challenge using the Kaggle dataset "Predict Product Backorders," which encompasses a total of 23 features, encompassing inventory levels, lead times, and sales predictions. While Ali, et al. [26] emphasize the value of explainable models in enhancing decision-making processes, Ntakolia, et al. [27] undertake a comparative analysis of various classification models, including Light Gradient Boosting Machines and XGBoost, employing SHAP to elucidate the significance of features. Islam

and Amin [28] also address the same classification problem, but with a focus on improving model accuracy. To this end, they use techniques such as Distributed Random Forest and Gradient Boosting Machines to address data imbalance. Despite the common problem and dataset, these studies diverge in their methodological focus, employing different approaches to model selection, performance optimization, and feature interpretability.

In the same sense, Rodger [29] has developed regression and classification methods to provide backorder predictions. Datasets from the Defense Logistics Agency's Requisition and Procurement History Data Marts have been used and included variables such as administrative lead time, production lead time, unit price, ordered quantity, and inventory status. Regression models predict the duration of backorder aging, while Bayesian networks classify items based on the likelihood of backorder occurrence, using triggers such as acquisition advice codes and controlled inventory item codes. A fuzzy feasibility Bayesian probabilistic estimation model, coupled with stochastic simulation, refines this classification by dynamically adjusting probabilities in response to changes in supply chain triggers. This hybrid approach enables proactive backorder risk management and provides a structured method for predicting backorder time in complex supply chain environments.

While previous studies have mainly focused on predicting backorders using existing datasets, this paper proposes a distinct approach by training ML models using data generated by simulating a model of a typical production system facing demand peaks.

4.2.4 Manufacturing Delay Prediction using Machine Learning

In this subsection, we extend the literature review to include some studies that use ML to predict delays other than backorder times in manufacturing systems. The studies reviewed are summarized in Table 4.1. All of them demonstrate the ability of ML to predict delays and improve scheduling in a variety of manufacturing systems, and the relevance of both order-related and production-related features.

Table 4.1: Examples of papers using ML to predict delays in manufacturing systems

Article	Prediction topic	Manufacturing System	Dataset	Features used	ML models
Alenezi, et al. [16]	Flow times and delivery dates	Make-to-order production system	Data generated	Customer workload, order size, processing	Support Vector Machine (SVM), Artificial Neural Networks

			by simulation	times, queue lengths, arrival rates	(ANNs), Time-Series Models
Burggräf, et al. [18]	Assembly start delays due to missed components	Engineer-to-order production system	Real-world data	Lead time, workstation type, production order creation delay, bill of materials, component availability	Random Forest (RF), Decision Tree (DT), Logistic Regression, K-Nearest Neighbors
Rokoss, et al. [19]	Delivery dates early in the production process	Job shop	Real-world data	Customer order size, Work-In-Progress (WIP), customer data, machine utilization, range of bottleneck which is the maximum waiting time across all production systems, process times.	Gradient Boosting Machines (GBM), DT, RF, SVM
Schneckenreither, et al. [17]	Lead times	Make-to-order production system	Data generated by simulation	Product routing, production order lead times, processing times, queue times, mean and standard deviation of flow times, and WIP levels.	ANNs
Yang, et al. [20]	Flow times	Dynamic job shop	Data generated by simulation	Job characteristics such as the number of operations, total processing time, machine queue lengths, and workload across the shop.	Orthogonal Kernel Least Squares Algorithm and Back-Propagation Neural Network

4.2.5 Paper contribution

The DDMRP literature doesn't provide clear guidance on how to estimate backorder times during demand peaks, which is key information that must be communicated to customers to prevent dissatisfaction and lost sales. This paper attempts to fill this gap and improve customer satisfaction with DDMRP systems by i) developing a learning-based approach to predicting backorder times in a DDMRP-managed production system, and ii) identifying the relevant information needed to generate accurate predictions.

From a methodological point of view, this paper demonstrates a practical application of ML in an area where its use remains limited. Unlike existing studies that use simulation to evaluate the

performance of DDMRP systems, this paper uses simulation to generate data that will be used to train different ML models and extend the functionality of DDMRP by embedding predictive insights.

4.3 Methodology

In this paper, we define a backorder time in a DDMRP system as the time from the due date of a buffer replenishment order until the full required quantity is received.. To predict backorder times , we propose the methodology shown in Figure 4.2. Inspired by the literature (see Table 4.1), we identify several potential features that may be relevant to backorder time prediction. We then follow a four-step process:

- 1) **Data generation:** several scenarios, including a large number of backorders, are simulated to generate data (i.e., inputs and outputs of the simulation model);
- 2) **Learning:** part of the generated data is used to train various ML predictive models;
- 3) **Prediction accuracy evaluation and feature importance:** the remaining data is used to evaluate the prediction accuracy and importance scores are calculated for each feature. If the accuracy is acceptable, the results are analyzed to provide managerial insights and the process ends. Otherwise, we move on to step 4;
- 4) **Feature selection:** based on the importance scores, we select the features that contribute most to predict backorder times, add new features, and return to step 1.

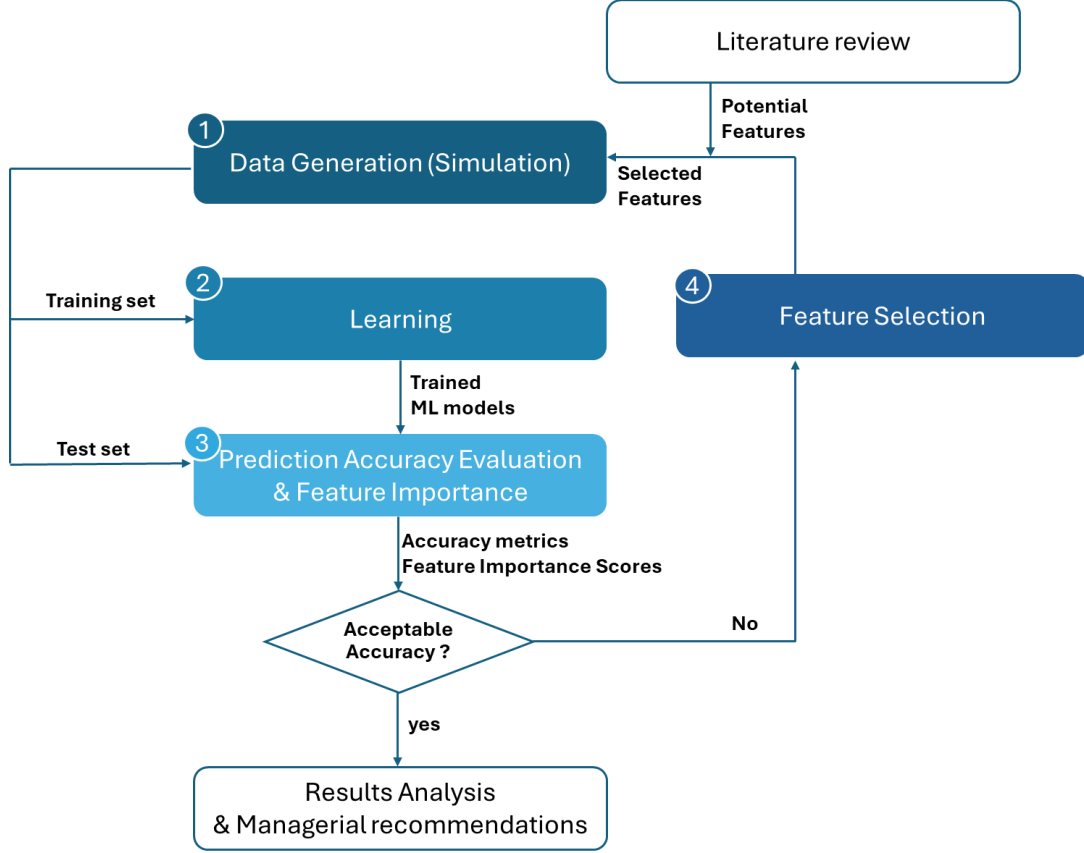


Figure 4.2: General methodology

This methodology, which combines simulation-based knowledge generation, a learning process, and a comprehensive results analysis provides a robust framework for predicting backorder times in DDMRP-managed systems. More details are provided in what follows.

4.3.1 Generating knowledge using simulation

4.3.1.1 Simulation Model Description

To generate knowledge, we propose to simulate a DDMRP system facing situations with many backorders. A backorder occurs when the *Quantity On hand* is insufficient to fill a customer's order, and the customer has to wait until that quantity increases enough to fill his pending order. This wait time is the backorder time. Inspired by the model of Alves., et al. [22] which represents a flow shop managed by DDMRP (see Figure 4.3), we developed a discrete event simulation model using Simio software. We consider multiple machines producing different final products, all managed by DDMRP, and an unlimited raw material supply. As in Alves., et al. [22]'s model, customer requests a single product. For every customer order received, the model updates the NFP

of the requested product and its parameters accordingly. If the customer order size is less than or equal to the On Hand, the customer order will be filled and expedited immediately. Otherwise, the customer order will be delayed until sufficient stock is available.

Following the DDMRP methodology explained in Section 0, each time the NFP is computed for a buffer, it will dictate whether a replenishment order will be recommended. When the NFP drops below the Top of Yellow, a replenishment order is created to restore stock levels to the Top of Green (TOG) and the replenishment order size is equal to the difference between the TOG and the current NFP. Replenishment orders are prioritized based on the highest buffer penetration percentage (i.e., the position of the NFP compared to the TOG). A First-In, First-Out rule is applied when multiple replenishment orders have the same priority.

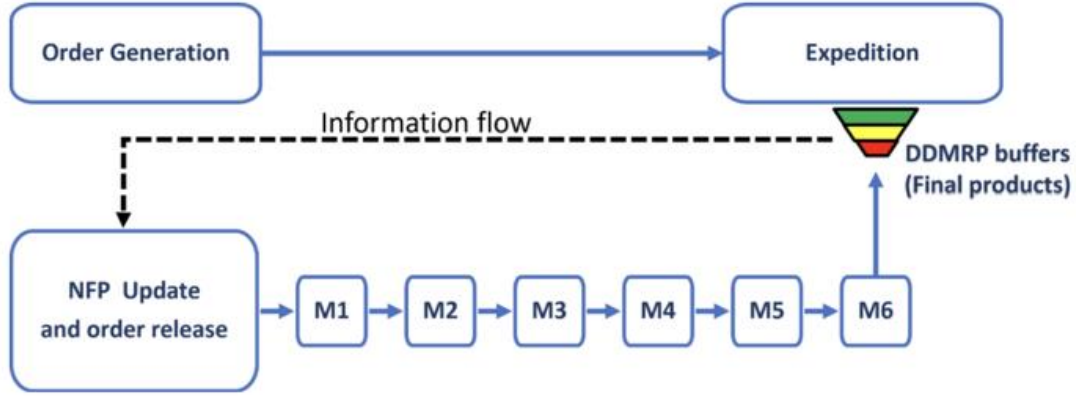


Figure 4.3: The simulation model

4.3.1.2 Case Study Description

In this study, as in Alves., et al. [22], we consider six machines and 30 final products. Table 4.2 shows the ADU for each product. The customer order size follows a normal distribution with a mean equal to the product ADU and a variance equal to 10% of the ADU. Customer arrivals follow an exponential distribution at the rate of 3 orders per day for products P1 to P10, 6 orders per day for products P11 to P20, and 12 orders per day for products P21 to P30. The processing times for each product on each machine are presented in Table 4.3 are randomly varied using a triangular distribution TRI(0.8, 1, 1.2). To obtain different loading levels for the flow shop, we scale the processing times by a multiplication coefficient C to modify the loading rate.

Table 4.2: Average Daily Usage (units)

Product	P1	P2	P3	P4	P5	P6	P7	P8	P9	P10
ADU	195	69	165	189	57	114	87	99	183	102
Product	P11	P12	P13	P14	P15	P16	P17	P18	P19	P20
ADU	183	186	171	96	156	63	183	126	144	132
Product	P21	P22	P23	P24	P25	P26	P27	P28	P29	P30
ADU	105	156	69	168	165	111	96	153	165	156

Table 4.3: Processing times (seconds) of Lucas. et al. (2024)

	Machines					
Products	M1	M2	M3	M4	M5	M6
P1-P10	5	5	5	10	15	5
P11-P20	5	10	10	10	10	10
P21-P30	5	15	15	10	5	15

The DDMRP buffer parameters are set according to Lucas Alves et al. (2024). We consider a VF of 0.5 for all the DDMRP buffers. The LTF varies according to processing times (see Table 4.3) and takes 0.75 for products P1 to P10, 0.5 for products for products P11 to P20, and 0.25 for products P21 to P30. The flow shop operates 24h/day.

4.3.1.1 Experimentation

First, we consider nine scenarios, each of which is associated with a pair (lead time, loading rate), in accordance with the experiments carried out by Alves., et al. [22]. We consider three levels for the loading rate (see Table 4.4), which represents the utilization rate of the machine bottleneck. The different loading rates are obtained by multiplying the processing times (see Table 4.3) by a different multiplication coefficient C . As in Alves., et al. [22], we identify three levels (low, medium, or high) of lead times for each loading rate, which are adjusted to influence the size of

the buffer zones. For each scenario, 30 replications are performed. The results are gathered over a simulation period of 130 days, following an 11-day warm-up period to stabilize the system.

Table 4.4: Lead time levels according to the loading rate [22]

	Loading Rate		
Lead Time	80%	90%	95%
Low	8.12h	9.72h	11.36h
Medium	9.52h	11.64h	13.76h
High	10.64h	13.20h	16.08h

The simulation results confirm that all these scenarios lead to backorders. To develop a generalized predictive model, we consider all the scenarios from Table 4.4 and randomly generate replications across them. The resulting dataset created from these random replications is further used to train and test the ML models, with input and output data collected throughout the simulation process.

4.3.1.4 Resulting dataset

The resulting dataset from the simulation of all scenarios comprises 10,620 rows and 15 columns. The target output feature is the backorder time of a delayed customer order, measured from the moment the customer order is received until it is fulfilled. The different input features presented in Table 4.5 have been identified based on articles reviewed in Table 4.1 and the specific context of the project. We categorized them into three feature groups. While the first group is related to the product requested by the customer order, the second group provides information about the DDMRP system status. Finally, the third group tracks the load on the production system. All input features are captured when a customer order is received, providing an insightful snapshot of the system at that moment.

Table 4.5: Input Features Description

Features	Description	Features group		
		Product requested by the customer order	DDMRP system status	Production system load
Product ID	refers to the unique identifier of the product being ordered.	X		
Quantity Ordered	indicates the number of units requested by the customer order.	X		
NFP	qualifies the status of a DDMRP buffer.	X	X	
Quantity On Hand	tracks the number of units of a product that are physically available.	X	X	
Quantity Backordered	represents the sum of delayed demand awaiting inventory availability.	X	X	
Quantity On Order	indicates the number of units ordered but not yet received in inventory.	X	X	
WIP	tracks the number of units currently in the flow shop.			X
Lmax	represents the highest number of replenishment orders waiting to be processed at the machine bottleneck.			X
Mi (i=1..6)	tracks the Quantity Ordered on each machine Mi.			X

4.3.2 Learning Process

In this study, we employed a structured approach to optimize the ML models used to predict the backorder time of a delayed customer order in a DDMRP flow shop. The process is initiated with data preparation, where the dataset is subjected to preprocessing and partitioned into a training set and a test set. In order to identify optimal hyperparameters for the different ML models, a grid search combined with K-fold cross-validation is used. This approach allowed for the exploration

of various combinations of hyperparameters using only the training data and ensured the selection of optimal parameters while minimizing the risk of overfitting. A variety of ML models are implemented, including linear regression, Random Forest (RF), Decision Tree (DT), Gradient Boosting (XGBoost), Support Vector Machine (SVM) and Artificial Neural Networks (ANNs), with the objective of determining which would be more appropriate for backorder time prediction in a DDMRP flow shop. The variety of ML models allowed for the identification of the most accurate model for backorder time prediction, as each model processed the data differently. After tuning the models on the training set, the best performing model is evaluated on the unseen test set to determine its ability to generalize and its reliability for future predictions.

4.3.2.1 Data preparation

The data preparation phase is a critical juncture in the construction of predictive models, as it impacts the accuracy and reliability of the resulting models. It is imperative to ensure that all inputs are in the required format for the models. A categorical feature, such as Product ID, is converted to numerical values using one-hot encoding, yielding 30 binary columns. Furthermore, scaling features are necessary for stable and efficient learning in artificial neural networks (ANNs) and support vector machines (SVMs). SVM relies on distance-based calculations, which are sensitive to feature magnitudes, while ANN benefits from scaled inputs to prevent gradient instability and accelerate convergence during training. The transformation ensures that the data is in the correct format for modeling. Moreover, an exploratory data analysis is conducted through boxplots to gain insight into the dataset and a correlation matrix to evaluate the relationships between features. Then, the dataset is divided into two subsets: a training set and a test set. The training set is utilized exclusively for model development, including hyperparameter tuning and cross-validation, while the test set is maintained as a separate entity to ensure an impartial evaluation of model performance on previously unseen data.

4.3.2.2 Hyperparameter Tuning with Grid Search

We performed hyperparameter tuning using grid search to optimize the performance of different ML models. Table 4.6 details the hyperparameter configurations explored for each model. Each model is tested with several hyperparameters that control how the model learns from the data. The grid search algorithm, implemented using Python and GridSearchCV function from the Scikit-learn (sklearn) library, systematically explores all possible combinations of these hyperparameters. Each

configuration is evaluated through cross-validation. By iterating over all possible parameter combinations, the algorithm identified the optimal hyperparameter set that maximized predictive accuracy.

Table 4.6: Hyperparameter configurations explored for each model

Model	Hyperparameter	Values
DT	Max_depth	3, 5, 7, 9
	Min_samples_leaf	3, 5, 7
	Min_samples_split	2, 3, 4, 6
RF	N_estimators	50, 100, 250, 500
	Max_depth	3, 5, 7, 9
	max_features	log2
XGBoost	Objective	reg: squarederror
	Colsample_bytree	0.3
	Learning rate	0.1, 0.01, 0.001
	Max_depth	2, 4, 6, 8
	N_estimators	100, 200, 250
SVM	Kernel	Rbf
	Gamma	10, 1, 0.1, 0.01, 0.001
	C	10, 100, 1000
ANN	Activation	'relu', 'tanh'
	Optimizer	'adam'
	Neurons	50, 100
	Batch_size	32, 64
	Epochs	16
	Learning rate	0.001, 0.01

4.3.2.3 K-Fold Cross-Validation

In order to assess the efficacy of each hyperparameter configuration, a 5-fold cross-validation approach was employed during the grid search process. This method involves the division of the dataset into five equal segments. In each iteration, one part is designated as the validation set, while

the remaining four parts are allocated for training, as illustrated in Figure 4.4. This process ensures that each data point has an opportunity to be included in the validation set, thereby providing a more reliable estimate of the model's performance on unseen data. Cross-validation is a process of evaluating the model's performance using different subsets of the data. This process reduces the risk of overfitting by ensuring that the model's performance is consistent across different data sets. Following an exhaustive evaluation of all possible hyperparameter combinations across a series of folds, the grid search methodically identifies the configuration that yields the optimal overall performance.

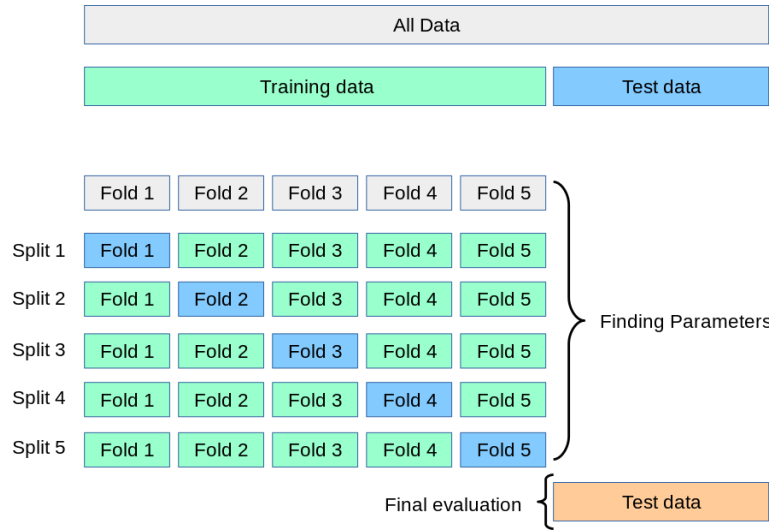


Figure 4.4: 5-Fold Cross-Validation Process [30]

4.3.3 Prediction Accuracy Evaluation

After identifying the optimal hyperparameters through a combination of grid search and cross-validation processes, the selected best model is retrained using 80% of the available training data. This approach ensures that the model uses as much data as possible to improve its learning capabilities while applying the optimal hyperparameter configuration. The remaining 20% of the dataset is designated as test data, allowing for a final evaluation of the model's performance on previously unseen data. To evaluate the effectiveness of the model in predicting backorder times, we employ several performance metrics, including Mean Absolute Error (MAE), Root Mean Squared Error (RMSE), and the coefficient of determination (R^2) (Chai & Draxler, 2014; Janssen & Heuberger, 1995). The objective is to assess the accuracy of the predictions and the extent to which the model accounts for the observed variability.

The metrics obtained with the selected best model are compared to those obtained with an average-based approach, which uses the average backorder time as a prediction for all observations. The main purpose of this comparison is to ascertain whether ML provides substantial enhancements over a naive model. If ML models demonstrate consistent superiority over the average-based approach in terms of accuracy and error reduction, this evidence supports the conclusion that they are effective in delivering more reliable estimates of backorder time.

4.3.4 Feature Importance and Feature Selection

In this study, feature importance is determined using the SHAP (SHapley Additive exPlanations) method, which is a widely used technique in predictive modeling to ensure transparent, interpretable, and reliable decisions [31]. SHAP values provide a robust framework for interpreting ML models by assigning each feature a contribution to a prediction. The magnitude of a feature's SHAP value indicates its importance in that prediction. Unlike traditional feature importance methods such as Gini importance or permutation importance, SHAP values provide both global and local explanations, making them particularly useful for understanding complex, non-linear relationships in production systems like DDMRP. For example, Lundberg and Lee [32] demonstrated that SHAP values consistently provide more accurate insights into model predictions by accounting for feature interactions and distributing importance fairly among correlated variables.

If the feature importance step and the subsequent predictions do not yield satisfactory results (see Figure 4.2), the process is improved by additional feature selection and generating of new dataset through simulation during the data generation phase. The features selected are incorporated into the dataset, enriching it to capture aspects that may have been previously overlooked. This iterative cycle of analyzing feature importance, selecting relevant features, generating new features through simulation, and updating the dataset continues until satisfactory results. Prediction results are considered satisfactory if one of the ML models demonstrates consistent superiority over the average-based approach in terms of accuracy and error reduction.

4.4 Results analysis

In results analysis, we analyze the input and output features generated from the simulation, discuss the results and improvements achieved through the learning process described previously, and

examine the residuals of the final predictions, along with the key features that had the greatest impact on model performance.

4.4.1 Analysis of the data generated by the simulation

Figure 4.5 shows the distribution of the backorder time (i.e., the output feature), which follows a naturally skewed distribution. For our case study, the average backorder time for delayed customer orders is approximately 3.15 hours. Most values are concentrated between 0 and 4.5 hours, and over 90% of the delayed customer orders are completed within 8 hours. Figure 4.5 shows that only 6% of the delayed customer orders are classified as outliers. These extreme values are expected in our case and represent critical or problematic situations for the DDMRP flow shop, such as system overloads. These overloads replicate real-world situations and are critical to accurately predicting backorder times. By including these extreme cases in the analysis, the prediction model can better capture the system's behavior under peak demand conditions and identify bottlenecks.




Figure 4.5: Distribution of the backorder time generated by simulation

The analysis of input features reveals that the Quantity On Order for machines M1 and M3 consists predominantly of zero values, suggesting a limited presence of meaningful data for these features.

Figure 4.6 presents the correlations between the different input features introduced in Table 4.5 and the predicted backorder time. This correlation matrix highlights medium to high correlations between DDMRP related features (NFP, Quantity On Order, Quantity On Hand and Quantity Backordered), reflecting a high degree of interdependence between them. Of all the input features, WIP, Quantity Backordered, and Lmax had the highest correlations with the predicted backorder time, with values of 0.65, 0.53, and 0.47 respectively. These results suggest that the WIP could be a potential predictor of backorder time, while the other two features could also play a significant role. This data analysis provides an initial understanding of the relationships between the considered features and their potential importance for modeling.

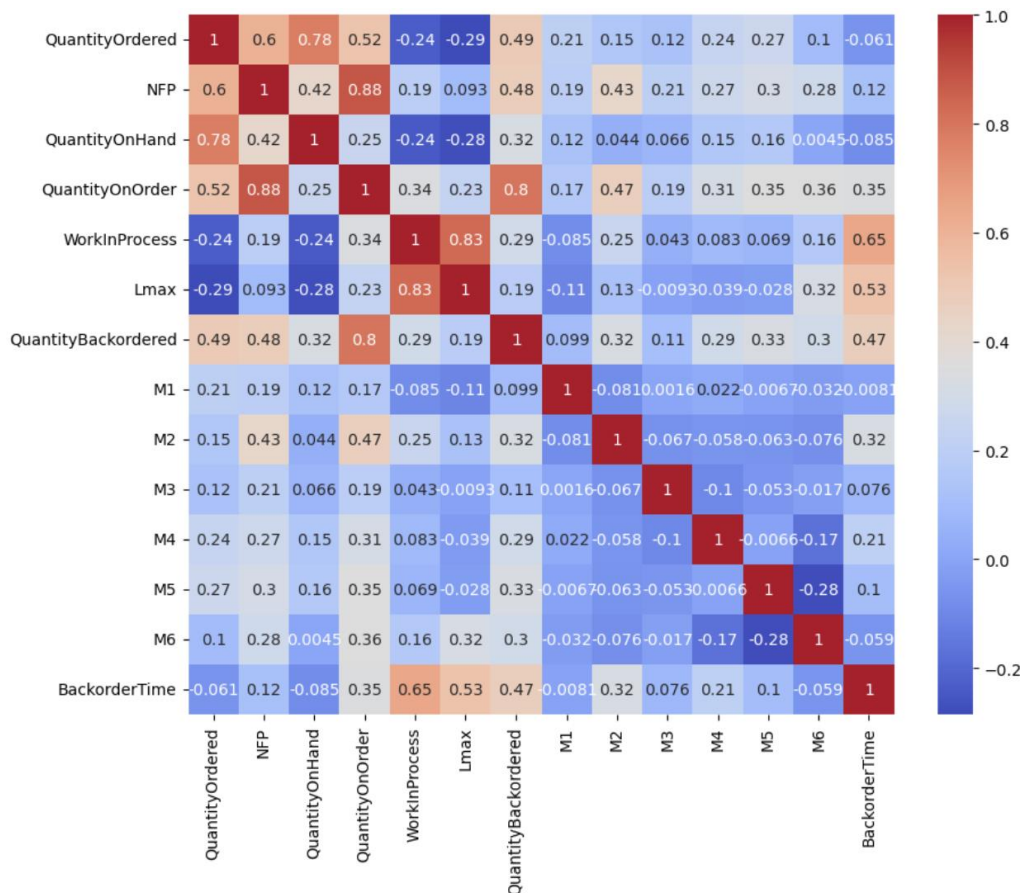


Figure 4.6: Correlation matrix

4.4.2 Comparison of the predictive performance of the different models

The predictive performance of the ML models is evaluated in two cases. In Case 1, we considered a limited set of input features as shown in Table 4.7. In Case 2, we expand the dataset by adding the Quantity Backordered and the Quantity On Order on the different machines (M_i , $i=1..6$). The predictive performance of each different ML model is shown in Table 4.8 for both Case 1 and Case 2 using three different metrics. It is important to note that all models show no signs of overfitting (see Appendix A).

Table 4.7: Feature selection between Case 1 and Case 2

Features	Case 1	Case 2
Product ID	X	X
Quantity Ordered	X	X
NFP	X	X
Quantity Backordered		X
Quantity On Hand	X	X
Quantity On Order	X	X
WIP	X	X
Lmax	X	X
M_i ($i=1..6$)		X

Table 4.8: Predictive performance of the different models

ML models	RMSE (h)		MAE (h)		R ²	
	Case 1	Case 2	Case 1	Case 2	Case 1	Case 2
Linear regression	2.24	2.02	1.60	1.46	0.55	0.63
RF	2.30	1.91	1.70	1.39	0.52	0.67
DT	2.28	1.77	1.63	1.23	0.53	0.72
XGBoost	2.14	1.61	1.54	1.14	0.59	0.77
SVM	2.14	1.71	1.51	1.21	0.59	0.73

ANN	2.15	1.64	1.53	1.18	0.58	0.75
------------	------	------	------	------	------	------

First, the comparison between Case 1 and Case 2 reveals that for all ML models, the inclusion of the additional features (Case 2) led to a significant improvement in the performance metrics. This can be seen in Table 4.8 since the RMSE and the MAE decrease and the R^2 value increases when we move from Case 1 to Case 2. This indicates that the added features (Quantity Backordered and the Quantity On Order on machine areas) provide valuable information that enhances the models' ability to predict the backorder time. The inclusion of these additional features likely captured important relationships and dynamics in the production system that were omitted in Case 1.

Second, we can see that the SVM model performs best (the lowest RMSE, the lowest MAE and the highest R^2) with a slight difference in Case 1, while XGBoost outperforms the other models in Case 2 (the lowest RMSE, the lowest MAE and the highest R^2). To evaluate the predictive performance of these models, we compare their performance metrics to those obtained with an average-based approach that uses the average backorder time as the prediction for all observations. Using the average backorder time in the test set (3.26 hours in our case) as the prediction, the RMSE is 3.35 hours and the MAE is 2.55 hours. Table 4.9 shows that the best models (i.e., SVM in Case 1 and XGBoost in Case 2) have significantly better predictive performance than considering the average backorder time. In addition, Table 4.9 indicates that with an extended dataset (Case 2 with additional features), we can significantly improve the predictive performance. This is evidenced by a reduction in RMSE and MAE by more than 50% and an increase in R^2 to 77% compared to the average-based approach. This highlights the importance of the feature selection step (see Figure 4.2 and Subsection 3.4) in improving predictive performance.

Table 4.9: Performance improvement of the best models compared to the average-based approach

	RMSE	MAE	R^2
SVM performance in Case 1	36.11%	40.78%	59%
XGBoost performance in Case 2	51.94%	55.29%	77%

In the following, we use XGBoost as the ML model. We conducted a residual analysis on the test data for the target feature and evaluated the feature importance of the selected features in Case 2.

4.4.3 Residual analysis

The objective of this subsection is to validate the performance of the XGBoost (i.e., the best ML model) with the extended dataset (Case 2) by analyzing the residuals. Residuals represent the difference between the actual values and the predicted values. Residual analysis is a method of assessing accuracy of the model and identifying potential patterns that indicate bias or model shortcomings [33]. To this end, we illustrate in Figure 4.7 the distribution of the residuals in order to determine whether the residuals follow a normal distribution, which is a key assumption in many regression models. The boxplot highlights the presence of outliers, while the histogram provides insight into the overall distribution shape.




Figure 4.7: Residual distribution

Figure 4.7 shows a good model fit, reinforcing the suitability of the XGBoost model. The residuals are primarily concentrated within a range of ± 2.5 h, confirming the effectiveness of the model in predicting unseen data and supporting the results obtained in the previous section. The histogram of Figure 4.7 shows a normal distribution (we confirmed it through a hypothesis test), indicating that the model handles prediction errors effectively across most data points. The presence of a few outliers in the boxplot suggests that some underlying relationships may still be unaccounted for by the model. This observation implies that, while the model performs well overall, there may be further opportunities for refinement to better capture these missing patterns.

4.4.4 Feature Importance

To assess the contribution of different features to backorder time prediction, we estimate feature importance using SHAP values. Figure 4.8 displays the feature importance rankings for all the features of Case 2, ordered from most to least significant. The analysis of the feature importance reveals that the WIP throughout the entire factory is the most significant predictor of the output variable. This feature reflects well the current state of the production flow, making it essential for accurate prediction. After WIP, the Quantity Ordered on machine M6 was identified as an informative feature, indicating that the number of units being processed on machine M6 is more crucial for determining backorder times than the Quantity Ordered on the machines earlier in the production process and the overall Quantity On Order. In addition, the Quantity Backordered emerged as another significant feature as it is directly correlated to on-time deliveries. Figure 4.8 shows also that the features Lmax (which represents the highest number of replenishment orders waiting to be processed at the machine bottleneck), the Net Flow Position (NFP), and the Quantity Ordered respectively on machine M2, M4 and M5 make a small contribution to backorder time prediction.

The importance of the features (Quantity on Hand, Quantity On Order, Quantity Ordered, Quantity Ordered on machines M3 and M1) in prediction is negligible. In particular, Quantity On order on M1 and M3 provides minimal valuable information for prediction, mainly due to a notable presence of zero values, which limits variability and reduces their contribution compared to other predictors. Our tests confirm that excluding these less influential features from the dataset did not negatively impact the model's performance.

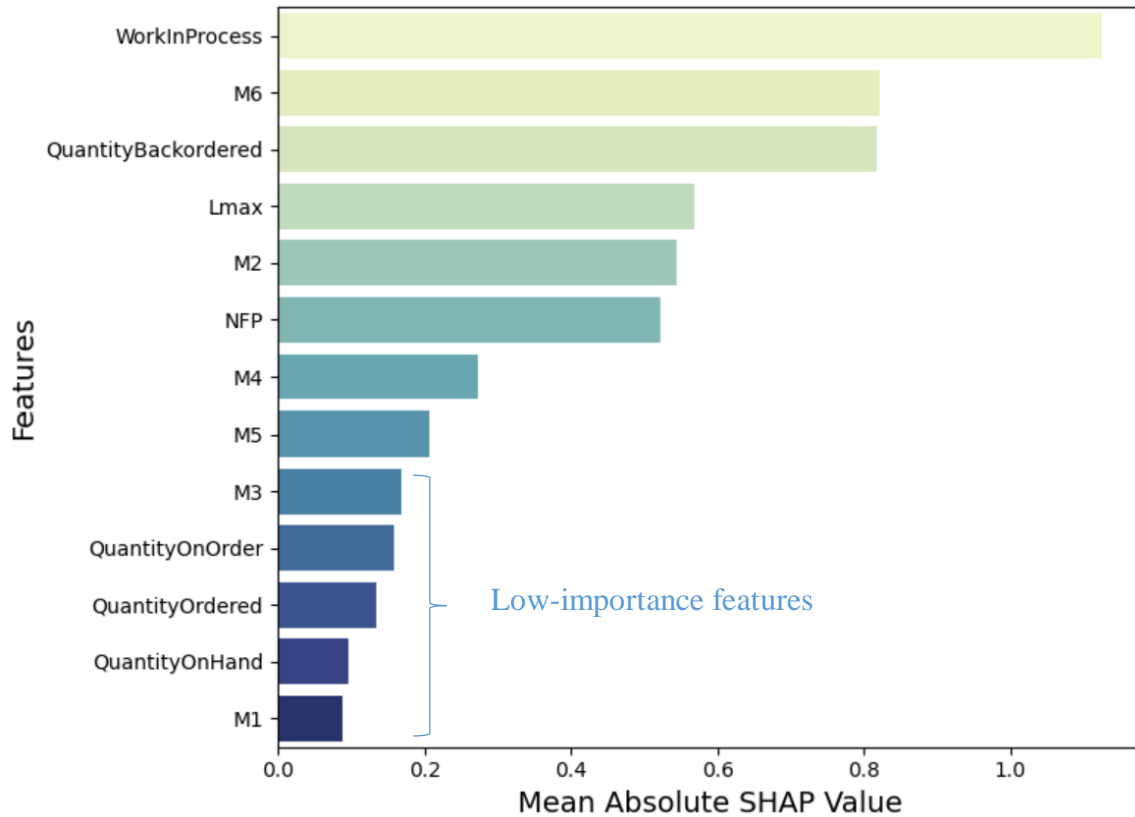


Figure 4.8: Feature importance

4.5 Discussion

Prediction models tested in this study exhibit enhanced performance when integrating the features which characterize the current production system load, which are WIP, Lmax and the Quantity Ordered on machine M6. These features provide crucial insights into when delayed customer orders are expected to be fulfilled, significantly improving the prediction of backorder times. Quantity Backordered when added demonstrates also its effectiveness in prediction and that's related to the context. Our analysis further demonstrates that removing the least important features (Quantity on Hand, Quantity On Order, Quantity Ordered, Quantity Ordered on machines M3 and M1) does not negatively impact model performance. This has been confirmed when the model achieved approximately the same accuracy without these features. This enables a more streamlined and focused approach to feature selection.

These results underscore that even within a DDMRP system, features that provide insight into the load on the production system (i.e., features from the third group presented in Table 4.5) are more critical than the NFP. While DDMRP aims to maintain the NFP within a desirable range (the Green

Zone), our study demonstrates that the NFP does not present a complete picture of when the next order will be fulfilled, the potential delays within the flow shop, or the volume of work pending completion. Although a favorable NFP may suggest better system functioning, it does not guarantee that operations are running smoothly or that customer orders are being delivered on time. Consequently, to predict backorder time in a DDMRP environment, metrics that accurately reflect the load on the production system is more relevant than vital for enhancing predictions and operational efficiency.

Among the features related to the DDMRP system (i.e., those from the second group in Table 4.5), only the Quantity Backordered has shown a significant contribution to backorder time prediction in a DDMRP system. This finding can be generalizable, as even through this feature is contextually linked to a DDMRP system, it can be used to predict backorder time within other replenishment systems as well. This suggests that the prediction approach proposed in this paper is not limited solely to DDMRP environments; it could be applied to other production systems and offer similar contribution in predicting order delays and backorder times, regardless of the replenishment methodology in place.

Furthermore, our results show that the features characterizing the product (i.e., Quantity Ordered, Quantity On Hand, and Quantity On order) are not important for predicting the backorder time and can therefore be removed from the input features list without affecting the prediction accuracy.

4.6 Conclusion

In this paper, we propose a learning-based approach to predict backorder times in DDMRP systems during peak demand periods. By combining simulation and regression models, our findings show that ML, particularly with XGBoost, can significantly improve the accuracy of backorder time predictions in DDMRP-managed systems.

The results highlight that production system load features, such as WIP, Lmax and Quantity On Order on some machines, contribute more effectively to predictive accuracy than product-related information alone. This insight emphasizes the value of incorporating real-time production metrics into DDMRP predicting, thereby expanding the traditional focus of DDMRP from inventory control to proactive delay management.

The learning-based approach proposed in this study provides practical applications for manufacturing firms seeking to minimize backorder times and improve delivery commitments. By

leveraging ML within a DDMRP framework, companies can better predict delays, anticipate stockouts, optimize replenishment cycles, and ultimately enhancing both operational efficiency and customer satisfaction. Ultimately, this study underscores the potential of ML to transform DDMRP into a more dynamic and predictive system, paving the way for improved decision-making and operational resilience in high-demand environments. Furthermore, the proposed learning-based approach is not limited to DDMRP and can be applied to other production systems.

While this study provides a strong foundation, limitations include the reliance on simulated data, which may not fully capture the complexities of real-world operations. Future research could benefit from testing the models in diverse manufacturing environments and refining the predictive features used. Additionally, expanding the model to integrate adaptive algorithms could enhance its responsiveness to peak demand conditions.

CHAPITRE 5

DISCUSSION GÉNÉRALE

5.1 Principales réalisations

La contribution de ce projet repose sur une approche innovante combinant la simulation et l'apprentissage automatique pour répondre aux objectifs. La simulation a été utilisée pour générer des données d'entraînement et de test, tandis que l'apprentissage automatique a permis de prédire les retards des ordres de réapprovisionnement dans une chaîne de production gérée par DDMRP, notamment dans un contexte de pics de demande où le système ne parvient pas à livrer les commandes à temps. Ces deux outils ont été intégrés dans une boucle itérative, permettant une amélioration continue des résultats et une validation progressive des variables pertinentes.

La méthodologie adoptée a d'abord impliqué un modèle initial basé sur une sélection de variables identifiées dans la revue de littérature. Cette première itération a montré une nette amélioration par rapport à une approche de référence basée sur la moyenne. Toutefois, une analyse approfondie de l'importance des variables a mis en évidence que certaines variables avaient une contribution significative à la prédiction des retards, tandis que d'autres étaient peu influentes. Dans un premier temps, la quantité de produits en souffrance s'est avérée essentielle dans ce contexte spécifique, suivi par des variables décrivant l'état du système, telles que les quantités de produits en cours sur les machines.

Sur cette base, des itérations supplémentaires ont été réalisées pour intégrer ces variables pertinentes. Cette nouvelle sélection de variables a permis d'obtenir des résultats significativement meilleurs avec la méthode XGBoost, aboutissant à une réduction de plus de moitié du RMSE et du MAE, et une augmentation du R^2 au-delà de 76 %, comparé à l'approche basée sur la moyenne.

L'analyse finale de l'importance des variables a révélé que les principaux contributeurs à la prédiction des retards étaient :

1. Le travail en cours sur l'ensemble de l'usine.
2. La quantité de produits en cours sur la dernière machine M6.
3. La quantité de produits en souffrance.

Ces variables ont chacune une moyenne absolue de SHAP value supérieur à 0.8, soulignant leur rôle clé dans la modélisation. En revanche, des variables liées au produit telles que la quantité commandée par le client, la quantité en stock et la quantité en cours de production, bien qu'importantes pour la gestion classique en DDMRP, se sont révélées peu utiles pour prédire les retards dans ce contexte (moins de 0.2). Leur suppression n'a eu aucun effet négatif sur les performances du modèle.

Les résultats obtenus soulignent que, même dans un système DDMRP, les variables reflétant la charge du système de production (telles que le WIP, Lmax et la quantité commandée sur la machine M6) sont plus critiques que la position de flux net (NFP) pour prédire les retards. Bien que DDMRP vise à maintenir le NFP dans une zone optimale (Green Zone), notre étude montre que cette métrique ne fournit pas une image complète du moment où la prochaine commande sera honorée, des potentiels délais dans l'atelier, ou du volume de travail restant. Un NFP favorable peut suggérer un bon fonctionnement du système, mais il ne garantit ni un flux optimal ni une ponctualité des livraisons. Ainsi, pour anticiper les retards dans un environnement DDMRP, il est essentiel de privilégier des indicateurs reflétant fidèlement la charge du système.

Par ailleurs, parmi les variables spécifiques au DDMRP, seule la quantité en souffrance s'est révélée significative dans la prédiction des délais. Cette constatation met en évidence le rôle central de cette variable dans la performance des systèmes tirés par la demande. Bien que la quantité en souffrance puisse exister dans d'autres contextes de réapprovisionnement (MTO, ETO, etc.), son rôle et sa dynamique sont fortement influencés par la logique DDMRP, notamment en raison de la gestion des stocks tampons, de la position des points de découplage, et des règles de priorisation des ordres. Par conséquent, si certains aspects du modèle développé ici peuvent théoriquement être transférés à d'autres systèmes de production, une telle application nécessiterait une adaptation spécifique aux règles de gestion propres à chaque environnement. L'approche proposée dans cette étude reste donc principalement conçue pour le contexte DDMRP, dans lequel elle a été testée, simulée et validée.

En résumé, ce projet met en évidence l'importance cruciale d'une sélection rigoureuse des variables dans la prédiction des retards, tout en exploitant la synergie entre la simulation et l'apprentissage

automatique. Cette approche a permis non seulement d'améliorer les résultats, mais aussi d'optimiser le modèle pour qu'il soit spécifiquement adapté aux défis du contexte étudié.

5.2 Implications managériales

Ce projet présente des implications managériales significatives pour les entreprises utilisant le DDMRP comme méthode de gestion des stocks et des flux de production. En intégrant l'apprentissage automatique dans ce cadre, il offre des outils puissants pour améliorer la prise de décision et optimiser les performances opérationnelles.

5.2.1. Anticipation des retards et réduction des impacts

Grâce à la prédiction des retards des ordres de réapprovisionnement, les managers peuvent anticiper les dysfonctionnements dans le système, notamment lors de pics de demande. Cela leur permet de mettre en place des mesures correctives rapidement, telles que la réallocation des ressources ou la modification des priorités de production, afin de minimiser les retards et leurs impacts sur les délais de livraison.

5.2.2. Amélioration de la satisfaction des clients

En fournissant des estimations précises des délais, les entreprises peuvent mieux communiquer avec leurs clients sur les livraisons, réduisant ainsi l'incertitude et augmentant leur satisfaction. Cette transparence contribue à renforcer la confiance et la fidélité des clients, même en cas de perturbations.

5.2.3. Réduction des coûts opérationnels

L'approche combinant simulation et apprentissage automatique permet d'optimiser les processus sans nécessiter les investissements coûteux associés à des solutions comme les jumeaux numériques. Les managers peuvent ainsi améliorer les performances du système tout en maîtrisant les coûts technologiques et opérationnels.

5.3 Contributions du projet

Ce projet apporte une contribution significative à l'approche DDMRP en intégrant l'apprentissage automatique, une approche encore peu explorée dans ce contexte. Le DDMRP est traditionnellement reconnu pour son efficacité dans la gestion des stocks et l'ajustement des flux en fonction de la demande. Cependant, ce travail propose une avancée théorique en exploitant la

puissance de l'apprentissage automatique pour résoudre des problématiques spécifiques, comme la prédiction des retards dans l'exécution des ordres de réapprovisionnement, un aspect rarement abordé dans la littérature consacrée au DDMRP, mais qui se révèle crucial dans des scénarios de pics de demande. En étudiant ce contexte particulier, le projet met en lumière des variables critiques qui se révèlent déterminantes pour obtenir des prédictions précises. Ces résultats enrichissent les connaissances actuelles sur la gestion des systèmes DDMRP en démontrant comment l'apprentissage automatique peut compléter et améliorer les mécanismes classiques de ce cadre.

De plus, cette approche offre une alternative économique pertinente à l'utilisation des jumeaux numériques, souvent perçus comme une solution idéale pour résoudre ce type de problème. Si les jumeaux numériques fournissent une représentation virtuelle précise des systèmes physiques, leur mise en œuvre implique toutefois des coûts élevés, des infrastructures technologiques complexes et une grande quantité d'informations détaillées. En combinant la simulation et l'apprentissage automatique, ce projet propose une méthode plus accessible, capable de fournir des résultats fiables et exploitables sans nécessiter les investissements massifs associés aux jumeaux numériques.

En conclusion, ce projet propose une nouvelle approche théorique pour intégrer l'apprentissage automatique dans les systèmes DDMRP. En exploitant cette synergie, il devient possible d'anticiper plus efficacement les ruptures de stock et d'optimiser les cycles de réapprovisionnement.

CHAPITRE 6

CONCLUSION

6.1 Synthèse des travaux

Ce projet a réussi à intégrer efficacement l'apprentissage automatique dans le cadre de la méthode de gestion DDMRP pour prédire les retards des ordres de réapprovisionnement causés par les pics de demande. Le cas d'étude s'appuie sur un modèle de simulation inspiré des travaux de Alves., et al. [22], reproduisant une chaîne de production étudiée dans la littérature. En s'appuyant sur les connaissances issues de la littérature, des variables pertinentes ont été identifiées, et des scénarios spécifiques, reflétant la problématique des pics de demande, a été sélectionné. La simulation a ensuite été utilisée pour générer les données nécessaires : un ensemble d'entraînement pour développer les modèles d'apprentissage automatique et un ensemble de test pour évaluer leurs performances. Grâce à une analyse rigoureuse des résultats, une nouvelle sélection de variables a été menée pour améliorer les prédictions. Ces derniers ont permis de confirmer que l'apprentissage automatique constitue une méthode fiable pour prédire les retards. Les variables clés identifiées comme ayant un impact significatif sur les performances des modèles étaient principalement liées à l'état du système, telles que le travail en cours et les quantités de produits en souffrance, plutôt qu'à des caractéristiques directement liées aux commandes clients. Parmi les modèles d'apprentissage testés, XGBoost a montré des performances supérieures, pour prédire les retards. Une analyse approfondie de l'importance des variables avec SHAP value a permis de concentrer les efforts sur les variables clés, contribuant à renforcer la précision et la robustesse des modèles. En conclusion, ce projet démontre que la combinaison de l'apprentissage automatique et la simulation dans système géré par DDMRP offrent une solution robuste et efficace pour gérer les défis liés aux pics de demande et optimiser les processus de réapprovisionnement.

6.2 Limitations de la solution proposée

La solution proposée repose principalement sur des données de simulation, ce qui constitue une limitation importante lorsqu'elle est transposée à un environnement réel. En pratique, la collecte de données est souvent complexe, marquée par des lacunes, des incohérences ou un accès limité aux informations en temps réel. De plus, les systèmes réels présentent une variabilité et des

imprévus bien plus complexes que ceux modélisés en simulation, comme les pannes, les erreurs humaines ou les contraintes opérationnelles spécifiques. Par conséquent, les modèles développés pourraient nécessiter un recalibrage significatif pour être adaptés aux particularités des systèmes physiques et garantir leur efficacité dans des conditions réelles.

6.3 Améliorations futures

L'objectif principal de ce projet est de prédire les retards des ordres de réapprovisionnement afin de les communiquer aux clients, ce qui permet de réduire leur insatisfaction et d'éviter les pertes de revenus. Cependant, la méthode proposée se limite à la prédiction et n'intègre pas de solutions pour optimiser les revenus ou gérer les priorités de manière proactive. Pour améliorer cette approche, des recherches futures pourraient explorer l'intégration de mécanismes d'optimisation qui, en plus de prédire les retards, permettraient de prioriser les commandes en fonction de leur importance stratégique ou de leur impact financier. Par exemple, des modèles combinant apprentissage automatique et optimisation stochastique pourraient être utilisés pour non seulement anticiper les retards, mais aussi proposer des ajustements dans les flux de production ou les ordres de réapprovisionnement, maximisant ainsi la rentabilité globale tout en améliorant la satisfaction client. Ces améliorations renforceraient la valeur pratique et stratégique de la solution dans des environnements réels et compétitifs.

RÉFÉRENCES

- [1] G. Dessevre and M. Benali, "Analysis of a new dynamic capacity management approach in DDMRP: Application on a real industrial case," *Journal of Industrial Engineering and Management (JIEM)*, vol. 17(2), pp. 445-462, 2024.
- [2] N. Jyeniskhan, A. Keutayeva, G. Kazbek, M. H. Ali, and E. Shehab, "Integrating Machine Learning Model and Digital Twin System for Additive Manufacturing," (in English), *Ieee Access*, vol. 11, pp. 71113-71126, 2023.
- [3] C. Ptak and C. Smith, *Orlicky's Material Requirements Planning 3/E*. 2011.
- [4] G. Dessevre, "Contrôle du paramètre Decoupled Lead Time (DLT) et des temps de réponse dans un système piloté en DDMRP," Phd, Industrial Engineering, Polytechnique Montréal, 2021.
- [5] M. El Marzougui, N. Messaoudi, W. Dachry, H. Sarir, and B. Bensassi, "Demand driven MRP: Literature review and research issues," presented at the 13ème conference internationale de modelisation, optimisation et simulation (mosim2020), Agadir, Maroc, 2020.
- [6] C. A. Ptak and C. Smith, *Demand driven material requirements planning (DDMRP)*, 2. ed. South Norwalk, Connecticut: Industrial Press, Inc., 2018, pp. xxii, 343 pages.
- [7] Ptak and Smith, *Demand Driven Material Requirements Planning (DDMRP)*. 2016.
- [8] D. Damand, Y. Lahrichi, and M. Barth, "Parameterisation of demand-driven material requirements planning: a multi-objective genetic algorithm," (in English), *Int J Prod Res*, vol. 61, no. 15, pp. 5134-5155, Aug 3 2023.
- [9] O. López-Ortega, V. López-Morales, and I. Villar-Medina, "Intelligent and collaborative Multi-Agent System to generate and schedule production orders," (in English), *J Intell Manuf*, vol. 19, no. 6, pp. 677-687, Dec 2008.
- [10] Y. C. Wang and J. M. Usher, "A reinforcement learning approach for developing routing policies in multi-agent production scheduling," (in English), *Int J Adv Manuf Tech*, vol. 33, no. 3-4, pp. 323-333, 2007.
- [11] C. L. Han and Q. Zhang, "Optimization of supply chain efficiency management based on machine learning and neural network," (in English), *Neural Comput Appl*, vol. 33, no. 5, pp. 1419-1433, Mar 2021.
- [12] B. Abbasi, T. Babaei, Z. Hosseinifard, K. Smith-Miles, and M. Dehghani, "Predicting solutions of large-scale optimization problems via machine learning: A case study in blood supply chain management," (in English), *Comput Oper Res*, vol. 119, Jul 2020.
- [13] P. Priore, B. Ponte, R. Rosillo, and D. de la Fuente, "Applying machine learning to the dynamic selection of replenishment policies in fast-changing supply chain environments," (in English), *Int J Prod Res*, vol. 57, no. 11, pp. 3663-3677, Jun 3 2019.

- [14] L. Ren, X. Y. Fan, J. Cui, Z. Shen, Y. S. Lv, and G. Xiong, "A Multi-Agent Reinforcement Learning Method With Route Recorders for Vehicle Routing in Supply Chain Management," (in English), *Ieee T Intell Transp*, vol. 23, no. 9, pp. 16410-16420, Sep 2022.
- [15] S. Kumar and S. C. Sharma, "Integrated Model for Predicting Supply Chain Risk Through Machine Learning Algorithms," (in English), *Int J Math Eng Manag*, vol. 8, no. 3, pp. 353-373, Jun 2023, doi: 10.33889/Ijmems.2023.8.3.021.
- [16] A. Alenezi, S. A. Moses, and T. B. Trafalis, "Real-time prediction of order flowtimes using support vector regression," (in English), *Comput Oper Res*, vol. 35, no. 11, pp. 3489-3503, Nov 2008.
- [17] M. Schneckenreither, S. Windmueller, and S. Haeussler, "Smart Short Term Capacity Planning: A Reinforcement Learning Approach," (in English), *Ifip Adv Inf Comm Te*, vol. 630, pp. 258-266, 2021.
- [18] P. Burggräf, J. Wagner, B. Heinbach, and F. Steinberg, "Machine Learning-Based Prediction of Missing Components for Assembly - a Case Study at an Engineer-to-Order Manufacturer," (in English), *Ieee Access*, vol. 9, pp. 105926-105938, 2021.
- [19] A. Rokoss, M. Syberg, L. Tomidei, C. Huelsing, J. Deuse, and M. Schmidt, "Case study on delivery time determination using a machine learning approach in small batch production companies," (in English), *J Intell Manuf*, Jan 12 2024.
- [20] D. H. Yang, L. Hu, and Y. Qian, "Due Date Assignment in a Dynamic Job Shop with the Orthogonal Kernel Least Squares Algorithm," (in English), *Iop Conf Ser-Mat Sci*, vol. 212, 2017.
- [21] George E. P. Box, Gwilym M. Jenkins, Gregory C. Reinsel, and G. M. Ljung, *Time Series Analysis: Forecasting and Control, 5th Edition*. 2015, p. 720.
- [22] L. Alves., M. Benali., and P. Baptiste., "Dynamic Dispatching of DDMRP Replenishment Orders," presented at the 43rd IFIP WG 5.7 International Conference on Advances in Production Management Systems (APMS 2024), Chemnitz, Germany, 2024.
- [23] G. Dessevre, G. Martin, P. Baptiste, J. Lamothe, R. Pellerin, and M. Lauras, "Decoupled Lead Time in finite capacity flowshop: a feedback loop approach," (in English), *Proceedings of the 2019 International Conference on Industrial Engineering and Systems Management (Iesm 2019)*, pp. 136-141, 2019.
- [24] A. Kortabarria, U. Apaolaza, A. Lizarralde, and I. Amorrortu, "Material Management without Forecasting: From MRP to Demand Driven MRP," *Journal of Industrial Engineering and Management (JIEM)*, vol. 11, no. 4, OmniaScience, Barcelona, pp. 632-650, 2018.
- [25] L. Duhem, M. Benali, and G. Martin, "Parametrization of a demand-driven operating model using reinforcement learning," (in English), *Comput Ind*, vol. 147, May 2023.
- [26] A. Ali, R. Jayaraman, E. Azar, and M. Maalouf, "Maximizing supply chain performance leveraging machine learning to anticipate customer backorders," (in English), *Comput Ind Eng*, vol. 194, Aug 2024.

- [27] C. Ntakolia, C. Kokkotis, P. Karlsson, and S. Moustakidis, "An Explainable Machine Learning Model for Material Backorder Prediction in Inventory Management," (in English), *Sensors-Basel*, vol. 21, no. 23, Dec 2021.
- [28] S. Islam and S. H. Amin, "Prediction of probable backorder scenarios in the supply chain using Distributed Random Forest and Gradient Boosting Machine learning techniques," (in English), *J Big Data-Ger*, vol. 7, no. 1, Dec 26 2020.
- [29] J. A. Rodger, "Application of a Fuzzy Feasibility Bayesian Probabilistic Estimation of supply chain backorder aging, unfilled backorders, and customer wait time using stochastic simulation with Markov blankets," (in English), *Expert Syst Appl*, vol. 41, no. 16, pp. 7005-7022, Nov 15 2014.
- [30] C. Maklin, "K-Fold Cross Validation Example Using Sklearn," ed, 2019.
- [31] C. Molnar, *Interpretable Machine Learning: A Guide for Making Black Box Models Explainable*. 2020.
- [32] S. M. Lundberg and S. I. Lee, "A Unified Approach to Interpreting Model Predictions," (in English), *Adv Neur In*, vol. 30, 2017.
- [33] G. James, D. Witten, T. Hastie, and R. Tibshirani, "An Introduction to Statistical Learning with Applications in R Introduction," (in English), *Springer Texts Stat*, vol. 103, pp. 1-14, 2013.

ANNEXE A Performance des modèles d'apprentissage pour les cas 1 et 2 sur les données d'entraînement et de test




Figure A.1: Performances du modèle d'apprentissage pour le cas 1




Figure A.2: Performances du modèle d'apprentissage pour le cas 2