

République Algérienne Démocratique et Populaire  
Université Abderrahmane MIRA de Béjaia  
Faculté des Sciences Exactes

Département de Recherche Opérationnelle



## MÉMOIRE DE FIN D'ÉTUDES

Présenté en vue de l'obtention du diplôme de Master  
Spécialité : Optimisation et Fiabilité des Réseaux de Communication

*Prévision intelligente des stocks à l'entreprise SONATRACH :  
Application aux articles d'instrumentation*

Présenté par :

AICHOUB Siham  
AMIALI Aminis

Sous la direction de : Pr. AÏSSANI Djamil  
Et de : Dr. OUTAMAZIRT Assia

Défendu le 29/06/2025, devant le jury composé de :

M <sup>r</sup> KHIMOUM Nordine	M.C.A	Président de jury	UAMB - Bejaia.
M <sup>r</sup> SAHLI Ramzi	Doctorant	Examineur	UAMB - Bejaia
M <sup>me</sup> AOUDIA Zohra	M.A.A	Examinatrice	UAMB - Bejaia.
M <sup>r</sup> ELSAKAAN Nadim	Doctorant	Examineur	UAMB - Bejaia.

Année Universitaire 2024 – 2025

# Remerciements

*Nous tenons à exprimer notre profonde gratitude à*

**MONSIEUR DJAMIL AÏSSANI,**

*pour sa disponibilité, ses conseils avisés et ses remarques constructives qui ont largement contribué à l'élaboration de ce mémoire. Son encadrement rigoureux a été un véritable moteur de progression.*

*Nous remercions également chaleureusement*

**MONSIEUR SAHLI RAMZI,**

*pour son soutien précieux et l'intérêt sincère qu'il a manifesté envers notre projet. Ses orientations ont été déterminantes.*

*Nos remerciements vont aussi à*

**MONSIEUR ASLI,** *chef du Département de Recherche Opérationnelle,*

*pour son accompagnement bienveillant et sa confiance.*

*Nous adressons nos sincères remerciements aux membres du jury pour le temps qu'ils nous ont consacré et leurs remarques enrichissantes.*

*Nous exprimons notre reconnaissance à*

**MESSIEURS AZIB SAMIR ET SALMI NASSIM** *de SONATRACH,*

*pour leur encadrement sur le terrain et leur professionnalisme.*

*Nous remercions l'ensemble du personnel de SONATRACH pour leur accueil, ainsi que les professeurs du Département de Recherche Opérationnelle.*

*Nos remerciements vont enfin à nos familles et camarades pour leur soutien indéfectible.*

# Dédicace

À toi, papa **AMIALI Mohand Arezki**,  
pilier silencieux, force tranquille,  
dont les sacrifices ont bâti mes rêves  
et dont la force et la sagesse m'inspirent chaque jour.

À toi, maman **BOUAIFEL Samia**,  
étoile bienveillante de ma vie,  
dont l'amour infini a éclairé tous mes chemins.

À mes petits trésors :  
**Imane**, la brillante future médecin,  
**Zinedine**, le rayon de soleil de notre foyer,  
et **Céline**, ma belle et tendre petite sœur,  
douceur incarnée, sourire qui apaise.

À ma famille et à mes amis,  
pour chaque mot d'encouragement,  
chaque geste d'affection,  
chaque silence rempli de soutien...

Et à ma binôme **AICHOIR Siham**,  
pour sa présence, son engagement et sa belle complicité  
tout au long de cette aventure.

Ce mémoire est le fruit de votre présence,  
et le reflet de tout ce que vous êtes pour moi.

*Amiali Aminis*

---

*Dédicace*

---

*À mon père, EL HADI,  
pour m'avoir enseigné la persévérance*

*À ma mère, SAÏDA,  
pour son amour inconditionnel*

*À mes frères, YACINE et SOFIANE,  
pour leur soutien indéfectible*

*À mon amie, DJIDA,  
pour son amitié et son soutien*

*À ma binôme, AMINIS,  
pour sa précieuse collaboration*

---

*Que ces mots, bien qu'insuffisants,  
traduisent ma profonde gratitude.*

SIHAM AICHOUR

# Table des matières

<b>Remerciements</b>	<b>I</b>
Liste des figures	VII
Liste d'abréviations et notations	VIII
<b>Introduction générale</b>	<b>1</b>
<b>1 Contexte Organisationnel et Logistique de SONATRACH</b>	<b>3</b>
Introduction	3
1.1 Présentation de l'organisme d'accueil SONATRACH	3
1.2 La Région Transport Centre Béjaïa (RTC)	6
1.3 Patrimoine de la Région Transport Centre (RTC-Béjaïa)	6
1.4 Organisation structurelle et fonctionnelle de la RTC-Béjaïa	9
1.5 Le système de gestion intégré utilisé : SAP	13
1.6 Position du problème	14
Conclusion	14
<b>2 Fondements théoriques de la gestion des stocks et de l'intelligence artificielle</b>	<b>16</b>
Introduction	16
Partie 1 : Notions théoriques de la gestion des stocks	16
2.1 Les Stocks	16
2.2 La Gestion des Stocks	19
2.3 Classification des articles stockés	28
Partie 2 : Notions théoriques de l'intelligence artificielle	32
2.4 L'intelligence Artificielle	32
2.5 Le Machine Learning	33
2.6 Les principales méthodes utilisées pour la prévision de la demande	39
Conclusion	42
<b>3 Analyse critique des approches de prévision et de la gestion des stocks</b>	<b>43</b>
Introduction	43
3.1 Méthodes traditionnelles de gestion des stocks	43
3.2 Apport de l'IA dans la gestion des stocks	47
3.3 Gestion des stocks de sécurité	49

---

3.4	Méthodes intégrées de gestion des stocks : revue de la littérature . . . . .	53
3.5	Limites des approches fondées sur les données . . . . .	54
	Conclusion . . . . .	55
<b>4</b>	<b>Approche hybride de prévision de la demande et d'optimisation des stocks chez SONATRACH</b>	<b>56</b>
	Introduction . . . . .	56
4.1	Collecte et préparation des données . . . . .	56
4.2	Prédiction de la demande . . . . .	61
4.3	Adaptation des modèles de gestion des stocks . . . . .	62
4.4	Validation et optimisation . . . . .	64
4.5	Décision optimale de la politique de réapprovisionnement . . . . .	65
	Conclusion . . . . .	66
<b>5</b>	<b>Analyse et interprétation des résultats</b>	<b>67</b>
	Introduction . . . . .	67
5.1	Analyse comparative des modèles de prévision . . . . .	67
5.2	Analyse des recommandations de politiques de gestion des stocks . . . . .	79
5.3	Validation et Optimisation . . . . .	80
	Conclusion . . . . .	80
	<b>Conclusion générale</b>	<b>81</b>
	<b>Bibliographie</b>	<b>87</b>
	<b>Annexes</b>	<b>88</b>
	<b>Résumé</b>	<b>98</b>

# Table des figures

1.1	Organigramme de la SONATRACH . . . . .	4
1.2	Activités de la SONATRACH . . . . .	5
1.3	Description des ouvrages de RTC . . . . .	7
1.4	Organigramme de la RTC-Bejaia . . . . .	9
1.5	Organigramme de l'ATR [68] . . . . .	11
1.6	Schéma des principaux modules SAP[38] . . . . .	14
2.1	Gestion des stocks . . . . .	17
2.2	Environnement de la fonction stock [42]. . . . .	17
2.3	Réapprovisionnement à Date fixes et Quantité fixes. . . . .	21
2.4	Réapprovisionnement à Date fixes et Quantité variables. . . . .	21
2.5	Réapprovisionnement à Date variable et Quantité fixe. . . . .	22
2.6	Réapprovisionnement à Date Variable et Quantité variables. . . . .	22
2.7	Modèle de Wilson . . . . .	23
2.8	Evolution du stock avec la politique (Q,r)[17] . . . . .	24
2.9	Evolution du stock avec la politique (R,T)[17] . . . . .	27
2.10	Courbe de classification des articles par la methode ABC. . . . .	28
2.11	Exemple de produits XYZ [68] . . . . .	30
2.12	Illustration du principe de classification ABC-XYZ . . . . .	32
2.13	Structure hiérarchique de l'intelligence artificielle[44] . . . . .	32
2.14	Les applications de machine learning[32]. . . . .	33
2.15	Apprentissage non supervisé sans données étiquetées . . . . .	35
2.16	Apprentissage semi supervisé à partir des ensembles rouges, jaunes et verts . . . . .	36
2.17	Apprentissage par renforcement, test de sortie de labyrinthe . . . . .	36
2.18	Apprentissage supervisé à partir d'ensemble prédéfinis (rouge, vert, jaune) . . . . .	36
2.19	Principaux types d'apprentissage . . . . .	37
2.20	Modèles de régression linéaire [56] . . . . .	38
2.21	modèle de classification linéaire [34] . . . . .	38
2.22	Vote majoritaire des arbres de décisions pour le Random Forest . . . . .	40
3.1	Arbre méthodologique pour les prévisions [67] . . . . .	44
3.2	Score z pour un niveau de service de 70-100% . . . . .	53
4.1	Extrait du fichier Excel de gestion des articles – SONATRACH . . . . .	57

---

4.2	Ensemble des données simulées . . . . .	60
4.3	Chaîne décisionnelle de gestion intelligente des stocks . . . . .	66
5.1	Comparaison du MAE moyen par méthode et par classe ABC . . . . .	70
5.2	Comparaison du RMSE moyen par méthode et par classe ABC . . . . .	72
5.3	Comparaison du coefficient de détermination moyen ( $R^2$ ) par méthode et par classe ABC . . . . .	73
5.4	Erreur absolue moyenne (MAE) des modèles par classe XYZ . . . . .	75
5.5	Erreur quadratique moyenne (RMSE) des modèles par classe XYZ . . . . .	76
5.6	Comparaison du coefficient de détermination $R^2$ par classe XYZ et par méthode . . . . .	77

## Liste d'abréviations et notations

Abréviation	Signification
<b>SONATRACH</b>	Société Nationale pour la Recherche, la Production, le Transport, la Transformation, et la Commercialisation des Hydrocarbures
<b>DRGB</b>	Direction Régionale Béjaïa
<b>RTC</b>	Région Transport Centre
<b>SAP</b>	<i>Systeme, Anwendungen und Produkte</i> – Systèmes, Applications et Produits pour le traitement des données
<b>ERP</b>	<i>Enterprise Resource Planning</i> – Planification des ressources de l'entreprise
<b>IFR</b>	Increasing Failure Rate (Taux de défaillance croissant)
<b>DFR</b>	Decreasing Failure Rate (Taux de défaillance décroissant)
<b>MAE</b>	Erreur absolue moyenne
<b>RMSE</b>	Racine de l'erreur quadratique moyenne
<b>(Q,r)</b>	Politique de commande fixe avec point de réapprovisionnement
<b>(R,T)</b>	Révision périodique avec quantité variable
<b>ABC</b>	Classification selon la valeur annuelle consommée
<b>XYZ</b>	Classification selon la variabilité de la demande
<b>RF</b>	Forêt aléatoire (Random Forest)
<b>IA</b>	Intelligence Artificielle
<b>ML</b>	Machine Learning (Apprentissage automatique)
<b>RL</b>	Régression Linéaire
<b>(s,Q)</b>	Politique avec quantité économique et point de commande variable
<b>EOQ</b>	Quantité Économique de Commande (Economic Order Quantity)
<b>SRM</b>	Gestion de la relation fournisseur (Supplier Relationship Management)
<b>VMI</b>	Inventaire géré par le fournisseur (Vendor Managed Inventory)
<b>GARCH</b>	Generalized Autoregressive Conditional Heteroskedasticity
<b>KDE</b>	Kernel Density Estimation
<b>RL/DRL</b>	Reinforcement Learning / Deep Reinforcement Learning

<b>Abréviation</b>	<b>Signification</b>
<b>MM</b>	Moyenne Mobile
<b>TALN</b>	Traitement Automatique du Langage Naturel
<b>WMA</b>	Weighted Moving Average (Moyenne mobile pondérée)
<b>EMA</b>	Exponential Moving Average (Moyenne mobile exponentielle)
<b>ANN</b>	Artificial Neural Network (Réseaux de neurones artificiels)
<b>LSTM</b>	Long Short-Term Memory
<b>IoT</b>	Internet of Things (Internet des objets)
<b>SVR</b>	Support Vector Regression
<b>MLP</b>	Multi-Layer Perceptron
<b>RNN</b>	Recurrent Neural Network
<b>ARIMA</b>	AutoRegressive Integrated Moving Average
<b>SS</b>	Stock de Sécurité
<b>AHP</b>	Analytic Hierarchy Process
<b>XGBoost</b>	eXtreme Gradient Boosting

# Introduction générale

La gestion des stocks constitue un enjeu crucial pour les entreprises industrielles, notamment dans le secteur pétrolier où la disponibilité des pièces critiques conditionne le bon fonctionnement des installations. Chez **SONATRACH**, les défis liés à la diversité des articles, à la variabilité de la demande et aux contraintes opérationnelles exigent des politiques d'approvisionnement à la fois flexibles, robustes et efficaces, capables de garantir un niveau de service élevé tout en maîtrisant les coûts logistiques.

Plusieurs études ont été menées sur cette problématique. Oudina et Bentoumi [54] ont appliqué l'analyse ABC et le modèle EOQ dans une entreprise de production sous contraintes (ALFAPIPE-Ghardia). Deboub et Djir [26] ont développé une application informatique pour optimiser la gestion des centres de stockage pétroliers de NAFTAL. Tighilt et Younsioui [68] ont testé les modèles classiques  $(Q, r)$  et  $(R, T)$ , associés à des prévisions de type Holt-Winters et Box-Jenkins, pour la gestion des pièces critiques dans les stations de pompage OB1. D'autres travaux, comme ceux d'Anabi et Benali [10], ont mis en œuvre une classification ABC et des prévisions Holt-Winters pour gérer les pièces de rechange (pompes Guinard) chez SONATRACH Béjaïa. La thèse de Aiane [8] a analysé la stabilité des systèmes périodiques  $(R, s, lnQ)$ , tandis que Bazizi [15] a proposé une modélisation à l'aide de Réseaux de Petri stochastiques. Enfin, Mekhnache [49] a exploré l'intérêt de l'intelligence artificielle dans le dimensionnement des stocks de sécurité sans mise en œuvre concrète.

Dans cette continuité, notre travail se distingue par l'intégration effective de l'intelligence artificielle, en particulier des modèles Random Forest et de Régression Linéaire, pour améliorer la prévision de la demande. Ces prévisions sont ensuite exploitées dans les modèles classiques de gestion des stocks  $(Q, r)$  et  $(R, T)$ , dans une logique d'optimisation dynamique tenant compte des réalités du terrain chez SONATRACH. L'objectif est de mieux anticiper les besoins, de réduire les ruptures critiques et d'optimiser les coûts logistiques.

Actuellement, la gestion des articles d'instrumentation repose encore largement sur des méthodes traditionnelles, efficaces mais parfois inadéquates à la complexité des consommations réelles. Le manque de données historiques fiables et la forte irrégularité de certaines demandes rendent difficile l'application de règles fixes. Cela se traduit par des excès de stock pour certains articles, des ruptures fréquentes pour d'autres, et des coûts globalement sous-optimisés. Dans ce contexte, les apports de l'IA, notamment en termes de capacité d'anticipation et d'adaptabilité, deviennent stratégiques.

Dès lors, la question centrale à laquelle ce travail tente de répondre est la suivante :

*Comment améliorer la gestion des articles d'instrumentation chez SONATRACH en intégrant des techniques d'intelligence artificielle pour une prévision plus fiable de la demande et une optimisation dynamique des modèles classiques de réapprovisionnement ?*

Pour y répondre, une **approche hybride** est développée, combinant :

- une classification ABC-XYZ pour regrouper les articles selon leur criticité et la régularité de leur consommation ;
- des modèles prédictifs basés sur l'IA (Régression Linéaire, Random Forest) et un modèle de référence (Moyenne Mobile) pour anticiper la demande ;
- l'optimisation des paramètres de réapprovisionnement selon les modèles  $(Q, r)$  et  $(R, T)$ , en tenant compte des prévisions obtenues ;
- une évaluation multicritère selon des indicateurs tels que : MAE, RMSE, coût total, taux de rupture, niveau de service, etc.

Le mémoire est structuré comme suit :

- **Chapitre 1** : Présentation du contexte organisationnel et logistique de SONATRACH, avec un focus sur la Région Transport Centre (RTC-Béjaïa) et le système SAP utilisé ;
- **Chapitre 2** : Rappels théoriques sur la gestion des stocks et les concepts de l'intelligence artificielle appliqués à la prévision ;
- **Chapitre 3** : Revue des approches traditionnelles et intelligentes de gestion des stocks, ainsi que des techniques de prévision et de calcul du stock de sécurité ;
- **Chapitre 4** : Démarche méthodologique adoptée : simulation de données, classification, prévisions, calculs de paramètres et mise en œuvre des modèles ;
- **Chapitre 5** : Analyse et discussion des résultats obtenus selon les classes ABC-XYZ, comparaison des performances des politiques de gestion étudiées, et formulation de recommandations.

Cette étude vise à démontrer qu'une intégration intelligente de l'IA dans les systèmes de gestion des stocks permet non seulement de gagner en précision et en réactivité, mais aussi d'assurer un pilotage plus efficient des ressources, en adéquation avec les exigences de performance de SONATRACH.

# 1

## Contexte Organisationnel et Logistique de SONATRACH

### Introduction

Dans un contexte économique concurrentiel, la gestion efficace des stocks est essentielle pour assurer la rentabilité et la continuité des activités, notamment dans le secteur des hydrocarbures. Ce premier chapitre présente **SONATRACH**, en soulignant son rôle stratégique en Algérie, avec un focus sur la **Direction Régionale de Béjaïa** et son **département Transport et Approvisionnement**.

### 1.1 Présentation de l'organisme d'accueil SONATRACH

Société Nationale pour la Recherche, la Production, le Transport, la Transformation et la Commercialisation des Hydrocarbures. Elle intervient également dans d'autres secteurs tels que la génération électrique, les énergies nouvelles et renouvelables et le dessalement d'eau de mer [29]. C'est une compagnie nationale algérienne d'envergure internationale. Sa mission est de valoriser de façon optimale les ressources nationales d'hydrocarbures et de créer des richesses au service du développement économique et social du pays [28].

SONATRACH est un acteur majeur dans le domaine du pétrole et du gaz. Ce qui la place, aujourd'hui, première compagnie d'hydrocarbures en Afrique et en Méditerranée.

### 1.1.1 Organigramme de la SONATRACH

La figure ci-dessous représente un organigramme global de l'entreprise SONATRACH avec ces différentes branches sur le terrain national [64].

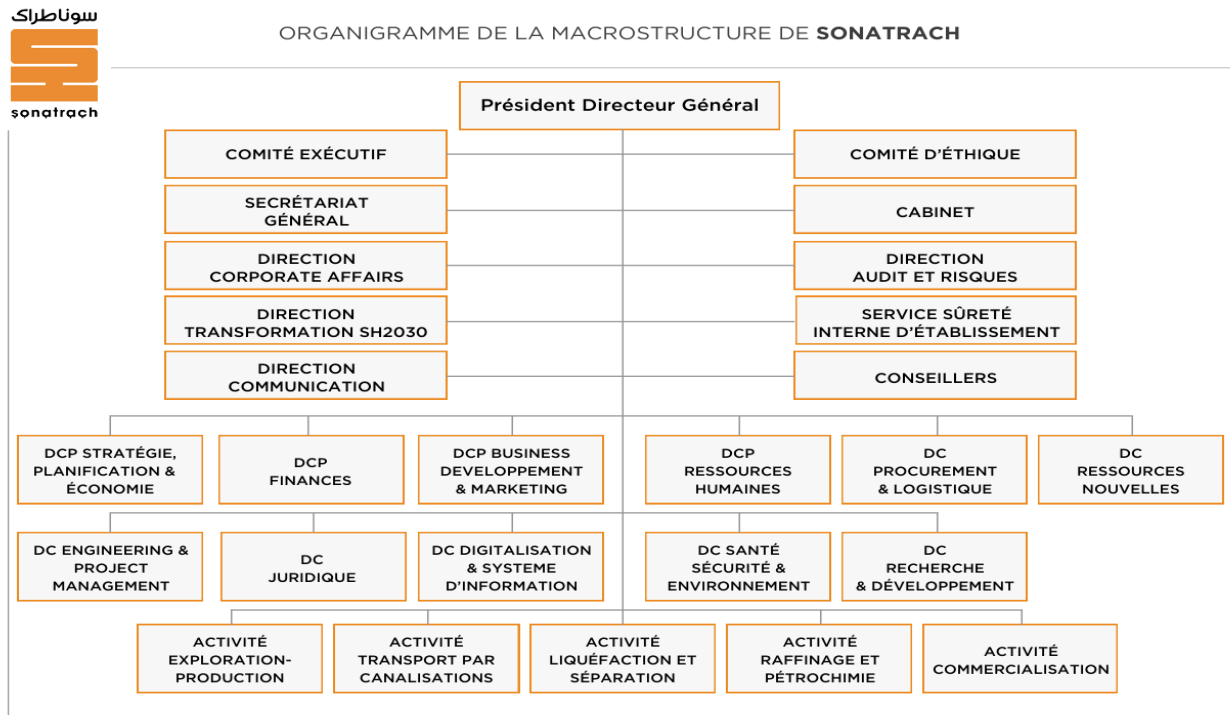


FIGURE 1.1 – Organigramme de la SONATRACH

### 1.1.2 Les activités de la SONATRACH

Les principales activités de SONATRACH englobent l'ensemble de la chaîne de valeur des hydrocarbures, allant de la recherche et l'exploration jusqu'à la transformation et la commercialisation des produits finis auprès des consommateurs. Ces activités se structurent autour de cinq grands domaines [42] :

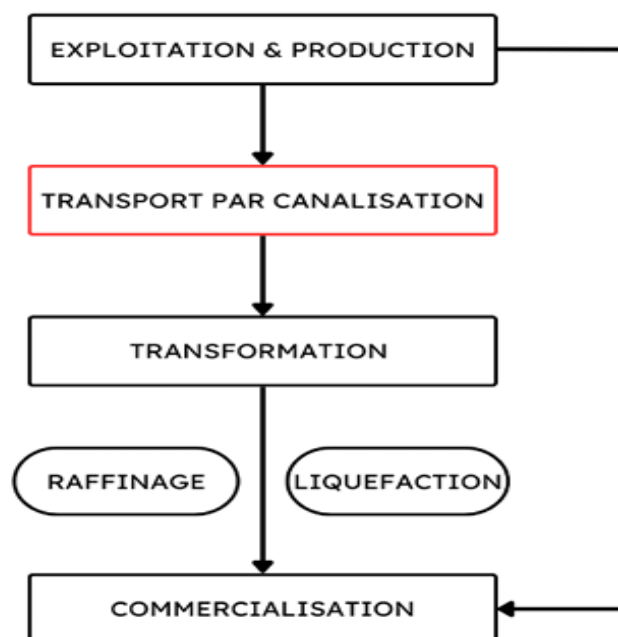


FIGURE 1.2 – Activités de la SONATRACH

- **Exploration-Production (EP)** : Valorisation des gisements, gestion des partenariats et développement de projets nationaux et internationaux.
- **Liquéfaction-Séparation (LQS)** : Liquéfaction du gaz naturel, séparation des GPL et optimisation des installations de production.
- **Raffinage-Pétrochimie (RP)** : Raffinage et pétrochimie pour répondre à la demande nationale en produits pétroliers.
- **Transport par Canalisations (TRC)** : Gestion d'un réseau de 22 systèmes de transport d'hydrocarbures (21 185 km), encadré par 6 directions régionales et 2 directions opérationnelles.
- **Commercialisation (COM)** : Vente des hydrocarbures sur les marchés national et international, y compris leur transport maritime.

### 1.1.3 Le Réseau de Transport par Canalisation (TRC)

Le Réseau de Transport par canalisation assure le transport, au profit des utilisateurs, de toute production d'hydrocarbures des points d'entrée aux points de sortie. Il permet également d'alimenter[63] :

- Le marché national ;
- Les complexes de GNL en gaz ;
- Les complexes de séparation en GPL ;
- Les raffineries en pétrole brut et en condensat.

L'excédent en gaz est destiné à l'exportation via le **GEM, GPDF et MEDGAZ**, tandis que l'ex-

cédent en pétrole brut et condensat est exporté via les ports d'**Arzew, Bethioua, Béjaïa et Skikda**. Le Réseau de Transport constitue un maillon flexible de la chaîne hydrocarbures, offrant la possibilité de gérer les aléas pouvant survenir en amont ou en aval. Afin de remplir cette mission dans des conditions optimales de sécurité, de respect de l'environnement et à moindre coût, SONATRACH applique les normes et standards internationaux pour le développement et l'exploitation du Réseau de Transport.

### 1.1.3.1 Description du Réseau de Transport

Le réseau de transport des hydrocarbures est composé de canalisations, stations de pompage/compression et parcs de stockage. Il assure l'acheminement des effluents des champs de production vers les zones industrielles et les ports (Arzew, Bethioua, Béjaïa, Skikda) pour traitement, exportation ou consommation nationale. Intégré aux systèmes STC Nord (OZ1/OZ2, OB1/OG1, OK1, NZ1, NK1), ce réseau s'est développé progressivement depuis 1959 pour répondre à la croissance des besoins en transport.

### 1.1.3.2 Structure du Réseau de Transport

Le réseau de transport se divise en deux axes :

- **Réseau sud** : transporte les effluents vers Haoud El Hamra (CDHL) pour le pétrole/condensat, et vers Hassi R'mel (CNDG) pour le gaz et le GPL.
- **Réseau nord** : achemine le pétrole, le condensat, le gaz et le GPL vers les raffineries, ports, marchés nationaux et unités de traitement.

Le tracé des canalisations repose sur des critères économiques, de distance et de sécurité.

## 1.2 La Région Transport Centre Béjaïa (RTC)

La RTC est l'une des huit régions de transport par canalisation de SONATRACH, chargée du transport, stockage et distribution des hydrocarbures liquides et gazeux depuis le centre du pays. Relevant de la division exploitation, la direction régionale de Béjaïa assure :

- L'exploitation des canalisations et stations de pompage (liquides) et de compression (gaz).
- La gestion des flux selon les besoins de production et de commercialisation.
- La maintenance, la sécurité et les révisions des équipements.
- La conduite des études et projets de développement du réseau.

## 1.3 Patrimoine de la Région Transport Centre (RTC-Béjaïa)

La région transport centre est chargée de l'exploitation de deux (02) oléoducs, un (01) gazoduc et un port pétrolier.

### 1.3.1 Oléoduc 24"/22" OB1 "Haoud El Hamra – Béjaïa"

L'oléoduc **OB1** fut le premier pipeline réalisé en Algérie par la société pétrolière de gérance **SOPEG**. Mis en service en **1959**, il s'étend sur une longueur de **668 km**, reliant le centre de stockage de **Haoud El Hamra** au terminal marin de **Béjaïa** [4].

Le diamètre du pipeline varie selon deux tronçons distincts :

- **Premier tronçon** : allant de **Haoud El Hamra** au col de **Selatna**, équipé d'un pipeline de **24 pouces** de diamètre.
- **Deuxième tronçon** : s'étendant du col de **Selatna** au terminal marin de **Béjaïa**, pourvu d'un pipeline de **22 pouces** de diamètre.

Par ailleurs, la ligne **OB1** est équipée de huit stations de pompage, réparties comme suit :

– **Quatre stations principales** :

- **SP1 bis** à Djamâa
- **SP2** à Biskra
- **SP3** à Msila
- **SP4** à Béni Mansour

– **Quatre stations intermédiaires (satellites)** : SPA, SPB, SPC et SPD.



FIGURE 1.3 – Description des ouvrages de RTC

### 1.3.2 L'oléoduc de Beni-Mansour-Alger

Il est d'une longueur de 130Km et d'un diamètre de 20 pouces, il est piqué sur l'oléoduc Haoud-El-Hamra-Bejaïa, il alimente depuis 1970 la raffinerie d'Alger grâce à une pompe installée à Beni Mansour et à un terminal à Sidi arcine.il permet de répondre à la demande de la raffinerie qui est de l'ordre de 30 M.T.A.

### 1.3.3 Le gazoduc Hassi-R'Mel - Bordj M'naiel

- En exploitation depuis le 1er Octobre 1981 et d'une capacité désignée en line de 7 milliards de M3/an, il est d'une longueur de 437Km et d'un diamètre de 42 pouces. Ce dernier assure l'approvisionnement en gaz naturel plusieurs localités et villes du centre du pays.
- Il existe (11) poste de prélèvement qui permettent la consommation du gaz à des fins industriel et domestique. Cette consommation s'est élevée à plus de 3 milliards de M3/an.

### 1.3.4 Le port pétrolier de Bejaïa

Le port pétrolier composé de trois quais de chargement de navires par lesquels le ravitaillement de ses navires jaugeant jusqu'à 80.000 tonnes à partir d'une terminale de stockage du pétrole brut composé de 16 bacs à Toit flottants dont 12 à capacité de 35.000M3, et 4 à capacité de 50.000M3 ainsi qu'un bac pour réserve d'eau à capacité de 2.900M3.

## 1.4 Organisation structurelle et fonctionnelle de la RTC-Béjaia

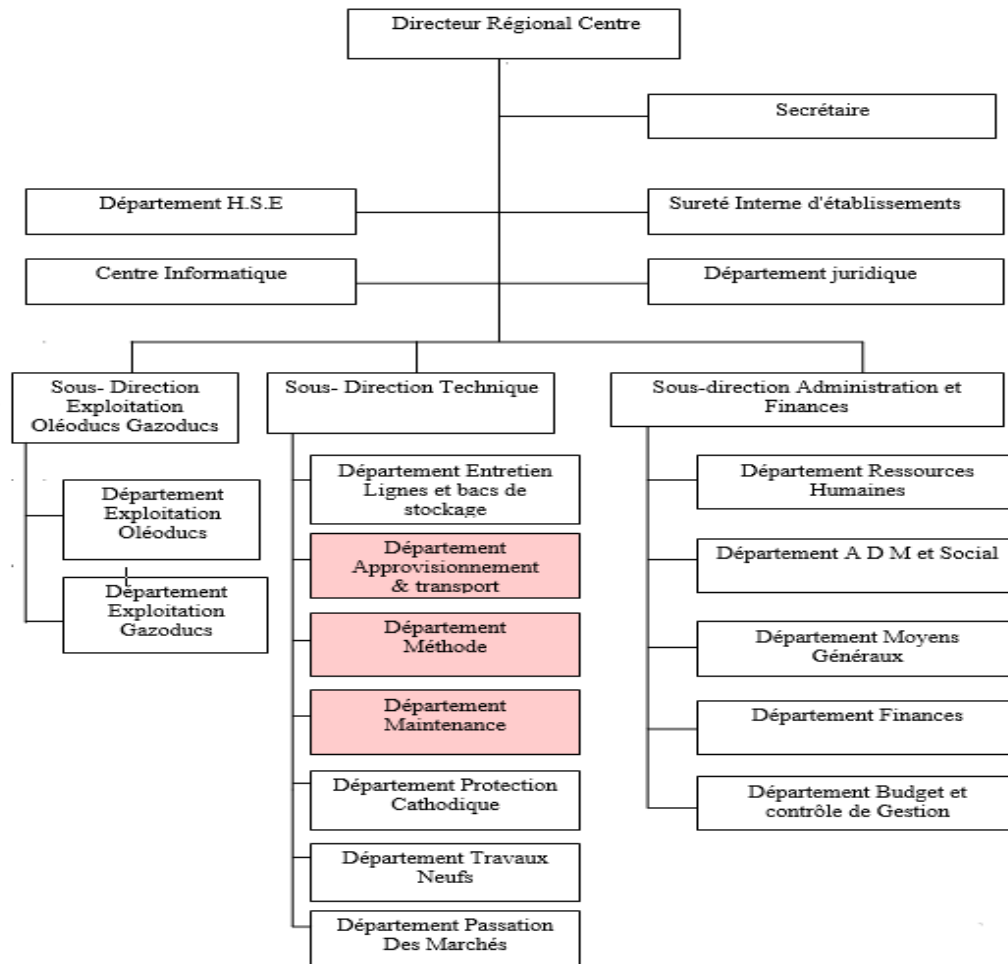


FIGURE 1.4 – Organigramme de la RTC-Bejaia

### 1.4.1 Structures et organisation interne de la RTC

La RTC est structur e autour d'une direction r gionale, assist e d'un secr tariat, d'un assistant de s uret  interne (ASI), d'un centre informatique et de plusieurs sous-directions.

- **HSE** : Assure la s curit , la sant  au travail et la protection de l'environnement.
- **Exploitation** : G re les installations de transport (ol oduc et gazoduc) via deux d partements (liquide et gaz).
- **Finances et Juridique** : Supervise le budget, les finances et les affaires juridiques.
- **Administration** : S'occupe des RH, des services sociaux et du soutien logistique.

- **Technique** : Gère la maintenance, les projets neufs, la protection des ouvrages, et l’approvisionnement.

La **sous-direction technique** comprend également le **Département Approvisionnement et Transport (ATR)** chargé de répondre aux besoins en matériel et logistique. Il se subdivise en cinq services :

- **Service d’achat** : Gère les achats locaux, étrangers et leur transit.
- **Service gestion technique** : Traite la codification, la gestion des équipements et des biens.
- **Service gestion de stock** : Supervise l’approvisionnement, le stockage et la distribution des articles.
- **Service transport** : Organise les transports de personnel et de marchandises.
- **Service entretien et réception** : Assure la maintenance et le bon fonctionnement du parc roulant.

Étant donné que notre étude porte sur la gestion des stocks, il est essentiel de présenter ce service ainsi que l’organisation de ses différentes sections et la répartition des responsabilités.

Pour garantir une gestion efficace des stocks, l’entreprise doit s’appuyer sur un dispositif administratif structuré, chargé d’exécuter l’ensemble des opérations essentielles telles que la valorisation, l’inventaire et le suivi des approvisionnements. Ce rôle est assuré par le service de gestion des stocks.

Afin de mener à bien ses missions, ce service est organisé en plusieurs sections, chacune étant responsable de tâches spécifiques conformément à l’organigramme illustré dans la figure (1.5).

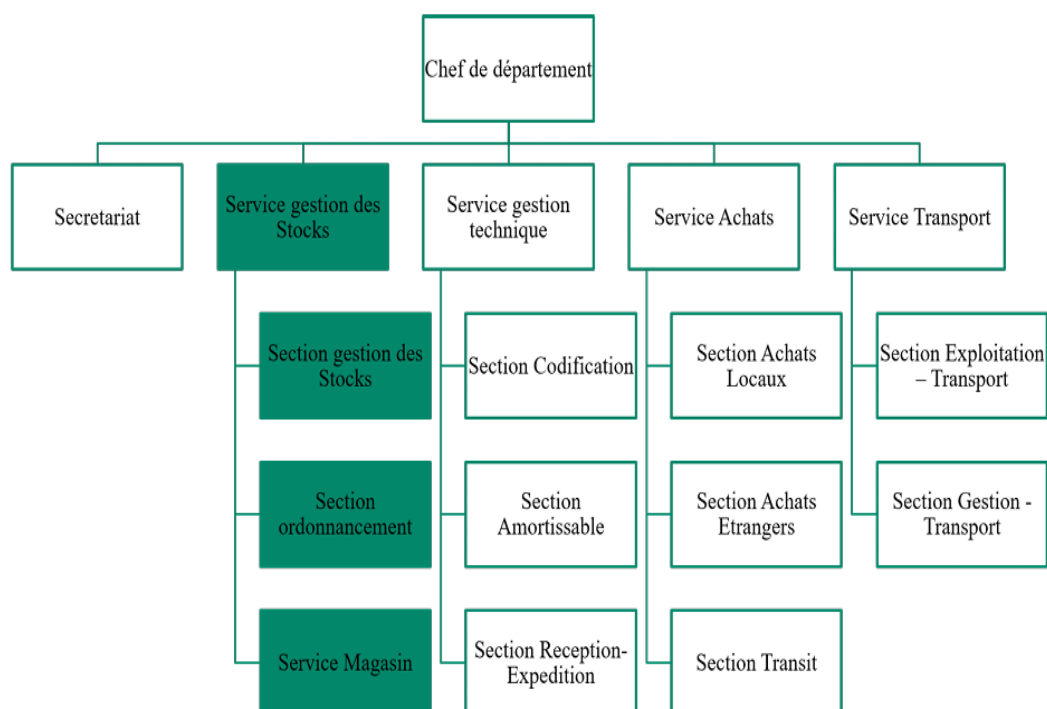


FIGURE 1.5 – Organigramme de l'ATR [68]

#### 1.4.1.1 Le service de gestion des stocks : fonctions et objectifs

La RTC accorde une importance considérable à ses stocks, ce qui se traduit par la création du **Service Gestion des Stocks**. Ce service a pour objectif stratégique d'optimiser la gestion des stocks afin de **réduire les coûts de stockage** et d'**éviter les ruptures de stock**. [49]

Pour atteindre cet objectif, l'entreprise doit s'appuyer sur un dispositif qualifié, capable d'assurer les opérations de **valorisation**, de **comptabilisation** et d'**inventaire**.

##### Section Gestion des Stocks

Cette section définit les **matières et matériaux à stocker** ainsi que leurs **quantités respectives**. Sa politique de gestion doit répondre aux besoins suivants :

- **Consommation** pour l'entretien programmé des engins et matériels de la direction.
- **Consommation** pour les réparations en cas de panne.
- **Maintien du stock de sécurité**.

Les tâches de cette section incluent l'enregistrement de tous les flux de stock dans les magasins à travers l'utilisation des documents suivants :

- **BRC** : Bon de Réception de Commande.
- **BS** : Bon de Sortie de matériel.
- **BTS** : Bon de Transfert Sortie pour les sorties des magasins cédants.
- **BTE** : Bon de Transfert Entrée pour les entrées des magasins preneurs.

- **BR** : Bon de Retour des pièces au magasin.
- **DA** : Demande d'Achat pour le réapprovisionnement des stocks.

### Section Ordonnancement

La Section Ordonnancement joue un rôle central en servant de **liaison entre les finances et les achats**. Elle est chargée de la **vérification et de la valorisation** des factures ainsi que des bons de réception fournisseurs, afin d'autoriser leur paiement. Les documents fondamentaux utilisés par cette section sont :

- Bon de réception fournisseur.
- Facture accompagnée de la fiche d'enregistrement.
- Facture d'assurance.
- Facture de transport (aérien ou maritime).
- Facture des droits de douane.

### Section Magasin

Cette section assure la **gestion du stockage**, la **conservation** et la **distribution** des matériaux aux utilisateurs. Les articles stockés sont classés par famille en tenant compte de plusieurs critères : **volume**, **poids** et **fréquence des mouvements**. Chaque pièce est étiquetée et rangée sur des étagères numérotées, facilitant ainsi une localisation rapide. Les magasiniers prennent en charge :

- La réception, le contrôle et la mise en stock des articles.
- La distribution du matériel en fonction des besoins des utilisateurs.
- L'inventaire permanent des entrées et sorties.
- L'inventaire physique général, réalisé en fin d'année.

Le suivi des stocks repose sur l'exploitation des documents suivants : **BS, BTS, BTE, BR et BRC**.

#### 1.4.1.2 Mission et Objectifs du Service Gestion des Stocks

Le Service Gestion des Stocks a pour mission principale de **gérer les stocks de manière optimale**, en garantissant un approvisionnement efficace en **pièces de rechange** et autres produits nécessaires. Tous les mouvements sont comptabilisés dans un **fichier central**, permettant un suivi précis de l'inventaire en temps réel. Ce service joue un rôle clé dans le **contrôle et l'optimisation des stocks**, en veillant à assurer une disponibilité continue des articles tout en minimisant les coûts. Il recense également les articles à ne plus commander en fonction du **planning d'exploitation**. En tant que centre d'information, il constitue une **ressource stratégique** pour l'ensemble de l'organisation et agit comme un **support essentiel** pour la division entretien.

### 1.4.1.3 Objectifs spécifiques du Service Gestion des Stocks

- **Maintenir des niveaux de stock suffisants** pour assurer l’entretien et le bon fonctionnement des installations industrielles.
- **Éviter le surstockage** afin de prévenir l’accumulation d’articles excédentaires.
- **Prévenir les ruptures de stock** et garantir la disponibilité des pièces stratégiques.
- **Définir les paramètres de réapprovisionnement** pour déclencher le processus d’approvisionnement au moment opportun.

## 1.5 Le système de gestion intégré utilisé : SAP

Afin de gérer efficacement ses processus complexes et interconnectés, SONATRACH s’appuie sur un *système de gestion intégré* (ERP) de renommée mondiale : **SAP** (Systems, Applications, and Products for data processing)[61]. Ce système constitue la colonne vertébrale numérique de l’entreprise, en permettant une centralisation, une automatisation et une optimisation des flux d’information entre les différentes entités opérationnelles et fonctionnelles de SONATRACH, notamment dans les domaines des finances, de la maintenance, de la logistique, des achats, et de la gestion des stocks. L’utilisation de SAP permet une traçabilité complète des opérations, une réduction des erreurs humaines, ainsi qu’une prise de décision plus rapide et plus éclairée, fondée sur des données fiables et en temps réel. À travers ses différents modules, SAP contribue à harmoniser les pratiques au sein des directions régionales, dont la Direction Régionale de Béjaïa (DRGB), en assurant la cohérence et la transparence des activités logistiques et d’approvisionnement.

### 1.5.1 Présentation du système SAP

SAP est un progiciel de gestion intégré (ERP) développé par la société allemande SAP SE. Il se compose de plusieurs modules couvrant l’ensemble des fonctions d’une entreprise. Chez SONATRACH, les modules les plus utilisés dans le cadre de la gestion des stocks et de la logistique sont [24] :

- **MM (Materials Management)** : gestion des achats, des stocks et des mouvements de marchandises.
- **PM (Plant Maintenance)** : gestion de la maintenance préventive et corrective des équipements.
- **SD (Sales and Distribution)** : suivi des ventes et de la distribution des produits.
- **FI/CO (Finance and Controlling)** : gestion financière et contrôle de gestion.

Ces modules sont interconnectés, ce qui permet une circulation fluide de l’information entre les départements. Par exemple, une demande d’achat initiée par le service maintenance est directement visible dans le module MM, puis suivie dans FI pour les aspects budgétaires, et enregistrée dans les stocks une fois réceptionnée.



FIGURE 1.6 – Schéma des principaux modules SAP[38]

L'adoption de SAP par SONATRACH reflète une volonté de modernisation et d'alignement sur les standards internationaux en matière de gestion industrielle, dans un souci d'efficacité, de conformité et de compétitivité.

## 1.6 Position du problème

La gestion des articles d'instrumentation chez l'entreprise **SONATRACH** souffre de plusieurs limites : forte variabilité de la demande, délais d'approvisionnement incertains, données incomplètes, et recours à des méthodes traditionnelles peu adaptatives.

Ces difficultés entraînent surstocks, ruptures, et coûts logistiques élevés. Face à cela, les approches classiques montrent leurs limites.

L'enjeu est donc d'explorer comment les techniques d'intelligence artificielle peuvent améliorer la prévision de la demande et optimiser dynamiquement les politiques de réapprovisionnement.

Ce mémoire vise à répondre à la question suivante :

*Comment optimiser la gestion des articles d'instrumentation chez SONATRACH en s'appuyant sur des prévisions par IA et des modèles de gestion classiques ?*

## Conclusion

Ce premier chapitre a présenté l'organisation de SONATRACH, en mettant l'accent sur le rôle de la Région Transport Centre de Béjaïa (RTC-Béjaïa) et les enjeux liés à la gestion des stocks d'articles d'instrumentation. Parmi les principales difficultés identifiées figurent la variabilité des délais, le manque de données fiables et la spécificité des articles, qui rendent complexe le dimensionnement des stocks de sécurité.

Ces constats soulignent la nécessité d'une approche plus rigoureuse et innovante pour optimiser les approvisionnements. Le chapitre suivant introduit ainsi les fondements théoriques de la gestion des stocks, avant d'explorer les apports de l'intelligence artificielle dans ce domaine.

# 2

## Fondements théoriques de la gestion des stocks et de l'intelligence artificielle

### Introduction

La gestion des stocks constitue un enjeu stratégique dans un environnement industriel complexe comme celui de SONATRACH. Face à l'incertitude de la demande et aux aléas logistiques, les méthodes classiques atteignent leurs limites et appellent à des solutions plus flexibles et performantes.

Ce chapitre présente les bases théoriques de la gestion des stocks : fonctions, typologies, classifications et principales politiques d'approvisionnement. Il introduit ensuite les concepts de l'intelligence artificielle, en particulier ceux liés à la prévision de la demande et à l'optimisation, afin de montrer comment ces technologies peuvent renforcer l'efficacité des systèmes logistiques.

### Partie 1 : Notions théoriques de la gestion des stocks

#### 2.1 Les Stocks

##### 2.1.1 Définition

Les stocks désignent l'ensemble des biens ou ressources qu'une entreprise conserve afin de répondre à des besoins futurs. Ils jouent un rôle stratégique en servant de tampon entre les flux d'approvisionnement (entrées) et la demande des clients (sorties), garantissant ainsi

la continuité des opérations et la satisfaction des besoins en temps voulu, comme illustré à la Figure 2.1 [7].



FIGURE 2.1 – Gestion des stocks

## 2.1.2 Fonctions des stocks

Les stocks répondent à trois grandes fonctions [57] :

- **Financières** : Réduire les coûts de commande, anticiper les hausses de prix et profiter des remises sur quantité.
- **Sécurité** : Éviter les ruptures dues à l'incertitude de la demande ou aux retards de livraison [18].
- **Techniques** : Nécessité de stockage liée au processus de production (ex. : séchage, affinage, vieillissement).

### 2.1.2.1 La fonction stock dans l'entreprise

La gestion des stocks comprend deux fonctions clés :

- **Gestion des stocks** : Optimisation des quantités, élimination des stocks obsolètes, stratégie de réapprovisionnement et distribution rationnelle.
- **Suivi des stocks** : Suivi physique et financier pour assurer une visibilité en temps réel et un contrôle des coûts.

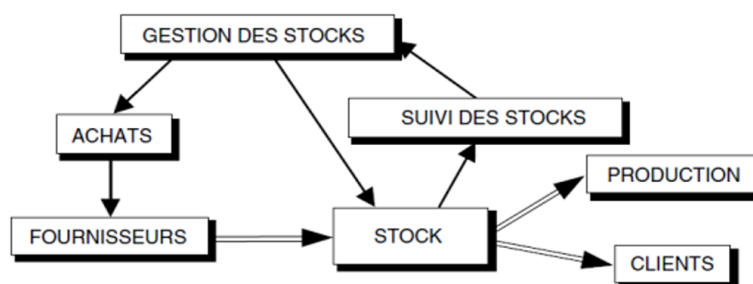


FIGURE 2.2 – Environnement de la fonction stock [42].

### 2.1.3 Les niveaux de stock

La nature de la demande, les délais de livraison, la dynamique des stocks et la politique de stockage ont conduit à l'apparition de plusieurs catégories de stocks [45], parmi lesquelles :

#### 2.1.3.1 Stock de sécurité

Le **stock de sécurité** représente le niveau minimal de stock permettant à l'entreprise d'anticiper les aléas tels qu'une consommation imprévue ou un retard de livraison. Il sert à prévenir les risques de rupture de stock et à assurer la continuité des activités.

#### 2.1.3.2 Stock minimum (stock d'alerte)

Le **stock minimum**, ou **stock d'alerte**, correspond à la quantité minimale de matières premières devant être disponible pour couvrir la consommation pendant le délai d'approvisionnement.

- Lorsque la demande est **déterministe** (connue à l'avance), ce stock est simplement équivalent à la quantité consommée durant ce délai.
- Dans le cas d'une demande **aléatoire**, il est ajusté afin de réduire le risque de rupture.

#### 2.1.3.3 Stock maximum

Le **stock maximum** correspond au seuil qu'il ne faut pas dépasser afin d'éviter des coûts de stockage excessifs. Il est généralement défini comme étant l'équivalent de la demande annuelle passée [16]. Il se calcule selon la relation suivante :

$$\text{Stock maximum} = \text{quantité commandée} + \text{stock de sécurité} \quad (2.1)$$

#### 2.1.3.4 Stock moyen

Le **stock moyen** représente la quantité moyenne de stock disponible sur une période donnée. Il peut être estimé par la formule suivante :

$$\text{Stock moyen} = \frac{\text{Stock maximum}}{2} \quad (2.2)$$

Il peut également être obtenu comme la moyenne entre le stock initial et le stock final, ou encore comme la consommation totale divisée par deux fois le nombre de commandes passées.

### 2.1.4 Utilités et inconvénients d'un stock

Le stock joue un rôle stratégique mais comporte aussi des contraintes.

#### Avantages :

- Réductions sur les achats en grande quantité.
- Continuité d'approvisionnement malgré les irrégularités.
- Protection contre les imprévus (retards, pannes).

- Opportunités de revente à profit.

**Inconvénients :**

- Immobilisation de capital.
- Besoin d'espace de stockage.
- Risques de détérioration, pertes ou obsolescence.
- Coûts de gestion et d'entretien.

## 2.2 La Gestion des Stocks

### 2.2.1 Définition

La gestion des stocks regroupe l'ensemble des opérations visant à planifier, approvisionner, conserver et suivre les articles en entrepôt, afin d'assurer leur disponibilité continue tout en évitant les ruptures ou les excès. Elle cherche à concilier efficacité économique et satisfaction des besoins des utilisateurs.

Quatre éléments fondamentaux caractérisent un stock :

- **Le produit** : tout bien conservé pour une utilisation future.
- **Le fournisseur** : entité capable de répondre à la demande en produits.
- **Le stock** : ensemble d'articles entreposés dans un lieu donné selon des conditions spécifiques.
- **L'utilisateur** : personne ou structure qui consomme les produits stockés.

### 2.2.2 Variables de la gestion des stocks

La gestion des stocks repose sur plusieurs variables clés, influencées par l'activité humaine et les aléas logistiques. Les principales sont :

- **Le délai de livraison** : temps écoulé entre la commande et la réception des produits, dépendant du fournisseur et du transport. Il se calcule par :

$$\text{Délai de livraison} = \text{date de réception} - \text{date de commande} \quad (2.3)$$

- **La demande** : quantité de produits souhaitée par les clients dans un laps de temps donné. Elle peut être continue ou discrète, constante ou variable dans le temps, et constitue le paramètre central de toute stratégie de stockage.
- **L'approvisionnement** : opération consistant à commander une certaine quantité d'articles pour reconstituer le stock.

### 2.2.3 Règles de contrôle

Pour assurer un suivi efficace des stocks, le gestionnaire dispose de plusieurs règles de contrôle. Ces règles varient en fonction du type de suivi adopté : revue continue ou revue périodique [26].

### 2.2.3.1 Systèmes à revue continue

Dans un système à revue continue, le niveau des stocks est surveillé en permanence, et une commande est déclenchée dès qu'un seuil prédéfini est atteint. Les principales politiques utilisées sont :

- **Politique  $(s, S)$**  : Une commande est passée dès que le stock atteint ou descend en dessous du seuil  $s$ , afin de le ramener au niveau  $S$ .
- **Politique  $(S, S)$**  : Cas particulier où  $s = S$ . Une commande est déclenchée à chaque demande. Elle est utilisée pour des articles coûteux à faible rotation.
- **Politique  $(s, nQ)$**  : Dès que le stock passe sous le seuil  $s$ , on commande un multiple  $n$  de la quantité de base  $Q$  tel que  $x + nQ > s$ , où  $x$  est le niveau actuel.

### 2.2.3.2 Systèmes à revue périodique

Dans un système à revue périodique, le stock est évalué à des intervalles fixes  $R$ , et des commandes sont déclenchées en fonction de la situation observée :

- **Politique  $(R, s, S)$**  : Tous les  $R$  temps, si le stock  $x \leq s$ , on passe une commande pour atteindre le niveau  $S$ .
- **Politique  $(R, S)$**  : À chaque période  $R$ , le stock est ramené à  $S$  indépendamment de son niveau. C'est un cas particulier de la précédente avec  $s = S$ .
- **Politique  $(R, s, nQ)$**  : Si à la revue le stock  $x \leq s$ , on commande un multiple  $nQ$  pour remonter le niveau.

## 2.2.4 Les coûts liés à la gestion des stocks

La gestion des stocks engendre plusieurs types de coûts, généralement regroupés en quatre catégories principales [11] :

- **Coût d'achat** : correspond au prix d'acquisition des articles stockés. C'est souvent le poste de dépense le plus important.
- **Coût de possession** : regroupe les frais liés au stockage des produits (entrepôts, personnel, assurance, obsolescence ou détérioration des articles).
- **Coût de commande** : comprend les dépenses liées à l'émission et au suivi des commandes (préparation, communication avec les fournisseurs, transport, réception).
- **Coût de pénurie** : désigne les pertes subies en cas de rupture de stock (arrêts de production, pertes de clients, coûts d'urgence ou de sous-traitance).

### 2.2.5 Politiques d'approvisionnement

Les décisions de réapprovisionnement s'appuient sur différentes stratégies visant à déterminer le moment et la quantité des commandes. Les principales approches sont les suivantes :

#### 1. Réapprovisionnement à date et quantité fixes

Aussi appelée méthode "calendaire", cette stratégie repose sur des livraisons effectuées

à des dates prédéfinies avec des quantités constantes. Elle est particulièrement adaptée aux produits à consommation régulière et de faible valeur. [68]

- **Avantages** : Simplification de la gestion des stocks, optimisation des coûts grâce aux économies d'échelle.
- **Inconvénients** : Risque d'accumulation excessive ou de rupture de stock en cas de variation de la consommation.




FIGURE 2.3 – Réapprovisionnement à Date fixes et Quantité fixes.

## 2. Réapprovisionnement à date fixe et quantité variable

Également connue sous le nom de méthode de rechargement, cette approche consiste à fixer un niveau de stock optimal pour chaque produit. À intervalles réguliers, l'état des stocks est évalué et les commandes sont ajustées pour restaurer le niveau requis. Cette méthode est privilégiée pour les produits à forte valeur, périssables ou encombrants. [68]

- **Avantages** : Gestion optimisée des stocks, réduction des coûts liés à l'immobilisation financière.
- **Inconvénients** : Possibilité de rupture de stock si la demande est mal anticipée.




FIGURE 2.4 – Réapprovisionnement à Date fixes et Quantité variables.

## 3. Réapprovisionnement à date variable et quantité fixe

Aussi appelée méthode du point de commande, cette approche repose sur le déclenchement automatique d'une commande dès que le niveau de stock atteint un seuil prédéfini. Elle permet une gestion en flux tendu adaptée aux consommations irrégulières.

- **Avantages** : Réduction des risques de rupture de stock, ajustement dynamique aux besoins réels.
- **Inconvénients** : Exige un suivi continu des stocks, entraînant des coûts de gestion plus élevés.




FIGURE 2.5 – Réapprovisionnement à Date variable et Quantité fixe.

#### 4. Réapprovisionnement à date et quantité variables

Cette stratégie est généralement adoptée pour les articles de classe A, dont l'achat est conditionné par les opportunités du marché. Elle prend en compte les besoins spécifiques des commandes, les impératifs de production et les fluctuations du marché. [68]

- **Avantages** : Flexibilité accrue, possibilité d'obtenir des prix avantageux en fonction des conditions du marché.
- **Inconvénients** : Nécessite une surveillance constante des prix et de la demande, augmentant ainsi les risques liés à la spéculation.




FIGURE 2.6 – Réapprovisionnement à Date Variable et Quantité variables.

Quantité/période	Date Fixe	Date Variable
Quantité Fixe	Approvisionnements automatiques	Point de commande
Quantité Variable	Méthode de recomplètement	Achats opportunistes

TABLE 2.1 – Les politiques de réapprovisionnement.

Le choix de la stratégie de réapprovisionnement idéale repose sur divers facteurs, tels que les coûts d'achat, la complexité de l'approvisionnement, les délais de livraison et les spécificités propres à chaque produit ou référence.

### 2.2.6 Modèles de gestion des stocks

Dans la littérature, plusieurs modèles de gestion des stocks ont été développés. Ceux-ci peuvent être classés en deux grandes catégories : les **modèles déterministes** et les **modèles stochastiques**.

### 2.2.6.1 Modèles déterministes

Un modèle de gestion des stocks est dit **déterministe** lorsque la demande et le délai d'approvisionnement sont parfaitement connus à l'avance.

#### Modèle de Wilson

Également connu sous le nom de **modèle de la quantité économique de commande (EOQ - Economic Order Quantity)**, ce modèle est l'un des plus anciens en gestion des stocks. Il demeure toutefois largement utilisé en raison de sa simplicité et de la stabilité des solutions qu'il fournit. Ce modèle repose sur les hypothèses suivantes [9] :

- La demande est connue et constante sur l'horizon de gestion.
- Il n'y a pas de rupture de stock.
- Le délai de livraison est indépendant de la demande, et la quantité de commande peut être estimée.




FIGURE 2.7 – Modèle de Wilson

L'objectif du gestionnaire est de déterminer la quantité optimale à commander  $Q$ , de manière à minimiser le **coût total annuel de gestion des stocks**, défini comme suit :

$$CT = CA + CL + CP \quad (2.4)$$

où :

- $CA$  : coût d'achat annuel =  $D \times p$ , avec  $D$  la demande annuelle et  $p$  le prix unitaire de l'article.
- $CL$  : coût de réapprovisionnement =  $\frac{D}{Q} \times h$ , où  $h$  est le coût de lancement d'une commande.
- $CP$  : coût de possession du stock =  $\frac{Q}{2} \times cs$ , avec  $cs$  le coût de stockage d'une unité en stock.

Le problème mathématique consiste à minimiser la fonction suivante par rapport à  $Q$  :

$$CT = pD + \frac{D}{Q}h + \frac{Q}{2}cs \quad (2.5)$$

La **quantité optimale à commander**  $Q^*$  (**quantité de Wilson**) est donnée par :

$$Q^* = \sqrt{\frac{2Dh}{cs}} \quad (2.6)$$

### 2.2.6.2 Modèles stochastiques

Dans ces modèles, la demande et/ou le délai de livraison sont incertains et suivent une distribution aléatoire. L'objectif principal est soit :

- d'atteindre un certain **niveau de service**,
- de **minimiser le coût total** de gestion des stocks.

Le problème consiste à déterminer, pour un niveau de service donné [52] :

- **La quantité à commander** ( $Q$ ),
- **Le moment optimal pour passer la commande**.

#### 2.2.6.2.1 Système à point de commande ( $Q, r$ ) :

Pour ce système de gestion de stock, le contrôle du stock se fait de manière continue, c'est-à-dire qu'à tout instant on connaît le niveau du stock. Ce contrôle est réalisé en utilisant des fiches de stock ou en informatisant le système.

Cette politique consiste à commander une quantité fixe  $Q$  chaque fois que le niveau du stock baisse en dessous du seuil  $r$ , appelé point de commande (ou stock d'alerte). La quantité commandée est réceptionnée après un délai d'approvisionnement  $L$ . Notons que pour ce modèle, les cycles de réapprovisionnement du stock diffèrent d'une période à une autre, mais la quantité commandée est toujours constante.[17]

L'évolution du niveau de stock dans le temps est illustrée par la figure suivante :




FIGURE 2.8 – Evolution du stock avec la politique ( $Q,r$ )[17]

- **Calcul du point de commande** : On suppose que le volume de commande est déjà connu, calculé par exemple à l'aide de la formule de Wilson. Le calcul du point de commande  $r$  se fait de manière à maximiser le niveau de service ou à minimiser le coût total de gestion des stocks.

Considérons la variable aléatoire  $D$ , représentant « la demande ponctuelle de l'article durant une unité de temps ». On suppose que  $D$  est une variable aléatoire continue. Soit  $f$  sa fonction densité de probabilité, de moyenne  $\mu_D$  et d'écart-type  $\sigma_D$ . [17]

On définit alors la variable aléatoire :

$X$  : la demande durant le délai de livraison  $L$ .

Pour des demandes indépendantes émanant d'un grand nombre de clients, on a :

$$X = \sum_{i=1}^L D_i = L \cdot D, \quad (2.7)$$

et donc  $X$  suit une loi normale d'espérance  $\mu_X = L \cdot \mu_D$  et d'écart-type  $\sigma_X = \sqrt{L} \cdot \sigma_D$ .

• **Calcul de  $r$  en fonction du risque de rupture de stock  $\alpha$  :**

On a :

$$\alpha = \mathbb{P}(X > r) \quad (2.8)$$

c'est-à-dire la probabilité que la demande durant le délai de livraison dépasse le point de commande  $r$ . Par conséquent :

$$1 - \alpha = \mathbb{P}(X \leq r), \quad (2.9)$$

qui correspond au **niveau de service**, représentant le pourcentage de la demande client qui est satisfaite pendant une période donnée, On a :

$$\mathbb{P}(X \leq r) = 1 - \alpha \implies \mathbb{P}\left(\frac{X - \mu_X}{\sigma_X} \leq \frac{r - \mu_X}{\sigma_X}\right) = 1 - \alpha, \quad (2.10)$$

Posons :

$$Z = \frac{X - \mu_X}{\sigma_X} \sim \mathcal{N}(0, 1), \quad (2.11)$$

d'où :

$$r = \mu_X + Z_{1-\alpha} \cdot \sigma_X, \quad (2.12)$$

où  $Z_{1-\alpha}$  est le quantile (ou quartile) associé à la loi normale centrée réduite de probabilité  $1 - \alpha$ . Cette valeur est lue à partir de la table de la loi  $\mathcal{N}(0, 1)$ . [17]

Le tableau suivant résume les valeurs de  $Z_{1-\alpha}$  associées à quelques taux de service classiques :

Taux de service $1 - \alpha$	Risque de rupture $\alpha$	Quantile $Z_{1-\alpha}$
90%	10%	1.28
95%	5%	1.64
97.5%	2.5%	1.96
99%	1%	2.33
99.5%	0.5%	2.58

**Stock de sécurité** C'est une quantité d'articles supplémentaire que l'on conserve en stock pour se protéger contre les pénuries résultant des incertitudes qui proviennent de la demande des clients, et/ou des délais de livraison du fournisseur, ou des deux à la fois.[17] Le niveau du stock de sécurité  $S$  est calculé comme suit :

$$S = r - \mu_X = Z_{1-\alpha} \cdot \sigma_X. \quad (2.13)$$

En remplaçant  $\sigma_X = \sqrt{L} \cdot \sigma_D$ , on obtient :

$$S = \sqrt{L} \cdot \sigma_D \cdot Z_{1-\alpha}. \quad (2.14)$$

**Méthodes de calcul du niveau de service :** Deux approches permettent d'estimer le niveau de service dans un système de gestion des stocks [17] :

– **Cas 1 : Basé sur la fréquence des ruptures de stock.**

Si une seule rupture est observée en  $n$  années, alors :

$$\alpha = \frac{Q}{n\lambda}$$

où  $\alpha$  est le risque de rupture,  $Q$  la quantité de commande et  $\lambda$  la demande annuelle.

– **Cas 2 : Basé sur le coût de pénurie.**

En tenant compte du coût de pénurie unitaire  $\pi$ , le coût total annuel de gestion du stock est donné par :

$$CT(Q, r) = \frac{\lambda}{Q} \cdot h + \left( \frac{Q}{2} + r - \mu_X \right) \cdot \frac{\lambda}{Q} \cdot c_s + \pi \cdot \frac{\lambda}{Q} \cdot \int_r^{+\infty} (x - r) f(x) dx$$

L'objectif est de choisir le point de commande  $r$  qui minimise ce coût. En dérivant cette fonction, on obtient le niveau de service optimal :

$$\alpha = \mathbb{P}(X > r) = \frac{c_s Q}{\pi \lambda}$$

#### 2.2.6.2.2 Le système à réapprovisionnement périodique (R, T) :

Dans ce système, le contrôle du stock se fait de manière **périodique**, par exemple chaque semaine, chaque mois ou chaque trimestre.

Au début de chaque période fixe  $T$ , on contrôle le niveau du stock et la quantité commandée est celle qui ramène le niveau du stock au seuil  $R$ , appelé *niveau de recombplètement* (ou de réapprovisionnement). Cette commande est reçue après un délai d'approvisionnement  $L$ . [17]

L'évolution du niveau de stock pour cette politique est illustrée dans la figure suivante :




FIGURE 2.9 – Evolution du stock avec la politique (R,T)[17]

L'avantage de cette politique par rapport à la politique  $(Q, r)$  est qu'elle permet de regrouper les commandes par fournisseur, ce qui réduit les coûts de commande et de transport.

Les calculs utilisés dans le système  $(Q, r)$  peuvent être repris dans ce système avec les modifications suivantes :

- Dans le modèle  $(R, T)$ , le stock n'est pas contrôlé entre les périodes de révision, contrairement au modèle  $(Q, r)$  où le stock est surveillé de manière continue.
- Pour une période de révision  $T$ , le niveau de reapprovisionnement  $R$  détermine le niveau de service offert par le système.

• **Calcul du niveau de reapprovisionnement  $R$  :**

Pour déterminer  $R$  dans le système  $(R, T)$ , on procède de la même manière que pour le calcul du point de commande  $r$  dans le modèle  $(Q, r)$ , à la différence que l'on considère la demande ponctuelle durant  $T + L$  (et non plus seulement pendant  $L$ ).[17]

Soit la variable aléatoire  $D$  la demande de l'article par unité de temps, supposée suivre une loi normale de paramètres  $\mu_D$  et  $\sigma_D$ . On considère la variable aléatoire :

$$X = D \cdot (T + L) \tag{2.15}$$

Alors  $X \sim \mathcal{N}(\mu_X, \sigma_X)$ , avec :

$$\mu_X = (T + L) \cdot \mu_D, \quad \sigma_X = \sqrt{T + L} \cdot \sigma_D. \tag{2.16}$$

Si l'on souhaite garantir un niveau de service  $1 - \alpha$ , on a :

$$\mathbb{P}(X \leq R) = 1 - \alpha. \tag{2.17}$$

Posons la variable standardisée :

$$Z = \frac{X - \mu_X}{\sigma_X} \sim \mathcal{N}(0, 1), \tag{2.18}$$

alors :

$$\mathbb{P}\left(Z \leq \frac{R - \mu_X}{\sigma_X}\right) = 1 - \alpha.$$

Ce qui donne :

$$R = \mu_X + \sigma_X \cdot Z_{1-\alpha}. \quad (2.19)$$

En remplaçant  $\mu_X$  et  $\sigma_X$ , on obtient la formule finale du niveau de recombplètement :

$$R = (T + L) \cdot \mu_D + \sqrt{T + L} \cdot \sigma_D \cdot Z_{1-\alpha}. \quad (2.20)$$

## 2.3 Classification des articles stockés

Le stockage génère des coûts importants, d'où la nécessité de classer les articles selon leur importance stratégique, leur coût, leur fréquence d'utilisation et leur délai d'approvisionnement [26]. Cette classification permet d'optimiser la gestion des ressources et de garantir la disponibilité des produits tout en maîtrisant les dépenses.

La méthode ABC-XYZ est l'approche la plus utilisée. Elle combine :

- l'analyse **ABC**, basée sur la valeur des articles,
- l'analyse **XYZ**, basée sur la régularité de la demande [49].

### 2.3.1 Classement ABC

L'optimisation d'un système de gestion des stocks commence par la **sélection et la classification des articles** à stocker. Tous les articles ne nécessitent pas la même gestion, et leur différenciation repose principalement sur leur **valeur et leur niveau de consommation**. Parmi les méthodes empiriques couramment utilisées, on trouve la **méthode ABC**, basée sur le **principe de Pareto** [18].




FIGURE 2.10 – Courbe de classification des articles par la méthode ABC.

Cette approche classe les articles en trois catégories :

- **Catégorie A** : Articles coûteux, rares, et à délais d'approvisionnement longs, représentant environ **10 % des articles stockés mais 75 % de la valeur totale**. Ils nécessitent un contrôle rigoureux.
- **Catégorie B** : Articles de valeur intermédiaire, relativement disponibles, représentant **40 % des articles stockés et 15 % de la valeur totale**. Leur gestion est plus souple.
- **Catégorie C** : Articles peu coûteux et facilement accessibles, représentant **50 % du stock total mais seulement 10 % de sa valeur**. Leur gestion est plus flexible.

L'application de cette classification permet d'adopter une **stratégie de gestion différenciée**, en concentrant les efforts de suivi et d'optimisation sur les articles de **catégorie A**, tout en appliquant des méthodes plus souples pour les catégories B et C [18]

### 2.3.1.1 Étapes de la Classification ABC

Pour appliquer efficacement l'analyse ABC, les étapes suivantes doivent être suivies :

1. **Classer les articles** : Ordonner les articles en fonction du critère choisi, en commençant par ceux qui ont la plus grande valeur.
2. **Calculer les pourcentages cumulés** : Calculer les pourcentages cumulés du critère utilisé pour chaque article.
3. **Déterminer les fréquences cumulées** : Exprimer les fréquences cumulées en pourcentage du nombre total d'articles.
4. **Définir les classes A, B et C** : Identifier les trois classes (A, B et C) selon les pourcentages cumulés obtenus.

### Avantages et inconvénients de l'analyse ABC

L'analyse ABC optimise la gestion des stocks en identifiant les articles prioritaires selon leur valeur, réduisant les coûts et les risques de rupture. Toutefois, elle néglige la variabilité de la demande et peut surestimer certains articles. Pour pallier ces limites, elle est souvent associée à l'analyse XYZ, qui intègre la régularité de la consommation.

### 2.3.2 Analyse ABC-XYZ

L'analyse XYZ ajoute une dimension supplémentaire à l'analyse ABC en classant les articles selon leur **prévisibilité** ou leur **variabilité de demande**. Cette classification est essentielle pour ajuster les stratégies de gestion des stocks en fonction de la stabilité de la demande des articles.

#### Objectifs :

L'analyse XYZ est particulièrement utile pour les prévisionnistes et les gestionnaires de stocks. Elle permet de :

- Établir des règles de réapprovisionnement et de gestion des stocks adaptées à la variabilité de la demande.
- Optimiser le processus de planification de la chaîne d’approvisionnement en tenant compte de la prévisibilité des articles.
- Réduire les coûts de stockage tout en maintenant un niveau de service client élevé.

Pour mieux comprendre comment la classification XYZ complète l’analyse ABC, la figure suivante montre un exemple de produits classés selon la méthode XYZ. Cette illustration aide à visualiser comment les articles sont classés en fonction de la stabilité de leur demande.

La classification XYZ reflète la **stabilité de la consommation** des articles. Un produit avec une demande stable est plus facile à prévoir et à gérer qu’un produit avec une demande variable.

### 2.3.2.1 Classes XYZ :

- **Classe X** : Articles dont les ventes sont stables et prévisibles. Ils ont une faible variabilité de la demande et sont plus faciles à gérer.
- **Classe Y** : Articles avec des ventes modérément volatiles. Ils montrent une certaine variabilité mais restent relativement prévisibles.
- **Classe Z** : Articles avec des ventes très volatiles et imprévisibles. Ils nécessitent une gestion flexible pour éviter les ruptures de stock ou les surstocks.

**Exemple :**



FIGURE 2.11 – Exemple de produits XYZ [68]

Dans la figure 2.11, les produits sont classés selon leur volume moyen de ventes, mais chacun montre des incertitudes différentes. Pour maintenir un niveau de service similaire entre un produit de classe Z et un produit de classe X, il faut prévoir un stock de sécurité plus élevé pour le produit Z en raison de sa plus grande variabilité.

### 2.3.2.2 Calcul de la Classification XYZ :

Pour calculer la classification XYZ, les étapes suivantes doivent être suivies :

1. **Collecter l'historique des sorties** : Récupérer les données de sorties mensuelles pour l'année passée. Pour les produits à durée de vie courte, utiliser un historique hebdomadaire.
2. **Calculer les statistiques des sorties** : Calculer la moyenne  $\mu$  et l'écart type  $\sigma$  des sorties.
3. **Calculer le coefficient de variation (CV)** :

$$CV = \frac{\sigma}{\mu} \quad (2.21)$$

4. **Définir les limites des classes X, Y et Z** :
  - Classe X :  $CV < 50\%$
  - Classe Y :  $50\% \leq CV \leq 100\%$
  - Classe Z :  $CV > 100\%$Ces seuils peuvent être ajustés selon les spécificités de l'entreprise et du marché.
5. **Affecter les classes** : Classifier chaque article en fonction du coefficient de variation obtenu.

### 2.3.3 Utilisation de l'Analyse ABC-XYZ dans la Gestion des Stocks :

L'analyse combinée ABC-XYZ permet de définir des stratégies de gestion des stocks plus fines, en tenant compte à la fois de la **valeur** (ABC) et de la **variabilité** (XYZ) des articles. Voici des recommandations pour chaque combinaison de classes :

- **AX et BX** : Articles importants avec une demande stable. Faible couverture de stock et surveillance régulière.
- **AY** : Articles critiques avec une demande modérément variable. Une couverture de stock moyenne est recommandée.
- **AZ** : Articles à forte variabilité mais essentiels. Grande couverture de stock nécessaire pour prévenir les ruptures.
- **BY et CX** : Articles avec un risque modéré. Gestion flexible avec couverture de stock moyenne.
- **BZ et CY** : Articles volatils de moindre importance. Gestion automatique possible et limitation des stocks.
- **CZ** : Articles peu importants avec une demande erratique. Stocks minimaux recommandés, voir gestion sur commande ou déréférencement.[49]

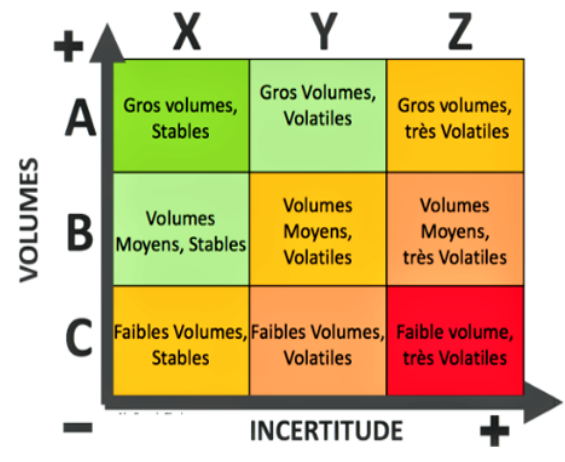


FIGURE 2.12 – Illustration du principe de classification ABC-XYZ

## Partie 2 : Notions théoriques de l'intelligence artificielle

### 2.4 L'intelligence Artificielle

L'intelligence artificielle (IA) est une discipline interdisciplinaire qui combine informatique, mathématiques, *neurosciences*<sup>1</sup> et robotique. Son objectif est de développer des systèmes capables de reproduire des fonctions cognitives humaines pour résoudre des problèmes complexes. Introduite officiellement en 1956 par John McCarthy, l'IA repose sur divers fondements théoriques, comme les probabilités, la théorie des jeux ou encore les neurosciences, et trouve des applications variées dans des domaines tels que la santé, le transport ou la logistique. Elle englobe plusieurs sous-domaines, notamment le *machine learning* et le *deep learning*, différenciés par leur degré d'automatisation et de complexité.

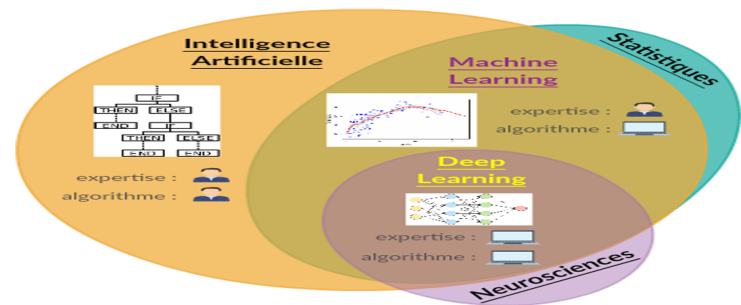


FIGURE 2.13 – Structure hiérarchique de l'intelligence artificielle[44]

1. Les neurosciences, qui étudient le fonctionnement du cerveau, ont inspiré de nombreuses avancées en intelligence artificielle (IA). Par exemple, les réseaux de neurones artificiels imitent les neurones biologiques, et les méthodes d'apprentissage automatique s'inspirent de la façon dont le cerveau apprend. Ce lien permet de créer des IA plus intelligentes, adaptatives et proches du raisonnement humain.

## 2.5 Le Machine Learning

### 2.5.1 Définition

Arthur Samuel a introduit l'apprentissage automatique pour la première fois en 1959, avec la définition suivante : « champ d'études qui permet aux ordinateurs d'apprendre sans être explicitement programmés ». Cette définition se concentre clairement sur le concept d'intelligence artificielle. Ce dernier représente l'environnement dans lequel le machine learning a évolué [62].

L'apprentissage automatique, ou aussi appelé Machine Learning (ML), est un domaine scientifique et plus particulièrement une sous-catégorie de l'intelligence artificielle qui permet aux ordinateurs d'acquérir des capacités d'apprentissage autonomes sans une programmation explicite. Elle englobe diverses méthodes permettant la création automatique de modèles à partir de données. Ces méthodes se manifestent sous la forme d'algorithmes conçus pour analyser et interpréter les données, facilitant ainsi l'apprentissage autonome des systèmes informatiques [13]. Machine Learning utilise des algorithmes pour générer des modèles statistiques à partir de données structurées [46].

Les différentes formes d'apprentissage en machine learning trouvent des applications concrètes dans des domaines variés. La figure suivante en illustre les principales catégories et usages



FIGURE 2.14 – Les applications de machine learning[32].

## 2.5.2 Objectifs de l'apprentissage automatique

Selon Tantuğ et Türkmenoğlu (2015), l'apprentissage automatique vise principalement à développer des modèles qui peuvent s'entraîner eux-mêmes pour s'améliorer, à percevoir les modèles complexes et à trouver des solutions aux nouveaux problèmes en utilisant les données des modèles précédents[70].

Machine Learning est largement employée en science des données et en analyse de données. Il offre la possibilité de concevoir, expérimenter et mettre en œuvre des algorithmes d'analyse prédictive sur diverses données pour anticiper l'avenir. Il s'agit d'offrir aux algorithmes la possibilité de détecter des « *patterns*<sup>2</sup> », dans les ensembles de données [43].

L'apprentissage automatique vise principalement à donner aux machines la capacité d'apprendre à partir des données, en repérant des modèles et en les généralisant afin de prendre des décisions ou de prédire de nouvelles données. Il s'agit fréquemment d'algorithmes d'apprentissage supervisé ou non supervisé, qui utilisent des ensembles de données massives pour entraîner des modèles capables de faire des prédictions précises ou de fournir des *insights*<sup>3</sup> importants [14].

## 2.5.3 Démarche des algorithmes d'apprentissage automatique

D'une manière générale, les algorithmes d'apprentissage automatique se décomposent en deux étapes [21].

- **Phase d'entraînement (ou d'apprentissage)** Pendant la phase d'entraînement (ou d'apprentissage), le modèle sélectionné est exposé à un grand nombre d'exemples significatifs. Le système cherche alors à acquérir des règles implicites en se basant sur ces données, appelées données d'entraînement. Cette phase précède généralement l'utilisation du modèle, bien que certains systèmes puissent continuer à apprendre indéfiniment s'ils reçoivent un retour sur les résultats, phénomène appelé apprentissage en ligne [48].
- **Phase de prédiction (inférence)** Durant la phase d'inférence, le modèle entraîné est apte à être utilisé sur de nouvelles entrées. Ces entrées peuvent être traitées même si elles n'ont pas été présentées au modèle lors de la phase d'apprentissage. En effet, grâce à l'extraction de règles implicites, le modèle peut se généraliser à des entrées inconnues [48].

## L'apprentissage

L'apprentissage est une notion clé et spécifique au ML. L'apprentissage correspond à extrapoler une loi à partir d'un ensemble de données par itération successive en ajustant les règles en fonction de l'erreur obtenue à chaque itération. **C'est le mécanisme qui remplace la pro-**

---

2. "Patterns" désigne des structures, tendances ou comportements qui se répètent dans les données et que les algorithmes de machine learning apprennent à reconnaître pour faire des prédictions ou des analyses.

3. "insights" désigne les enseignements importants que les modèles peuvent révéler à partir des données, même s'ils ne servent pas directement à faire des prédictions.

### grammation a priori d'un ensemble de règles.

Il existe plusieurs modes d'apprentissage. Le choix d'un mode d'apprentissage dépend des données disponibles (beaucoup ou peu de données) et du problème que l'on cherche à résoudre (reconnaissance de forme, classification automatique, etc.).[23]

Les modes d'apprentissage les plus courants sont les suivants :

#### • Apprentissage non supervisé

L'apprentissage se fait sans données étiquetées. L'algorithme doit découvrir par lui-même le meilleur découpage possible des données. L'apprentissage non supervisé est utilisé par exemple pour les problèmes de classification (*clustering*<sup>4</sup>).




FIGURE 2.15 – Apprentissage non supervisé sans données étiquetées

#### • Apprentissage semi supervisé

L'apprentissage se fait à la fois sur une partie des données qui sont *étiquetées*<sup>5</sup> et une partie des données non étiquetées. L'utilisation d'une combinaison de données référencées et non référencées permet d'améliorer la qualité de l'apprentissage. Le *référencement*<sup>6</sup> de données nécessite toujours l'intervention d'un utilisateur.

Lorsque les jeux de données deviennent très grands, cette opération peut s'avérer fastidieuse. Dans ce cas, l'apprentissage semi-supervisé, qui ne nécessite que quelques références, a un intérêt pratique évident.[23]

4. Le clustering est une technique d'apprentissage non supervisé utilisée en intelligence artificielle pour regrouper automatiquement des données similaires en catégories appelées clusters (ou groupes), sans connaissance préalable des classes. Cela permet de découvrir des structures cachées dans les données, utile pour l'analyse de clients, la segmentation d'images, la détection d'anomalies, etc.

5. Les données étiquetées sont des données pour lesquelles on connaît la réponse attendue (appelée étiquette).

6. Le référencement désigne l'ensemble des techniques permettant de rendre un contenu visible sur un moteur de recherche




FIGURE 2.16 – Apprentissage semi supervisé à partir des ensembles rouges, jaunes et verts

### • Apprentissage par renforcement

L'apprentissage par renforcement consiste à apprendre par essais-erreurs en interagissant avec un environnement afin de maximiser une récompense. Utilisé en robotique et dans des jeux comme AlphaGo, il permet à une machine d'identifier progressivement le comportement optimal à adopter dans une situation donnée.




FIGURE 2.17 – Apprentissage par renforcement, test de sortie de labyrinthe

### • Apprentissage actif

L'apprentissage actif consiste à sélectionner les données les plus informatives à étiqueter pour améliorer efficacement l'apprentissage, tout en réduisant les coûts. Il est utilisé pour des tâches comme la classification ou la régression. [23].

### • Apprentissage supervisé

L'apprentissage se fait à partir de données étiquetées disponibles. L'apprentissage supervisé est très utilisé pour les problèmes de reconnaissance d'image par exemple.




FIGURE 2.18 – Apprentissage supervisé à partir d'ensemble prédéfinis (rouge, vert, jaune)

La figure 2.19 illustre de manière synthétique les principales approches d'apprentissage automatique, en distinguant l'apprentissage supervisé, non supervisé, semi-supervisé et actif, selon la nature des données disponibles.




FIGURE 2.19 – Principaux types d'apprentissage

Chaque type d'apprentissage en machine learning est adapté à des contextes spécifiques. Le tableau suivant présente quelques exemples d'applications selon le mode d'apprentissage utilisé.

Type d'apprentissage	Exemple d'application
<b>Supervisé</b>	Reconnaissance d'image.
<b>Non supervisé</b>	Associer des maladies à divers facteurs explicatifs.
<b>Semi-supervisé</b>	Filtrage de bruit sur une image.
<b>Par renforcement</b>	Robotique autonome, apprentissage d'une tâche manuelle.
<b>Actif</b>	Les Chatbots (TALN).

TABLE 2.2 – Exemple d'usages selon le mode d'apprentissage[66]

Il existe plusieurs algorithmes de l'apprentissage supervisé, mais les plus utilisés sont : **la régression et la classification.**

### Régression

La régression est une méthode d'apprentissage automatique supervisé qui utilise des algorithmes pour prédire des valeurs continues comme les ventes, le salaire, le poids ou la température [21].

La régression est employée lorsqu'il est possible de prédire une sortie qui peut prendre des valeurs continues, ce qui est le cas d'une variable réelle. Par exemple, on peut utiliser un algorithme qui anticipe la consommation électrique d'une installation ou un algorithme qui anticipe le cours des actions en bourse [48].

Les tâches de régression peuvent être effectuées à l'aide de nombreux algorithmes d'apprentissage automatique. Il existe différents types de régression tels que la régression linéaire, le régresseur d'arbre de décision, le k régresseur du voisin le plus proche, le régresseur de forêt aléatoire et les réseaux de neurones .




FIGURE 2.20 – Modèles de régression linéaire [56]

## Classification

La classification est un ensemble de tâches réalisées dans un ordre déterminé pour résoudre un problème ou proposer de nouvelles solutions. Comme l'utilisation d'un système d'intelligence artificielle pour apprendre [21].

Le rôle des algorithmes de classification utilisés dans le machine learning est précisément celui-ci. Grâce à eux, le logiciel peut apprendre de manière autonome à partir de diverses bases de données .

Le concept de classification consiste donc à classer les divers éléments d'un jeu de données en différentes catégories. Ces données sont regroupées en fonction de leur similitude. Étant donné que les données ont des traits communs, il est plus aisé de prédire leur comportement .




FIGURE 2.21 – modèle de classification linéaire [34]

## 2.6 Les principales méthodes utilisées pour la prévision de la demande

Dans le cadre de la gestion intelligente des stocks, plusieurs méthodes de prévision peuvent être mobilisées en fonction des caractéristiques des données.

Cette section présente deux approches complémentaires largement utilisées dans la littérature et en milieu industriel : les forêts aléatoires (Random Forest) et la régression linéaire. Chacune d'elles répond à des cas d'usage spécifiques selon la variabilité de la demande et le comportement des articles.

### 2.6.1 Les Forêts aléatoires (Random Forests)

#### 2.6.1.1 Principe général

Les Random Forests (RF) sont des classificateurs d'ensemble qui développent plusieurs arbres de classification. Chaque arbre est conçu sur un échantillon bootstrap de l'ensemble d'entraînement en utilisant une sélection aléatoire des nœuds. RF classe une instance sur la base des classifications des arbres individuels. La classe qui reçoit le plus de votes est attribuée à cette instance. Les RF protègent contre le surapprentissage ou « *overfitting*<sup>7</sup> », qui peut arriver parfois avec les arbres de décisions. La technique est capable de fournir une haute performance constante, est très robuste et a un temps de calcul raisonnable. Le seul paramètre à régler est le nombre des variables disponibles pour le fractionnement à chaque nœud.

#### 2.6.1.2 Le concept de Bagging (Bootstrap Aggregating)

Afin de formaliser les forêts aléatoires, il faut tout d'abord définir la notion de *Bootstrap*<sup>8</sup> *Aggregating*<sup>9</sup> (Bagging) [37] :

La méthode **bootstrap** implique un rééchantillonnage itératif d'un ensemble de données en procédant à des tirages avec remises. Au lieu d'estimer notre statistique une seule fois sur les données complètes, nous pouvons le faire plusieurs fois sur un rééchantillonnage (avec remise) de l'échantillon d'origine. La répétition de ce rééchantillonnage plusieurs fois permet d'obtenir un vecteur d'estimations. Nous pouvons ensuite calculer la variance, la valeur attendue, la distribution empirique et d'autres statistiques pertinentes de ces estimations[37].

---

7. L'*overfitting* (Le surapprentissage), c'est-à-dire quand un modèle apprend trop bien les données d'entraînement, y compris le bruit ou les exceptions, ce qui le rend moins performant sur de nouvelles données (données de test ou réelles).

8. *Bootstrap* (statistiques) : C'est une méthode pour estimer la fiabilité d'un résultat en utilisant plusieurs fois les mêmes données, mais en les mélangeant un peu à chaque fois. Ça aide à savoir si ton modèle est solide ou pas.

9. *Aggregating* (agrégation) en apprentissage automatique, c'est le fait de combiner plusieurs modèles ou résultats pour en faire un seul plus fiable ou plus performant.

### 2.6.1.3 Formalisation de la méthode

Cet algorithme construit plusieurs arbres de décisions en utilisant des échantillons boots-trappés à partir de l'ensemble d'entraînement, chaque arbre de décision ayant une variance élevée[37]. L'agrégation des différents arbres permet de réduire la variance. Afin d'éviter qu'il y ait une corrélation entre les arbres, l'algorithme sélectionne aléatoirement un sous ensemble de variables à prendre en considération pour chaque arbre, généralement de l'ordre de  $m = \sqrt{N}$ ,  $N$  étant le nombre de variables total. L'*index de Gini*<sup>10</sup> présenté précédemment sert à mesurer l'importance des variables en marge du déroulement des arbres de décision.

### 2.6.1.4 Fonction d'agrégation et prédiction finale

On définit par la suite une fonction d'agrégation pour prédire un nouvel individu en utilisant la majorité des votes des arbres de décision dans le cas de la classification. Dans le cas de la régression, la moyenne des résultats obtenus par chaque arbre est calculée [37].

$$G(x) = \text{Vote majoritaire}(G_1(x), \dots, G_B(x))$$

Sachant que  $B$  est le nombre d'échantillons obtenus aléatoirement à partir de l'ensemble d'entraînement.

On peut illustrer le fonctionnement d'un algorithme de Random Forest ainsi :




FIGURE 2.22 – Vote majoritaire des arbres de décisions pour le Random Forest

### 2.6.1.5 Avantages et limites des forêts aléatoires

#### Avantages :

10. L'indice de Gini (ou index de Gini) est une mesure de pureté utilisée dans les arbres de décision pour évaluer la qualité d'un critère de séparation entre différentes classes. Il sert à identifier les variables les plus pertinentes pour la construction des arbres et à mesurer l'importance de chacune d'elles.

- Très bonne performance prédictive, même sur des données bruitées ou complexes.
- Capacité à gérer des relations non linéaires entre les variables.
- Moins sensible à l'overfitting que les arbres de décision simples.
- Peut traiter à la fois des tâches de classification et de régression.

#### Limites :

- Moins interprétable qu'un modèle simple (comme un arbre unique ou une régression linéaire).
- Temps de calcul plus élevé, surtout avec un grand nombre d'arbres et de données.
- Nécessite un réglage des hyperparamètres (nombre d'arbres, variables à tester à chaque nœud).
- Moins adapté à la prévision de séries temporelles sans transformations préalables.

### 2.6.2 La Régression Linéaire

La régression linéaire simple est un modèle statistique permettant d'étudier et de quantifier la relation entre une variable explicative  $X$  (par exemple, le temps ou le mois) et une variable à expliquer  $Y$  (par exemple, la demande d'un article). Elle repose sur le modèle suivant [69] :

$$Y_i = \beta_0 + \beta_1 X_i + \varepsilon_i, \quad i = 1, \dots, n$$

où  $\varepsilon_i$  est un terme d'erreur aléatoire supposé centré (espérance nulle), indépendant et de variance constante  $\sigma^2$ .

Les coefficients  $\beta_0$  et  $\beta_1$  sont estimés par la méthode des moindres carrés ordinaires (MCO), qui consiste à minimiser la somme des carrés des résidus  $e_i = Y_i - \hat{Y}_i$ . Cela conduit aux estimateurs suivants :

$$\hat{\beta}_1 = \frac{\sum(X_i - \bar{X})(Y_i - \bar{Y})}{\sum(X_i - \bar{X})^2}, \quad \hat{\beta}_0 = \bar{Y} - \hat{\beta}_1 \bar{X}$$

La droite de régression estimée permet alors de prédire les valeurs futures de  $Y$  à partir de nouvelles valeurs de  $X$ .

#### 2.6.2.1 Prédiction avec la Régression Linéaire

L'un des principaux avantages du modèle est la capacité à effectuer des prédictions. Pour une nouvelle valeur  $x_0$  de la variable explicative, la valeur prédite est donnée par :

$$\hat{Y}_0 = \hat{\beta}_0 + \hat{\beta}_1 x_0$$

Cette estimation peut être accompagnée d'un **intervalle de confiance** pour la moyenne conditionnelle de  $Y$  en  $x_0$  ou d'un **intervalle de prédiction** pour une nouvelle observation  $Y_0$ , qui prend en compte la variabilité du terme d'erreur.

L'intervalle de prédiction à un niveau de confiance  $1 - \alpha$  s'écrit :

$$\hat{Y}_0 \pm t_{\alpha/2, n-2} \cdot s \cdot \sqrt{1 + \frac{1}{n} + \frac{(x_0 - \bar{X})^2}{\sum (X_i - \bar{X})^2}}$$

où :

–  $s$  est l'estimateur de l'écart-type des résidus :

$$s = \sqrt{\frac{SC_{\text{Rés}}}{n-2}}$$

–  $t_{\alpha/2, n-2}$  est la quantile de la loi de Student à  $n-2$  degrés de liberté.

Dans le contexte de la gestion intelligente des stocks, la régression linéaire simple s'avère particulièrement utile pour prévoir la demande à court terme des articles de classe **BX**, caractérisés par une consommation régulière et une faible variabilité.

Lorsque la demande présente une tendance linéaire dans le temps, ce modèle permet de déterminer les quantités futures à commander, facilitant l'intégration dans les modèles de réapprovisionnement classiques tels que  $(Q, r)$  ou  $(R, T)$ .

Cependant, en présence de saisonnalité ou de fluctuations complexes, la régression linéaire simple peut se révéler insuffisante, ce qui justifie l'exploration de méthodes d'apprentissage automatique plus robustes, comme les forêts aléatoires, pour améliorer la précision des prévisions.

## Conclusion

Ce chapitre a posé les bases théoriques nécessaires à l'étude. Il a d'abord rappelé les principes essentiels de la gestion des stocks, puis introduit les apports de l'intelligence artificielle, notamment en matière de prévision de la demande. En combinant ces deux approches, nous avons montré le potentiel d'une stratégie hybride pour optimiser la chaîne d'approvisionnement dans un contexte industriel exigeant comme celui de Sonatrach. Ces fondations guideront les analyses et expérimentations des chapitres suivants.

# 3

## Analyse critique des approches de prévision et de la gestion des stocks

### Introduction

La gestion des stocks, essentielle à la performance logistique, évolue face à la volatilité de la demande et à la complexité croissante des chaînes d'approvisionnement. Les méthodes classiques, comme l'EOQ ou la politique (s,Q), montrent aujourd'hui leurs limites. L'intelligence artificielle, via l'apprentissage automatique et profond, offre de nouvelles solutions pour améliorer les prévisions, ajuster les stocks de sécurité et optimiser les réapprovisionnements. Ce chapitre présente un état de l'art des techniques d'IA appliquées à la gestion des stocks, en exposant leurs apports, limites et perspectives.

### 3.1 Méthodes traditionnelles de gestion des stocks

#### 3.1.1 Prévision de la demande

La prévision de la demande consiste à estimer, sur une période future, la quantité attendue d'un bien ou service[5]. Elle joue un rôle stratégique dans la planification des opérations, la gestion des ressources et l'optimisation des coûts[6]. Dans un contexte marqué par une volatilité croissante de la demande et des déséquilibres entre offre et besoin, les méthodes traditionnelles montrent leurs limites [5].

Face à l'explosion des données disponibles, les entreprises s'orientent de plus en plus vers des approches prédictives fondées sur les données, notamment celles issues de l'intelligence

artificielle. Ces méthodes permettent de mieux anticiper les comportements de consommation et d'atténuer des phénomènes comme l'*effet bullwhip*<sup>1</sup> [30]– amplification des *distorsions*<sup>2</sup> de la demande à travers les maillons de la chaîne logistique[51].

L'objectif central est de réduire l'écart entre la demande réelle et la demande prévue[67]. Une prévision inexacte peut entraîner des surstocks, des ruptures ou une mauvaise allocation des ressources. Ainsi, la précision du modèle utilisé est déterminante. Les méthodes de prévision combinent souvent analyses quantitatives (statistiques) et qualitatives (jugement d'expert), dans une approche qui relève autant de la science que de l'intuition managériale.

### 3.1.1.1 L'importance stratégique de la prévision de la demande

Dans un environnement économique de plus en plus instable et concurrentiel, la capacité à anticiper précisément la demande est devenue un levier fondamental pour assurer l'efficacité des chaînes d'approvisionnement.

Une prévision fiable permet non seulement d'aligner l'offre avec les besoins du marché, mais aussi de réduire les coûts logistiques, d'éviter les ruptures de stock, et de minimiser les surstocks, souvent synonymes de gaspillage ou d'obsolescence.

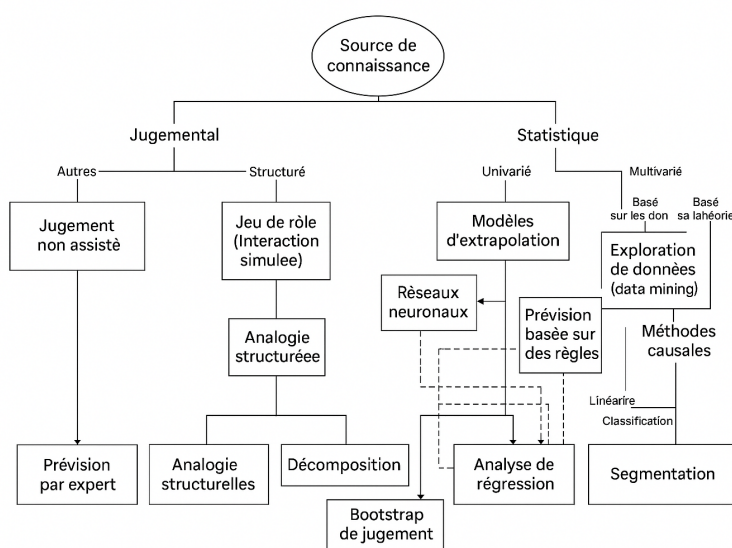


FIGURE 3.1 – Arbre méthodologique pour les prévisions [67]

1. l'effet bullwhip (ou effet coup de fouet) est un phénomène en gestion de la chaîne d'approvisionnement où de petites variations dans la demande finale provoquent des variations beaucoup plus grandes dans les commandes en amont.

2. les distorsions désignent des déformations ou des altérations d'une information, d'un signal, ou d'un phénomène par rapport à son état d'origine.

Une planification précise influence directement la gestion des fournisseurs, la production, les niveaux de stock et les délais de livraison. Elle favorise également une meilleure réactivité face aux aléas du marché. Dans ce contexte, la prévision ne doit plus se limiter à des approches statiques, mais s'appuyer sur des données actualisées, des tendances comportementales et des techniques analytiques avancées pour s'adapter à la volatilité croissante de la demande.

### 3.1.1.2 Approches traditionnelles de la prévision de la demande

Les approches traditionnelles de la prévision de la demande impliquent généralement une analyse des données historiques et diverses méthodes statistiques. Les techniques traditionnelles typiques ont été segmentées en techniques qualitatives et quantitatives.

#### Les techniques qualitatives

Les méthodes qualitatives s'appuient principalement sur l'expertise humaine et sont souvent utilisées lorsque les données historiques sont insuffisantes ou indisponibles. Elles sont adaptées aux environnements instables ou aux produits nouveaux. Trois approches principales se distinguent :

- **Le jugement d'expert** repose sur l'intuition et l'expérience de professionnels du secteur (vendeurs, consultants, etc.)[\[67\]](#). Cette méthode est utile en contexte incertain, mais elle reste subjective, sensible aux biais et dépendante de l'historique personnel de chaque expert.
- **L'étude de marché** consiste à collecter et analyser des données sur les préférences des consommateurs. Elle est appropriée pour les produits récents, mais peut être coûteuse, longue à mettre en œuvre et sujette aux interprétations[\[67\]](#).
- **La méthode Delphi**, développée dans les années 1950, sollicite un panel d'experts via des questionnaires successifs pour aboutir à un consensus. Elle est efficace pour intégrer des perspectives variées dans un contexte complexe[\[60\]](#), mais elle exige du temps, une bonne sélection des experts et plusieurs itérations pour être fiable[\[72\]](#).

#### Analyse quantitative des séries temporelles

Les méthodes quantitatives de prévision s'appuient sur l'analyse des données historiques pour détecter des tendances, lisser les fluctuations et anticiper les évolutions futures. Elles sont particulièrement adaptées lorsque les séries temporelles sont suffisamment longues et représentatives. Parmi les approches les plus utilisées, on distingue :

- **Les moyennes mobiles** : Ces techniques visent à lisser les variations à court terme d'une série temporelle afin d'en dégager la tendance générale. La moyenne mobile simple (SMA) calcule la moyenne d'un nombre fixe d'observations passées. La moyenne mobile pondérée (WMA) accorde plus de poids aux valeurs récentes. La moyenne mobile exponentielle (EMA)[\[39\]](#), quant à elle, applique un facteur de pondération décroissant de fa-

çon exponentielle, rendant le modèle plus réactif aux nouvelles données. Bien que faciles à mettre en œuvre, ces méthodes sont limitées dans les environnements instables, car elles ne tiennent pas compte des tendances ou de la saisonnalité de manière explicite[50].

- **Le lissage exponentiel** : Méthode très répandue dans la prévision des séries temporelles, elle consiste à attribuer un poids plus élevé aux observations récentes tout en conservant une mémoire des valeurs passées. La forme mathématique du lissage exponentiel simple est donnée par[41] :

$$S_t = \alpha x_t + (1 - \alpha)S_{t-1}, \quad \text{avec } 0 < \alpha < 1$$

où :

- $S_t$  représente la valeur lissée au temps  $t$ ,
- $x_t$  est la valeur observée à l'instant  $t$ ,
- $\alpha$  est le coefficient de lissage.

Selon la valeur de  $\alpha$ , le modèle peut être plus ou moins sensible aux variations récentes. Il existe plusieurs variantes adaptées à la complexité des données :

- le *lissage exponentiel simple*, utilisé lorsque la série ne présente ni tendance ni saisonnalité,
- le *lissage double*, approprié pour des séries avec tendance linéaire,
- le *lissage triple* (méthode de Holt-Winters), efficace pour des séries comportant à la fois tendance et saisonnalité.

- **La décomposition des séries temporelles** : Cette approche consiste à décomposer la série en composantes fondamentales : tendance, saisonnalité, et résidu (ou bruit aléatoire). On distingue deux types de modèles[71] :

- *Additif*, lorsque les variations saisonnières sont constantes dans le temps,
- *Multiplicatif*, lorsque les fluctuations saisonnières varient proportionnellement au niveau de la tendance.

La décomposition permet d'analyser finement la structure des données et de mieux orienter le choix de modèles prédictifs adaptés.

### 3.1.2 Prévision du délai d'exécution

La prévision du délai d'exécution est un élément clé de la gestion des stocks et de la chaîne d'approvisionnement. Elle consiste à estimer le temps nécessaire entre la passation d'une commande et sa réception. Une prévision fiable permet de réduire les ruptures de stock, d'optimiser les niveaux d'inventaire et d'améliorer la satisfaction client.

#### 3.1.2.1 Importance du délai d'exécution

Dans les secteurs critiques, la précision des délais est vitale. La complexité des processus de production, la variabilité des matières premières et les perturbations externes accentuent les difficultés de prévision[25]. La capacité à anticiper les retards permet d'améliorer la gestion des

fournisseurs, d'ajuster les niveaux de stock et de renforcer la résilience de la chaîne logistique.

### 3.1.2.2 Méthodes de prévision

Les approches traditionnelles incluent :

- la moyenne historique,
- le lissage exponentiel,
- les indices saisonniers,
- des méthodes heuristiques simples.

Les méthodes avancées reposent sur l'intelligence artificielle et l'analyse prédictive :

- régression linéaire ou non linéaire,
- machines à vecteurs de support (SVM),
- réseaux de neurones (ANN, LSTM),
- suivi temps réel via l'Internet des objets (IoT).

### 3.1.2.3 Facteurs influençant la variabilité

Plusieurs éléments peuvent affecter la fiabilité des délais :

- la performance et la fiabilité des fournisseurs,[1]
- les perturbations externes (grèves, catastrophes naturelles, instabilité politique),[55]
- les contraintes logistiques (douanes, transport),
- l'incertitude de la demande client.

### 3.1.2.4 Stratégies d'atténuation

Pour réduire l'impact de la variabilité des délais, plusieurs stratégies peuvent être mises en œuvre :

- **Diversification des fournisseurs** : recours à plusieurs sources pour le même article afin de limiter le risque de dépendance.
- **Gestion des relations fournisseurs (SRM)** : collaboration étroite, partage d'informations et suivi des performances.
- **Analyse prédictive et simulation** : modélisation des délais pour anticiper les perturbations.
- **Constitution de stocks tampons** : stockage de sécurité pour amortir les aléas.
- **Inventaire géré par le fournisseur (VMI)** : délégation partielle de la gestion du stock aux fournisseurs.

La combinaison de ces approches permet une meilleure maîtrise des délais, un pilotage efficace des niveaux de stock et une réduction des risques opérationnels.

## 3.2 Apport de l'IA dans la gestion des stocks

Dans les chaînes d'approvisionnement à plusieurs niveaux, l'effet d'amplification des écarts de demande (effet coup de fouet) perturbe la précision des prévisions, rendant les opérations

moins efficaces. L'apprentissage automatique (ML) et les techniques analytiques modernes apparaissent comme des solutions prometteuses pour atténuer cet effet, malgré certaines limites. Pour améliorer les performances, des approches hybrides combinant plusieurs méthodes sont aujourd'hui privilégiées[31].

### 3.2.1 Apprentissage automatique

L'apprentissage automatique permet de capter des relations complexes, souvent non linéaires, à partir de grands ensembles de données[2]. Les principales techniques incluent :

- **Régression** : les modèles établissent une relation [41] entre une variable cible  $y$  (ex. demande) et un ensemble de prédicteurs  $x_1, x_2, \dots, x_p$  :

$$y_i = \beta_0 + \beta_1 x_{i1} + \dots + \beta_p x_{ip} + \epsilon_i$$

Parmi les variantes, on trouve : régression multiple, de Poisson, Lasso, et à vecteur de support (SVR).

- **Arbres de décision et forêts aléatoires** : les arbres partitionnent l'espace de caractéristiques pour prédire la demande en minimisant la variance intra-région[20]. La forêt aléatoire combine plusieurs arbres construits aléatoirement pour améliorer la robustesse. La prédiction finale est obtenue par :

$$\hat{y} = \frac{1}{T} \sum_{t=1}^T h_t(x)$$

où :

$T$  est le nombre d'arbres et  $h_t(x)$  la prédiction de l'arbre  $t$ .

- **Gradient Boosting** : cette méthode construit des arbres séquentiellement,[73] chaque nouvel arbre corrigeant les erreurs des précédents. La mise à jour du modèle à l'itération  $m$  s'effectue comme suit :

$$F_m(x) = F_{m-1}(x) + \gamma_m h_m(x)$$

où  $h_m(x)$  est l'arbre ajouté et  $\gamma_m$  le taux d'apprentissage.

#### 3.2.1.1 Évaluation de la performance des modèles

L'évaluation repose sur plusieurs indicateurs clés [35] :

- **Erreur absolue moyenne (MAE)** :

$$\text{MAE} = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (3.1)$$

- **Erreur quadratique moyenne (MSE)** :

$$\text{MSE} = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (3.2)$$

- **Racine de l'erreur quadratique moyenne (RMSE) :**

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (3.3)$$

- **Coefficient de détermination ( $R^2$ ) :**

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (3.4)$$

### 3.2.2 Modèles hybrides

Les modèles hybrides combinent plusieurs approches (en parallèle, en série ou en structure mixte) afin d'augmenter la précision des prévisions. On distingue [36] :

- **Hybrides parallèles** : plusieurs modèles sont exécutés indépendamment et leurs résultats sont combinés (par moyenne, pondération, vote).
- **Hybrides en série** : la sortie d'un modèle alimente un second, permettant un enchaînement logique des traitements (ex. ARIMA suivi d'un réseau neuronal).
- **Hybrides série-parallèle** : combinaison complexe permettant d'exploiter différents aspects des modèles.

Ces combinaisons améliorent la détection des patterns, réduisent les biais liés à un seul modèle et renforcent la robustesse. Cependant, elles peuvent nécessiter davantage de ressources informatiques et une expertise approfondie pour leur paramétrage et leur maintenance.

## 3.3 Gestion des stocks de sécurité

La chaîne d'approvisionnement est soumise à plusieurs sources d'incertitude, notamment la variabilité de la demande, les délais d'approvisionnement et les événements externes. Dans un contexte économique instable et face à l'augmentation des perturbations logistiques à l'échelle mondiale, les entreprises tendent à adopter des stratégies plus prudentes, parmi lesquelles la constitution de stocks de sécurité s'avère essentielle [33].

Le stock de sécurité vise à pallier les écarts entre les prévisions et la demande réelle ou les délais de livraison. Il réduit ainsi la probabilité de rupture de stock [33], sans toutefois les éliminer totalement. Les principaux facteurs influençant ce niveau de stock sont l'imprécision des prévisions, la variabilité des délais et l'instabilité de la demande.

Certaines approches empiriques, reposant sur l'intuition ou sur des moyennes historiques, sont encore utilisées pour estimer ces niveaux, mais elles se révèlent souvent insuffisantes, car elles négligent des éléments clés de l'incertitude [12]. Plusieurs travaux [33] confirment que les stocks de sécurité représentent l'une des stratégies les plus robustes pour atténuer les risques liés aux aléas de la demande et de l'approvisionnement.

### 3.3.1 Approches existantes pour la détermination du stock de sécurité

Gonçalves et al.[33] ont réalisé une étude approfondie sur les méthodes de calcul des stocks de sécurité, en compilant et classifiant les approches existantes issues de la littérature scientifique. Leur analyse identifie les principaux facteurs influençant le dimensionnement du stock de sécurité : le niveau de service souhaité, la variabilité de la demande, les délais d'approvisionnement, la rareté des composants, les erreurs de prévision et les coûts de stockage[33].

Les approches classiques s'appuient sur des modèles stochastiques, supposant une demande normalement distribuée. La méthode la plus courante consiste à multiplier un facteur de sécurité  $z$  (dépendant du niveau de service) par l'écart-type de la demande pendant le délai d'approvisionnement  $LT$ .

$$SS = z \times \sigma_D \times \sqrt{LT}$$

où :

- $z$  : facteur de sécurité lié au niveau de service (valeur de la loi normale inverse),
- $\sigma_D$  : écart-type de la demande,
- $LT$  : délai d'approvisionnement.

Lorsque l'on dispose de prévisions historiques, il est possible de calculer le stock de sécurité à partir de l'erreur de prévision :

$$SS = z \times \sigma_F \times \sqrt{LT}$$

où  $\sigma_F$  représente l'écart-type de l'erreur de prévision pendant le délai.

Si l'incertitude réside principalement dans le délai d'approvisionnement, une autre formulation est utilisée [12] :

$$SS = z \times \sigma_{LT} \times D_{avg}$$

où :

- $\sigma_{LT}$  : écart-type du délai,
- $D_{avg}$  : demande moyenne pendant le délai.

Dans les cas où la demande et le délai sont tous deux variables et indépendants, le stock de sécurité se calcule selon [12] :

$$SS = z \times \sqrt{(\sigma_D^2 \times LT) + (D_{avg}^2 \times \sigma_{LT}^2)}$$

Si ces deux sources de variabilité sont corrélées, une formulation plus générale est proposée :

$$SS = z \times \sqrt{LT \times \sigma_D^2} + z \times \sigma_{LT} \times D_{avg}$$

Ces équations supposent en général une distribution normale de la demande, ce qui limite leur applicabilité dans les environnements à demande irrégulière ou intermittente. Des alternatives ont été proposées, notamment le bootstrap, permettant d'estimer empiriquement la variance de la demande sans hypothèse de normalité. Toutefois, ces méthodes n'ont pas toujours montré de meilleures performances que les approches paramétriques.

L'étude de Gonçalves [33] couvre 95 articles scientifiques publiés entre 1977 et 2020. Environ 88 % de ces travaux reposent sur des modèles analytiques (stochastiques ou d'optimisation), 6 % sur des simulations (ex. Monte Carlo), et le reste sur des approches hybrides. Par ailleurs, 35 % des études intègrent un contexte industriel concret (secteurs pharmaceutique, automobile, retail, électronique).

Certaines approches récentes modélisent le stock de sécurité comme proportionnel à l'erreur de prévision, en combinant des techniques de régression, de séries temporelles ou de prévision multivariée (intégrant prix, saisonnalité, événements exogènes). Ces méthodes alimentent ensuite des modèles d'optimisation intégrant les coûts, les ruptures de stock et les contraintes d'inventaire.

#### **Limites des approches classiques :**

- **Hypothèse de normalité** : inadéquate dans les chaînes complexes multi-produits à forte variabilité.
- **Perturbations fournisseurs** : les approches classiques ne capturent pas les risques exogènes récents.
- **Qualité des données** : les erreurs de prévision sont sensibles à la fiabilité des historiques.
- **Modèles mono-produit** : la plupart des études portent sur un seul article, sans considérer les effets croisés dans des environnements multi-produits.

Face à ces limites, les auteurs suggèrent l'intégration de méthodes d'**intelligence artificielle** pour mieux anticiper la demande, adapter dynamiquement les niveaux de sécurité et intégrer les signaux externes.

### **3.3.2 Niveau de service**

Le **niveau de service** désigne la probabilité qu'une entreprise soit en mesure de répondre à la demande client sans rupture pendant le délai d'approvisionnement. Il constitue un indicateur de performance des politiques d'inventaire.

Un niveau de service élevé implique la constitution d'un **stock de sécurité plus important** afin de réduire les risques de rupture, mais cela augmente également les **coûts de détention** et

mobilise davantage de **fonds de roulement**<sup>3</sup>[58]. Ainsi, l'entreprise doit équilibrer le niveau de service pour éviter à la fois les pertes dues aux ruptures et les coûts excessifs de stockage.

Le niveau optimal varie selon les produits, en fonction de la sensibilité des clients aux ruptures de stock. Dans la pratique, les entreprises utilisent souvent l'**analyse ABC** pour adapter les niveaux de service à chaque groupe de produits selon leur impact économique.

Un exemple de segmentation des niveaux de service par classe ABC, proposé par Radasanu et al. [58], comme le montre le tableau 3.1.

Catégorie	Segment	Description	Niveau de service recommandé (SL)
A	20% supérieur	Quelques critiques	Élevé, par exemple 96–98%
B	20–30% suivants	Interclasse	Moyenne, par exemple 91–95%
C	Derniers 50–60%	Nombre trivial	Inférieur, par exemple 85–90%

TABLE 3.1 – Segmentation ABC des niveaux de service [58]

Les clients préfèrent un niveau de service de 100 %, mais ce n'est pas souhaitable de la part d'une entreprise. Il est important de comprendre que les niveaux de service indiquent la performance des stocks et ne sont pas un indicateur direct de la performance de l'entreprise en matière de service au client dans les délais [22]. Ramos et al [59] présentent la relation entre les niveaux de service et de stock dans le tableau 3.2.

		Niveau d'inventaire	
		Haut	Faible
Niveau de service	Haut	A (plus de 85%) Satisfaire la demande des clients, détenir des stocks importants	B (70–85%) Niveau optimal, atteindre le niveau de service avec un stock équilibré
	Faible	C (70–85%) Stocks excédentaires et portage des stocks non performants	D (moins de 70%) Pénurie et rupture de stock

TABLE 3.2 – Niveau de service par rapport au niveau de stock

### Facteur de service (score $z$ )

Le **facteur de service**, ou **score  $z$** , est utilisé en gestion des stocks pour relier le *niveau de service* souhaité à la quantité de *stock de sécurité* à prévoir. Il représente le nombre d'écart-types

3. Le fonds de roulement est la différence entre l'actif circulant et le passif circulant :

$$\text{Fonds de roulement} = \text{Actif circulant} - \text{Passif circulant}$$

S'il est positif, l'entreprise peut couvrir ses besoins à court terme.

que la demande doit dépasser pour couvrir l'incertitude pendant le délai d'approvisionnement.

Le score  $z$  est obtenu à partir de l'*inverse de la fonction de répartition cumulative* (notée  $\Phi^{-1}$ ) de la loi normale centrée réduite. La relation est donnée par la formule suivante :

$$z = \Phi^{-1}(\text{Niveau de service})$$

où :

- $z$  est le score  $z$  correspondant au niveau de service souhaité,
- $\Phi^{-1}$  est l'inverse de la fonction de distribution cumulative de la loi normale standard,
- *Niveau de service* est la probabilité de ne pas être en rupture de stock pendant le délai d'approvisionnement (exprimée entre 0 et 1, par exemple 0,95 pour 95 %).

La relation entre le score  $z$  et le niveau de service est illustrée dans le graphique de la figure 2.2.




FIGURE 3.2 – Score  $z$  pour un niveau de service de 70-100%

**Exemple :** Pour un niveau de service de 95 %, on a :

$$z = \Phi^{-1}(0,95) \approx 1,645$$

Cela signifie que le stock de sécurité doit couvrir 1,645 écarts-types au-dessus de la demande moyenne pendant le délai de réapprovisionnement.

Le facteur de service traduit ainsi la *tolérance au risque* de l'organisation. Un niveau de service plus élevé entraîne une augmentation du stock de sécurité, mais aussi des coûts de détention. Le choix du niveau dépend de la *criticité des articles*, de leur *valeur stratégique* et de leur *impact sur les revenus de l'entreprise*.

### 3.4 Méthodes intégrées de gestion des stocks : revue de la littérature

La gestion des stocks a fait l'objet de nombreuses approches intégrées combinant prévision, optimisation et segmentation. Plusieurs travaux ont mis en œuvre des méthodes quantitatives

et décisionnelles pour améliorer la performance de la chaîne d'approvisionnement[53].

- **Approches multicritères et traditionnelles** : Lolli et al. utilisent l'AHP pour la classification des articles à demande intermittente. Sinaga et al. combinent moyenne mobile simple (SMA) et AHP pour améliorer la sélection des fournisseurs et la prévision des besoins en matières premières.
- **Optimisation des politiques d'inventaire** : Brunaud et al.[19] proposent des formulations mathématiques (politiques  $(r, Q)$  et  $(s, S)$ ) intégrant le stock de sécurité à travers des approches proportionnelles, linéaires ou basées sur le temps de service.
- **Modélisation de l'incertitude** : Trapero et al. appliquent GARCH et KDE pour estimer la distribution de la demande, réduisant l'erreur de prévision et renforçant la robustesse des stocks de sécurité.
- **Apprentissage automatique** : Carbonneau et al. montrent que les modèles RNN et SVM surpassent les méthodes classiques. Aamer et al. recensent 77 études mettant en avant l'efficacité des algorithmes comme XGBoost ou Random Forest dans la prévision de la demande.
- **Simulation et optimisation** : Warren et al. et Wadhwa et al. utilisent la simulation pour évaluer les effets combinés des politiques de réapprovisionnement, des délais et des prévisions sur le coût total. L'effet bullwhip est observé en cas de décisions locales non coordonnées.
- **Approches avancées** : L'apprentissage par renforcement (RL/DRL) est exploré par Zwaida et al. et Plessis et al. pour gérer automatiquement les décisions de réapprovisionnement.
- **Synthèse des connaissances** : Goncalves et al.[33] identifient des lacunes dans la prise en compte des perturbations et proposent d'intégrer des outils de simulation, d'optimisation et de segmentation avancée pour mieux dimensionner les stocks de sécurité.

En résumé, bien que les progrès soient notables, une intégration plus fine de l'analyse prédictive et de l'incertitude reste nécessaire, notamment pour les chaînes complexes. Une combinaison équilibrée entre méthodes quantitatives et organisationnelles est essentielle pour renforcer la résilience.

### 3.5 Limites des approches fondées sur les données

Malgré leurs avantages, les approches fondées sur les données rencontrent plusieurs limites clés :

- **Qualité des données** : Des données incomplètes ou imprécises compromettent la fiabi-

lité des prévisions.

- **Intégration complexe** : L'harmonisation entre différentes sources et systèmes reste difficile à mettre en œuvre.
- **Sécurité et confidentialité** : Les échanges de données sensibles augmentent les risques de cyberattaques.
- **Infrastructure technique coûteuse** : Le traitement en temps réel nécessite des ressources matérielles et humaines importantes.
- **Résistance au changement** : L'adoption des outils analytiques est souvent freinée par des blocages organisationnels.
- **Complexité de modélisation** : Le choix d'un modèle inadapté peut entraîner des décisions inefficaces.

Ces limites appellent à des approches hybrides, intégrant données, collaboration et conduite du changement.

## Conclusion

Ce chapitre a présenté les principales approches de prévision appliquées à la gestion des stocks, en particulier celles fondées sur l'intelligence artificielle. Ces méthodes offrent un fort potentiel d'amélioration, tout en restant dépendantes des données disponibles.

Le chapitre suivant décrit la méthodologie retenue pour leur mise en œuvre dans le cadre des articles d'instrumentation, en combinant simulation, classification ABC-XYZ et modélisation prédictive.

# 4

## Approche hybride de prévision de la demande et d'optimisation des stocks chez SONATRACH

### Introduction

Ce chapitre présente l'approche méthodologique adoptée pour mener l'étude de gestion intelligente des stocks d'articles d'instrumentation. Elle repose à la fois sur l'exploitation de données réelles issues de l'entreprise **SONATRACH** et sur une simulation permettant de pallier certaines limitations des données disponibles.

La démarche suivie s'articule autour de plusieurs étapes : la génération de données simulées, la mise en œuvre de différents modèles de prévision de la demande, leur intégration dans des stratégies classiques de gestion des stocks (modèles  $(Q, r)$  et  $(R, T)$ ), ainsi que l'évaluation des performances globales du système.

Les résultats quantitatifs détaillés et leur interprétation seront présentés et discutés dans le chapitre suivant.

### 4.1 Collecte et préparation des données

#### 4.1.1 Données réelles issues de l'entreprise SONATRACH

Dans le cadre de cette étude, l'entreprise **SONATRACH** a mis à disposition une base de données réelle issue de son système interne de gestion logistique. Celle-ci concerne un ensemble d'articles d'instrumentation utilisés dans la maintenance, la régulation et le contrôle

des installations industrielles.

### Description du jeu de données initial

Les données fournies couvrent plusieurs centaines d'articles techniques et comportent les attributs suivants :

- **Caractéristiques générales des articles** : Chaque article est identifié par un code spécifique et possède une désignation technique détaillée (ex. pièces pour actionneurs, transmetteurs de pression, cartes électroniques). Il est classé selon une famille fonctionnelle (telle que l'instrumentation ou l'automatisme), une sous-famille technique (par exemple : capteurs, modules, actionneurs), ainsi qu'un groupe et un sous-groupe selon sa nature physique ou fonctionnelle (ex. composants électriques, mécaniques, pneumatiques).
- **Historique de consommation** : Pour chaque article, on dispose d'un historique de sortie incluant les quantités retirées lors des mouvements de stock, les dates associées à ces mouvements ainsi que les quantités disponibles en stock à une date donnée.
- **Données économiques** : Chaque mouvement de sortie est associé à un montant total, permettant de calculer un prix unitaire pour l'article à cette date. Cela offre une base pour l'analyse économique des articles en stock, en tenant compte de la valeur des consommations et des coûts moyens.

A	B	C	D	E	F	G	H	I	J	K	L	M
Article	Famille	S/famille	Groupe	S/groupe	Libellé	N° Mouvement	Sens	Mouvement	Qté mvt	Montant mvt	Date mvt	Qté disp
1	AINST	PTETV	SOLDO	ELECT	BOITIER FIN DE COURSE POUR SCHEMA PNEUMATIQUE TYPE1	202401219	S	BSMH	5	641 513,85	06-mai-24	13
2	AINST	ADCS	ROSEM	AUXIL	TRANSMETTEUR MULTIVARIABLE ECHELLE DP/AP/TEMP: 0/622I	202301993	S	BSMH	1	534 019,85	31-mai-23	3
3	AINST	PTETV	ROTOR	MECAN	KIT VOLANT SUPÉRIEUR POUR IQMK2/MODÈLE IQ20/25	202402849	S	BSMH	6	483 645,62	18-sept-24	9
4	AINST	PTETV	ROTOR	MECAN	KIT VOLANT SUPÉRIEUR POUR IQMK2/MODÈLE IQ10/12/18	202402849	S	BSMH	10	457 997,97	18-sept-24	6
5	AINST	ADCS	SIEME	MOCOM	PROCESSEUR DE COMMUNICATION CP341	202402539	S	BSMH	1	432 122,59	18-sept-24	5
6	AINST	ADCS	ROSEM	AUXIL	TRANSMETTEUR DE PRESSION TYPE SMART SPAN: 0-6/210BAR	202304554	S	BSMH	1	291 233,35	27-nov-23	4
7	AINST	ADCS	ROSEM	AUXIL	Transmetteur de température :Echelle : Cal: -20 ÷ 80°C	202303229	S	BSMH	3	276 445,62	24-août-23	7
8	AINST	PTETV	ROTOR	MECAN	KIT VOLANT SUPÉRIEUR POUR IQMK2/MODÈLE IQ10/12/18	202403034	S	BSMH	6	274 798,78	07-oct-24	6
9	AINST	PTETV	ROTOR	ELECT	CAPOT ELECTRONIQUE COMPLET POUR IQMK2 VERSION CENEL	202300343	S	BSMH	4	263 029,30	16-mars-23	8
10	AINST	ADCS	ROSEM	AUXIL	RÉSISTANCE DE DÉTECTION DE TEMPÉRATURE PT100_385 WIRE	202303229	S	BSMH	3	249 628,73	24-août-23	7
11	AINST	PRDCS	ABB		BATTERIE 3.6 V SB 821 CÂBLE TK821V020	202402832	S	BSMH	2	246 140,43	10-sept-24	4
12	AINST	PTETV	ITW	ELECT	BOOSTER VOLUMETRIQUE 3/4" POUR ACTIONNEUR PNEUMATI	202301809	S	BSMH	2	239 194,19	17-mai-23	2
13	AINST	PTETV	ROTOR	ELECT	CARTE PROFIBUS DUAL CHANNEL NON PROGRAMMÉE	202402538	S	BSMH	1	211 471,41	18-sept-24	5
14	AINST	PTETV	STI	PNEUM	POSITIONNEUR E/P DN 1/2" POUR ACTIONNEUR PNEUMATIQUI	202301809	S	BSMH	1	210 448,73	17-mai-23	1
15	AINST	ADCS			CARTE CONTROLEUR P/ARMOIRE Z20605078 1/3	202304943	S	BSMH	1	205 266,13	21-déc-23	4
16	AINST	ADCS			CARTE CONTROLEUR P/MOTE RPP0104	202304942	S	BSMH	1	205 266,13	21-déc-23	4
17	AINST	ADCS	ROSEM	AUXIL	Transmetteur de pression relative	202301992	S	BSMH	1	198 091,68	31-mai-23	3
18	AINST	ADCS	ROCKW	MODUL	MODULE MODBUS TCP/IP	202402802	S	BSMH	1	185 444,97	08-sept-24	4
19	AINST	PDSTS			BLOC D'ALIMENTATION GE SECURITY POUR VRU 810/1210	202301010	S	BSMH	1	179 587,75	03-avr-23	3
20	AINST	PTETV	ROTOR	MECAN	KIT LEVIER MANU/AUTO POUR IQMK2/MODELE IQ10/12/18 ET	202402849	S	BSMH	6	178 634,99	18-sept-24	10

FIGURE 4.1 – Extrait du fichier Excel de gestion des articles – SONATRACH

### Limites des données réelles et justification de la simulation

Malgré leur richesse, plusieurs limitations ont été identifiées dans les données logistiques fournies par l'entreprise SONATRACH, rendant difficile une modélisation complète et directement opérationnelle :

- Absence d'un **historique journalier ou mensuel de la demande**, ce qui limite l'entraînement de modèles de prévision classiques (MM, lissage) ou modernes (RF, LSTM).
- Données **économiques incomplètes** : coûts de stockage, coûts de commande et coûts de rupture non explicitement renseignés.
- Aucune information sur les **niveaux de stock initiaux**, les seuils de commande ou les délais d'approvisionnement selon les processus d'achat.
- Faible nombre d'articles disposant d'un historique de consommation exploitable sur plusieurs années.

## 4.1.2 Modélisation et simulation

### 4.1.2.1 Choix de la loi de demande

La loi normale est couramment utilisée pour modéliser la demande continue en raison de ses propriétés statistiques avantageuses, notamment la symétrie autour de la moyenne et la capacité à représenter des fluctuations naturelles. Elle est définie par la densité de probabilité suivante :

$$f(d) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{1}{2}\left(\frac{d-\mu}{\sigma}\right)^2}$$

où  $\mu$  est la moyenne journalière de la demande et  $\sigma$  son écart-type.

### 4.1.2.2 Génération de la demande simulée

La demande journalière simulée pour un article  $i$  à l'instant  $t$  est définie comme suit :

$$D_i(t) = \max(0, \lfloor \mathcal{N}(\mu_i(t), \sigma_i) \rfloor)$$

avec :

$$\mu_i(t) = \mu_{0,i} \cdot (1 + \alpha t) \cdot (1 + \beta \cdot \sin(2\pi t/7))$$

où :

- $\mu_{0,i}$  est la demande moyenne initiale de l'article  $i$ ,
- $\alpha$  est un coefficient représentant la tendance (croissance ou décroissance modérée de la demande),
- $\beta$  modélise la saisonnalité hebdomadaire à travers une fonction sinusoïdale,
- $\sigma_i$  est l'écart-type associé à la variabilité de la demande de l'article  $i$ .

### 4.1.2.3 Troncature des valeurs négatives

Dans un contexte industriel, la demande ne peut être négative. Cependant, la loi normale peut théoriquement générer de telles valeurs. Pour garantir la cohérence des données simulées, chaque valeur générée est arrondie à l'entier le plus proche, puis tronquée à zéro si elle est négative :

$$D_i(t) = \max(0, \text{round}(\mathcal{N}(\mu_i(t), \sigma_i)))$$

Cette opération permet de conserver les avantages de la distribution normale tout en assurant la validité des données pour une utilisation en simulation de gestion des stocks.

#### 4.1.2.4 Simulation des coûts

Les paramètres économiques associés à chaque article ont été simulés de manière aléatoire dans des intervalles représentatifs de situations industrielles réalistes :

- Le **coût unitaire** de chaque article est généré dans une plage spécifique en fonction de sa valeur stratégique supposée. Trois niveaux sont considérés :
  - Articles critiques : entre 100 et 500 unités monétaires (articles potentiellement de classe A),
  - Articles intermédiaires : entre 30 et 100 unités monétaires (articles de classe B),
  - Articles peu coûteux : entre 5 et 30 unités monétaires (articles de classe C).

Cette génération permet une différenciation naturelle des articles en termes de valeur, prérequis essentiel à une classification ABC pertinente.

- Le **coût de commande** est fixé aléatoirement dans un intervalle proportionnel au coût unitaire, simulant les frais logistiques fixes associés à chaque réapprovisionnement. Il varie typiquement entre 80% et 150% du coût unitaire.
- Le **coût de possession unitaire annuel** est simulé en tant que pourcentage du coût unitaire de l'article, généralement compris entre 15% et 25%.
- Le **coût de rupture de stock** est également généré aléatoirement dans un intervalle proportionnel au coût unitaire (souvent entre 20% et 30%), représentant les pertes potentielles liées à une indisponibilité (interruption de production, commandes urgentes, etc.).

#### 4.1.2.5 Simulation du délai de livraison

Le **délai de livraison** est tiré aléatoirement parmi quatre valeurs représentatives : 50, 70, 95 et 160 jours. Cette distribution permet de simuler une variabilité réaliste des délais d'approvisionnement selon la nature de l'article ou les contraintes logistiques.

Ces paramètres sont utilisés en entrée dans les modèles de prévision et d'optimisation de la gestion des stocks présentés dans les sections suivantes.

4.1 Collecte et préparation des données

ID Article	Article	Classe ABC	Classe XYZ	Coût Unitaire	Coût Commande	Coût Stockage	Coût Rupture	Délai (jours)	Quantité demandée
1	INDICATEUR DE TEMPERATURE TYPE	A	X	249,82	343,74	49,96	74,95	95	130,8630137
2	TRANSMETTEUR DE PRESSION TYPE SMART SPAN 0-200BAR	A	Y	372,42	368,92	74,48	111,73	50	150,6876712
3	TRANSMETTEUR DE PRESSION TYPE SMART SPAN 0-6020BAR	A	X	465,72	389,43	93,14	139,72	95	140,3945205
4	TRANSMETTEUR DE PRESSION DIFFERENTIELLE TYPE SMART SPAN 0-40/10/60 MM/10BAR	A	X	189,88	223,98	37,98	56,96	95	101,9534247
5	TRANSMETTEUR DE PRESSION TYPE SMART SPAN 0-0,602BAR	A	X	303,34	299,7	60,67	91	70	166,2821918
6	TRANSMETTEUR DE PRESSION TYPE SMART SPAN 0,6020BAR	A	X	476,69	457,66	95,34	143,01	95	78,88493161
7	TRANSMETTEUR DE NIVEAU TYPE SMART SPAN0-2,1BAR	A	X	188,83	261,58	37,77	56,65	160	160,5972603
8	TRANSMETTEUR DE NIVEAU TYPE SMART SPAN0-2,1BAR	A	X	437,33	494,04	87,47	131,2	95	149,2857534
9	TRANSMETTEUR DE PRESSION TYPE SMART SPAN 0-0,602BAR	A	X	400,47	344,49	80,09	120,14	50	152,0968904
10	CARTE D'ENTREE LOGIQUE 32 VOIES 24 VDC	A	X	142,19	199,8	28,44	42,66	50	58,72054795
11	CARTE D'ENTREE LOGIQUE 32 VOIES 24 VDC	B	X	38,53	5,11	7,71	11,56	160	215,126986
12	CARTE DE SORTIE LOGIQUE 32 VOIES 24 VDC	B	X	82,04	118,96	16,41	24,61	95	266,1013699
13	CARTE DE COMMUNICATION SERIE REDONDANT 2 PORTS	B	X	51,82	55,75	10,36	15,55	160	257,739726
14	CARTE DE SORTIE LOGIQUE 32 VOIES 24 VDC	B	Y	64,51	84,9	12,9	19,35	95	286,7369863
15	TRANSMETTEUR DE PRESSION TYPE SMART SPAN 0-0,602BAR	B	Y	63,02	72,86	12,6	18,91	95	218,6493161
16	TRANSMETTEUR DE PRESSION TYPE SMART SPAN 0-0,602BAR	B	Y	54,69	46,63	10,94	16,41	70	282,6054795
17	CARTE DE COMMUNICATION SERIE REDONDANT 2 PORTS	B	Y	75,13	94,17	15,03	22,54	95	383,1123288
18	CARTE D'ENTREE ANALOGIQUE 8 CHANNELS 4-20 MA	B	X	42,49	52,74	8,5	12,75	160	236,4328767
19	CARTE DE SORTIE ANALOGIQUE 8 CHANNELS 4-20 MA	B	X	59,34	47,87	11,87	17,8	70	362,6767123
20	CARTE DE SORTIE ANALOGIQUE 8 CHANNELS 4-20 MA	B	X	52,95	77,94	10,51	15,76	70	329,6002192
21	POINTEAU H144 DE RELAIS DIFFERENTIEL COMPENSE NULLMATIC 68VT17 REGULATION GMP	B	X	62,27	75,7	12,45	18,68	50	336,5688663
22	THERMOSTAT MERCOD SIMPLE NAO/ ECH 0-100 °C	B	X	48,17	41,52	9,63	14,45	160	304,5898863
23	DIAGRAMME ROULEAU ECH 0-500 V D'ENREGISTREUR D'INTENSITE GUEREPILLON EC123F	B	X	94,49	81,87	18,9	28,35	160	427,5232877
24	TUBE DE BOURDON ECH 0-100 KG/CM2 MANOMETRE PETROLE MIP1 TYPE A D=150 MM	B	X	48,75	48,67	9,75	14,62	95	402,1452055
25	THERMOMETRE BIMETALLIQUE ECH 0-120 °C HUILE MULTIPLICATEUR GMP ET HUILE REFRIGE	B	X	72,53	100,47	14,51	21,76	70	292,5452055
26	THERMOMETRE BIMETALLIQUE ECH 0-120 °C HUILE MULTIPLICATEUR GMP ET HUILE REFRIGE	C	Y	25,66	30,8	5,11	7,67	70	1813,2849316
27	TUBE DE BOURDON ECH 0-2 KG/CM2 MANOMETRE PETROLE MIP1 D=150 MM TYPE A	C	X	24,89	20,52	4,98	7,47	95	1450,490274
28	RESSORT DE DIFFERENTIEL DE RELAIS DIFFERENTIEL COMPENSE NULLMATIC 68VT17 REGULA	C	Y	14,7	20,28	2,94	4,41	70	706,4493161
29	MANOMETRE PETROLE MIP1 D=150 MM ECH 0-40 KG/CM2 TYPE A	C	X	21,03	18,46	4,21	6,31	70	826,4739726
30	MANOMETRE PETROLE MIP1 D=150 MM ECH 0-40 KG/CM2 TYPE B	C	X	11,99	17,13	2,4	3,6	160	844,9370688
31	MANOMETRE PETROLE MIP1 D=150 MM ECH 0-2,5 KG/CM2 TYPE A	C	X	23,83	29,63	4,77	7,15	70	981,4
32	MANOMETRE A LLUNETTE CAPRE LAC 144X114 MM ECH 0-4 KG/CM2 TYPE 144	C	X	5,22	7	1,04	1,57	95	1425,969863
33	TUBE DE BOURDON ECH 0-7 KG/CM2 MANOMETRE D= 1MM TYPE	C	X	5,57	5,77	1,11	1,67	50	898,8328767
34	TUBE DE BOURDON ECH 0-10 KG/CM2 MANOMETRE INDUSTRIEL MAT10 D=130 MM TYPE B	C	Y	8,8	12,46	1,76	2,64	95	1815,778082
35	MANOMETRE D=100 MM ECH 0-16 KG/CM2 TYPE A	C	Y	12,13	12,94	2,43	3,64	95	1252,253425
36	MANOMETRE PETROLE MIP1 D=150 MM ECH 0-25 KG/CM2 TYPE	C	X	28,19	36,21	5,64	8,46	160	951,6457123
37	MANOMETRE PETROLE DUPLEX DURBIP D=150 MM ECH 0-10 KG/CM2 TYPE C	C	X	13,91	15,8	2,78	4,17	70	588,280274
38	BOBINE CAPREE 25 U-220V AC REF 39700-1009P (ELECTROVANNE SOGEV LP 226 DAD)	C	X	22,01	17,86	4,4	6,6	70	1230,978082
39	TIGE COMPLETE DE SOUPAPE DE SURETE CROSSBY JOR56A 4X1X6JCS89T	C	X	17,21	13,78	3,44	5,16	160	1195,968904
40	BAGUE DE REGLAGE INFERIEURE DE SOUPAPE DE SURETE CROSSBY JOR56A 4X1X6JCS89T	C	Y	15,16	15,47	3,03	4,55	70	1204,49589
41	THERMOMETRE LIQUIDE COLORE ECH 0 - °C MULTIPLICATEUR GRAFENSTADEN SADM	C	Y	22,51	32,95	4,5	6,75	95	1334,376088
42	AIGUILLE DE MANOMETRE PETROLE MIP1 D=150 MM	C	Y	29,06	41,81	5,81	8,72	95	956,8027397
43	JOINT DE VOYANT 150X140X5 MM MANOMETRE MIP1	C	Y	10,22	11,77	2,04	3,07	95	1720,60274
44	MANOMETRE PETROLE MIP1 D=150 MM ECH 0-25 KG/CM2 TYPE B	C	X	9,85	13,84	1,97	2,95	50	1511,142466
45	JOINT TORIQUE R24 (ELECTROVANNE SOGEV LP 226 DAD)	C	Y	21,33	25,4	4,27	6,4	70	1001,080274
46	DIAPHRAGME PREFORME H890 RELAIS DIFFERENTIEL COMPENSE NULLMATIC 68VT17 REGULATI	C	X	28,56	42,44	5,71	8,57	70	1495,282192
47	RESSORT POINTEAU H140 LG= 1MM DE RELAIS DIFFERENTIEL COMPENSE NULLMATIC 68V	C	X	28,71	31,93	5,74	8,61	95	680,6254795
48	BOUCIE DE FILTRE PHILIPONPE AIR COMPRI ME TYPE AC 25 ASSECHEUR GCHIN POULINC	C	X	21,32	17,96	4,26	6,4	160	1290,973973
49	GARNITURE DE 63X45 MM DE FILTRE PHILIPONPE AIR COMPRI ME TYPE AC 25 ASSECHEUR GD	C	Y	9,29	12,51	1,86	2,79	70	1235,50411
50	RONDELLE D=70X45 DE FILTRE PHILIPONPE AIR COMPRI ME TYPE AC 25 ASSECHEUR GCHIN PD	C	X	14,6	17,2	2,92	4,38	70	990,6857534

FIGURE 4.2 – Ensemble des données simulées

La signification des différentes colonnes est présentée ci-dessous :

- **ID Article** : Identifiant unique de chaque article dans la base de données.
- **Article** : Nom ou désignation générique de l'article de stock.
- **Classe ABC** : Catégorie de criticité basée sur l'analyse de la valeur annuelle consommée.
- **Classe XYZ** : Classification fondée sur la variabilité de la demande.
- **Coût Unitaire** : Prix d'acquisition d'une unité de l'article, simulé en fonction de son importance stratégique.
- **Coût Commande** : Coût associé au passage d'une commande.
- **Coût Stockage** : Coût annuel de stockage par unité.
- **Coût Rupture** : Coût estimé en cas de rupture de stock.
- **Délai (jours)** : Délai moyen de réapprovisionnement.
- **Quantité Demandée** : Moyenne quotidienne de la demande simulée, exprimée sur un horizon de 365 jours..

## 4.2 Prédiction de la demande

L'estimation précise de la demande est une étape fondamentale dans toute stratégie de gestion des stocks. Elle permet de définir les quantités optimales à commander, d'éviter les ruptures et de minimiser les coûts de stockage.

Dans ce travail, plusieurs approches de prévision ont été mises en œuvre afin de comparer leurs performances sur des séries temporelles représentant la consommation journalière d'articles.

### 4.2.1 Méthodologie de prévision

Les prévisions ont été effectuées à partir des séries temporelles simulées pour chaque article. Trois approches ont été mises en œuvre, représentant des niveaux croissants de complexité : la moyenne mobile simple, la régression linéaire et le modèle Random Forest. Ce choix méthodologique permet de confronter des techniques classiques, largement utilisées en gestion des stocks, à une méthode d'apprentissage automatique plus avancée, apte à modéliser des relations non linéaires dans les données de consommation. L'objectif est ainsi de mesurer la valeur ajoutée de l'intelligence artificielle par rapport aux méthodes traditionnelles.

- **Moyenne Mobile (MM)** : Il s'agit d'une méthode statistique simple et robuste qui calcule la moyenne des consommations passées sur une fenêtre glissante fixe.

$$\hat{y}_{t+1} = \frac{1}{k} \sum_{i=t-k+1}^t y_i$$

Elle est particulièrement adaptée lorsque la demande est relativement stable, sans tendance marquée ni variation saisonnière importante. Bien qu'elle soit peu sensible aux variations soudaines, la moyenne mobile reste largement utilisée dans les systèmes de gestion des stocks du fait de sa facilité de mise en œuvre.

- **Régression Linéaire (LR)** : Cette approche consiste à ajuster une droite aux données historiques de la demande, en cherchant à modéliser une éventuelle tendance (à la hausse ou à la baisse). Elle est utile lorsque la demande évolue de manière régulière dans le temps. En revanche, sa capacité à modéliser des fluctuations irrégulières ou des ruptures de tendance reste limitée, ce qui peut la rendre moins performante dans un contexte de variabilité élevée.
- **Random Forest (RF)** : Il s'agit d'un algorithme d'apprentissage supervisé basé sur un ensemble d'arbres de décision. Contrairement aux deux méthodes précédentes, la Random Forest est capable de capturer des relations complexes et non linéaires entre les variables. Elle est donc particulièrement adaptée aux environnements incertains et aux séries temporelles présentant des irrégularités ou des facteurs explicatifs multiples. Son usage dans ce contexte permet d'exploiter les caractéristiques spécifiques de chaque article (classe ABC-XYZ, coûts, délai, etc.) pour améliorer la précision des prédictions.

Les prévisions ont été effectuées sur les données simulées pour une période de 365 jours. La division entre données d'entraînement (80%) et données de test (20%) a été appliquée à chaque série.

### 4.2.2 Conditions de satisfaction des modèles

L'évaluation des modèles prédictifs repose sur des métriques quantitatives permettant de juger de leur adéquation aux données. Les critères suivants ont été retenus pour valider les performances des modèles.

#### 4.2.2.1 Métriques d'évaluation

**MAE** (Mean Absolute Error) : Mesure l'erreur moyenne absolue entre les valeurs réelles et prédites. Cette métrique donne une idée de l'ampleur des erreurs sans considérer leur direction.(voir équation (3.1))

**RMSE** (Root Mean Squared Error) : Similaire à la MAE mais accorde un poids plus important aux grandes erreurs, ce qui en fait un indicateur sensible aux écarts significatifs.(voir équation (3.3))

**R<sup>2</sup>** (Coefficient de détermination) : Exprime la proportion de la variance totale expliquée par le modèle.(voir équation (3.4))

#### 4.2.2.2 Seuils de validation

Pour chaque métrique, des seuils minimaux ont été définis afin de garantir la qualité des prédictions :

- **MAE** : Une valeur suffisamment basse, adaptée à l'échelle des consommations, est considérée comme acceptable.
- **RMSE** : L'écart-type des erreurs doit rester modéré afin d'assurer la stabilité des prédictions.
- **R<sup>2</sup>** : Un coefficient supérieur à 0,80 est requis pour valider un modèle comme suffisamment fiable.

Ces seuils, bien que fixés de manière empirique, permettent de classer les modèles selon leur efficacité, en tenant compte à la fois de la précision des prévisions et de la robustesse dans les décisions d'approvisionnement.

## 4.3 Adaptation des modèles de gestion des stocks

Les modèles classiques de gestion des stocks, tels que les politiques  $(Q, r)$  et  $(R, T)$ , sont largement utilisés pour déterminer les quantités à commander et les moments de réapprovisionnement. Dans cette étude, ces modèles ont été adaptés aux spécificités des données simulées,

en intégrant les prévisions de demande obtenues précédemment et les contraintes économiques (coûts de commande, de stockage et de rupture).

### 4.3.1 Objectif de l'adaptation

L'objectif est d'optimiser les paramètres de gestion des stocks (quantité économique de commande  $Q$ , point de commande  $r$ , seuil de reapprovisionnement  $R$ , et période de révision  $T$ ) pour chaque article, de façon à minimiser le coût total annuel, tout en garantissant un niveau de service satisfaisant.

Les contraintes incluent :

- Le respect d'un niveau de service cible (ex. 90% ou 95%);
- Le délai de livraison simulé pour chaque article;
- Les caractéristiques économiques spécifiques à chaque article.

### 4.3.2 Modèle ( $Q, r$ )

Le modèle ( $Q, r$ ) repose sur une politique à quantité fixe : une commande de taille  $Q$  est déclenchée dès que le niveau de stock atteint le seuil  $r$ .

Dans cette étude, ce modèle a été adapté à partir des prévisions journalières de la demande et des paramètres économiques propres à chaque article. L'objectif est de minimiser le coût total annuel tout en respectant un niveau de service cible.

La formulation mathématique du coût total est détaillée dans le chapitre 2 (équation (2.4)). L'optimisation des paramètres ( $Q, r$ ) est effectuée par recherche numérique pour chaque article, en intégrant la demande prévisionnelle et les contraintes logistiques.

Cette approche permet de définir, pour chaque classe ABC-XYZ, une politique ( $Q, r$ ) optimisée tenant compte des incertitudes et des coûts associés.

```
# Valeurs initiales selon la formule de Wilson adaptée
initial_Q = max(10, np.sqrt(2 * demande_annuelle * couts['
    commande'] / couts['stockage']))
initial_r = max(10, demande_moy * couts['delai'] + 1.28 *
    ecart_type)
```

### 4.3.3 Modèle ( $R, T$ )

Le modèle ( $R, T$ ) repose sur une politique de révision périodique : le stock est évalué à intervalles réguliers de durée  $T$ , et une commande est effectuée pour reconstituer le stock jusqu'au niveau cible  $R$ .

Cette méthode est adaptée aux contextes logistiques où les approvisionnements sont planifiés à des fréquences fixes (hebdomadaire, mensuelle, etc.).

Le calcul du coût total associé, incluant les coûts de commande, de stockage et de rupture, est donné dans le chapitre 2.

Les paramètres  $(R, T)$  sont déterminés par optimisation numérique, avec un encadrement réaliste de  $T$  pour refléter les pratiques industrielles. Cette politique offre une alternative flexible lorsque les contraintes organisationnelles limitent les possibilités de réapprovisionnement continu.

```
# Valeurs initiales
initial_R = max(10, demande_moy * (couts['delai'] + 7) + 1.04 *
    ecart_type * np.sqrt(couts['delai'] + 7))
initial_T = 7 # periode de revision initiale fixee a 7 jours
```

## 4.4 Validation et optimisation

Cette étape constitue un **pont stratégique** entre la prévision intelligente de la demande et **la mise en œuvre effective** des politiques de gestion des stocks. L'objectif est de transformer les prévisions obtenues via les modèles de machine learning en **décisions opérationnelles optimales**, en évaluant et en comparant les politiques classiques de réapprovisionnement  $(Q, r)$  et  $(R, T)$ .

### Optimisation des paramètres pour minimiser les coûts

Les paramètres de chaque politique ont été **optimisés automatiquement** en minimisant une fonction de coût total propre à chaque modèle. Cette fonction intègre plusieurs composantes économiques :

- le coût de commande,
- le coût de possession (ou de stockage),
- le coût de rupture de stock (en cas de demande non satisfaite),
- éventuellement, le coût d'achat (selon les hypothèses de gestion).

L'optimisation est réalisée à l'aide de la fonction `minimize` de la bibliothèque `scipy.optimize` en Python, qui applique des méthodes numériques de recherche de minimum local ou global :

```
from scipy.optimize import minimize

res_qr = minimize(fonction_cout_total_qr)
Q_opt, r_opt = res_qr.x
cout_total_qr = res_qr.fun

res_rt = minimize(fonction_cout_total_rt)
T_opt, R_opt = res_rt.x
cout_total_rt = res_rt.fun
```

Le programme débute par une estimation initiale des paramètres, puis les ajuste progressivement pour minimiser le coût total. Ce processus permet d'obtenir des paramètres de gestion **économiquement optimaux**, adaptés aux caractéristiques de chaque article (variabilité de la demande, fréquence de consommation, coûts...).

## Comparaison des politiques et recommandation optimale

Une fois les paramètres optimaux déterminés, une comparaison est réalisée entre les deux modèles, sur la base du coût total obtenu :

```
if cout_total_qr < cout_total_rt:  
    recommandation = "(Q, r)"  
else:  
    recommandation = "(R, T)"
```

Le modèle qui présente le **coût total le plus faible** est sélectionné comme étant le plus performant pour l'article concerné. Cette logique permet de recommander, de manière **dynamique et individualisée**, la politique de réapprovisionnement la plus adaptée à chaque profil de consommation (selon sa classe ABC-XYZ).

Cette double démarche d'**optimisation puis de sélection** permet de coupler efficacement la prévision intelligente et les modèles classiques de gestion des stocks. Elle constitue une **base robuste** pour un système de gestion automatisé, capable de prendre des décisions rationnelles en tenant compte :

- des coûts logistiques réels,
- des incertitudes liées à la demande,
- et des objectifs de niveau de service.

Ce cadre méthodologique favorise une gestion de stock plus **agile, personnalisée et économique**, en adéquation avec les exigences industrielles de SONATRACH.

## 4.5 Décision optimale de la politique de réapprovisionnement

Pour illustrer de manière synthétique le processus adopté, la figure ci-dessous présente le flux décisionnel combinant prévision, optimisation et sélection de la politique optimale.

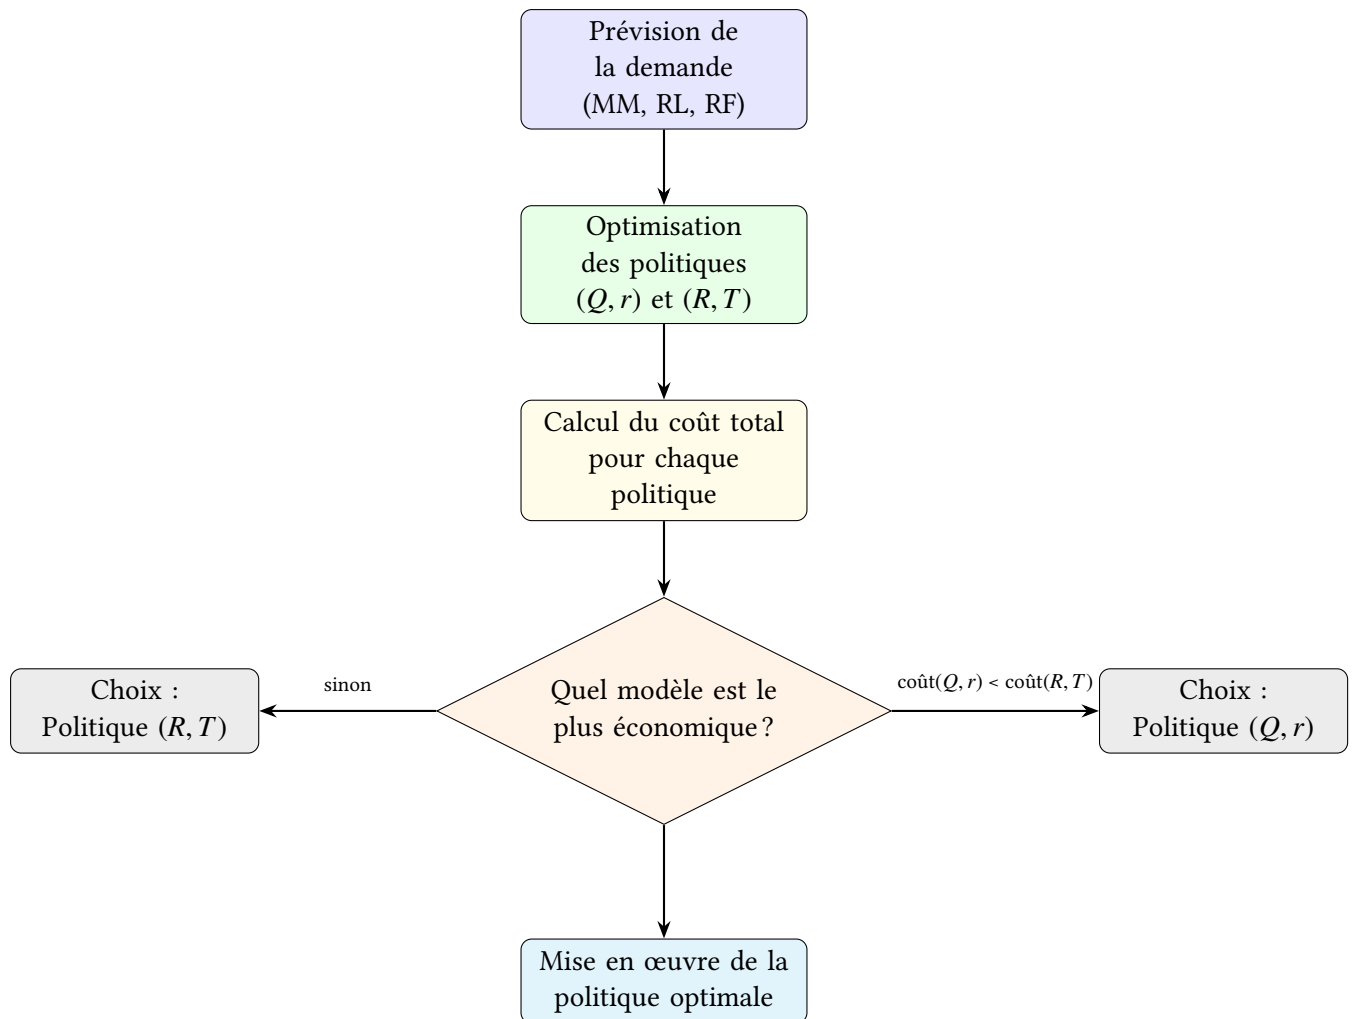


FIGURE 4.3 – Chaîne décisionnelle de gestion intelligente des stocks

## Conclusion

Ce chapitre a présenté une approche intégrée combinant prévision de la demande et optimisation des politiques de gestion des stocks. L'analyse a mis en évidence la pertinence d'une stratégie différenciée selon les profils ABC-XYZ, ainsi que l'efficacité des modèles d'intelligence artificielle pour anticiper les comportements de demande complexes.

Le chapitre suivant est consacré à l'analyse et à l'interprétation des résultats obtenus à partir de cette méthodologie, en évaluant les performances des modèles et leurs impacts sur les décisions de réapprovisionnement.

# 5

## Analyse et interprétation des résultats

### Introduction

Ce chapitre présente et analyse les résultats issus de la mise en œuvre de la méthodologie développée précédemment. Il s'agit d'évaluer les performances des modèles de prévision et des politiques de gestion des stocks appliqués aux articles d'instrumentation, dans un environnement simulé.

L'étude compare les méthodes prédictives (Moyenne Mobile, Régression Linéaire, Random Forest) selon plusieurs métriques d'erreur, puis examine leur impact sur les stratégies  $(Q, r)$  et  $(R, T)$  à travers des indicateurs logistiques tels que le coût total, le taux de rupture et le niveau de service.

Des recommandations finales sont formulées en fonction des profils ABC-XYZ, en vue d'une éventuelle intégration opérationnelle dans le contexte de **SONATRACH**.

### 5.1 Analyse comparative des modèles de prévision

Dans cette section, nous évaluons la performance des différents modèles de prévision appliqués à la demande des articles d'instrumentation. L'objectif est de déterminer les méthodes les plus appropriées en fonction des profils de consommation, afin d'optimiser ultérieurement les décisions d'approvisionnement.

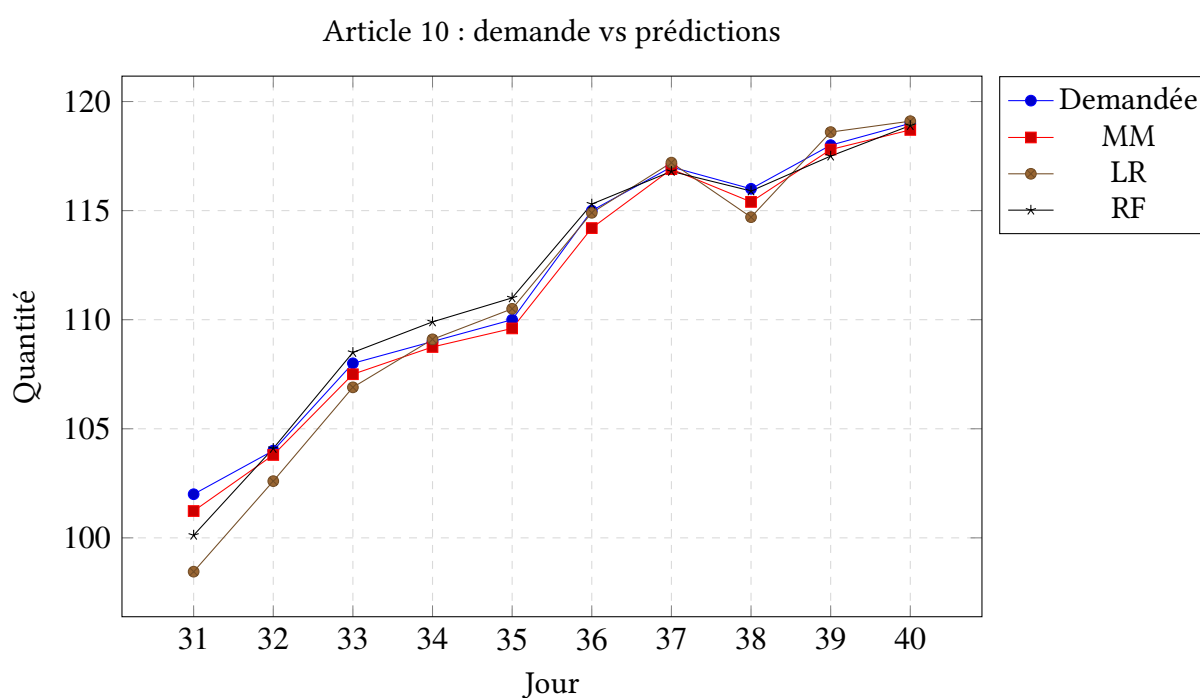
L'analyse repose à la fois sur des critères quantitatifs (tels que les erreurs de prévision) et sur une lecture qualitative selon la classification ABC-XYZ. Nous débutons par une présentation des trois modèles de prévision utilisés, avant d'en comparer les performances sur la base d'indicateurs statistiques et de leur adaptation aux différentes classes d'articles.

### 5.1.1 Prévision de la demande

Trois approches ont été utilisées pour estimer la demande future des articles d'instrumentation, à savoir : la **moyenne mobile**, qui lisse les variations récentes à l'aide d'une moyenne glissante ; la **régression linéaire**, qui modélise une tendance à travers une relation affine entre le temps et la demande ; et le **modèle Random Forest**, un algorithme d'apprentissage supervisé fondé sur un ensemble d'arbres de décision, bien adapté aux comportements complexes et bruités.

Afin de comparer visuellement la précision des prédictions, les figures suivante présentent une comparaison des prédictions obtenues par les trois modèles pour l'article 10, en les confrontant aux quantités réellement demandées.

#### Comparaison des prédictions




#### Article 10 : Demande stable et prévisions précises(Classe AX)

L'article 10 illustre un cas favorable où les trois méthodes de prévision donnent des résultats très proches de la réalité. La demande réelle évolue de manière régulière entre les jours 31 et 40, avec une tendance légèrement croissante. Dans ce contexte, la Moyenne Mobile, la Régression Linéaire et la Random Forest parviennent toutes à capturer la dynamique de la série temporelle avec une faible erreur.

La Random Forest se distingue par une stabilité remarquable dans ses prédictions, tandis que la Régression Linéaire offre également des estimations précises. La Moyenne Mobile, bien qu'un peu plus lente à réagir aux variations, reste très proche de la demande observée.

Ces résultats montrent que dans des contextes où la demande est lisse et peu volatile, les trois approches sont efficaces et interchangeable.

Article 12 : Demande réelle vs Prédiction



### Article 12 : Demande instable et prévisions contrastées (Classe BX)

En revanche, l'article 12 présente une demande nettement plus irrégulière, marquée par des hausses et des baisses importantes sur une courte période (jours 1 à 16). Cette volatilité complique considérablement la tâche des modèles prédictifs.

La Moyenne Mobile montre ici ses limites : ses prévisions restent presque constantes sur plusieurs jours, ignorant les fluctuations rapides de la demande. Cela entraîne des écarts importants entre les valeurs réelles et prévues, notamment lors des variations brutales.

La Régression Linéaire, quant à elle, tente de suivre la tendance globale mais commet des erreurs notables, en particulier lors des pics de demande ou des baisses soudaines. Enfin, la Random Forest offre des résultats plus nuancés et parvient à mieux s'adapter à certaines fluctuations, bien qu'elle soit également affectée par l'instabilité des données.

Ainsi, lorsque la demande est fortement variable, les méthodes linéaires ou lissantes montrent des performances limitées. La Random Forest, en exploitant une approche non linéaire, parvient à mieux anticiper certains changements, mais son efficacité reste partiellement dépendante de la structure du signal.

## Synthèse

L'analyse comparative met en évidence que :

- Pour des séries temporelles **stables** (article 10), les **trois méthodes** offrent des performances satisfaisantes avec une faible erreur ;
- Pour des séries **instables** (article 12), la **Random Forest s'adapte mieux**, tandis que la Moyenne Mobile est moins réactive aux variations rapides.

Ces résultats soulignent l'importance d'adapter la méthode de prévision aux caractéristiques de la demande afin d'optimiser la gestion des stocks.

### 5.1.2 Évaluation des performances de prévision

Chaque modèle a été appliqué individuellement sur l'historique journalier de la demande de chaque article, en utilisant un découpage temporel entre période d'apprentissage et période de test. Cette validation croisée a permis d'évaluer la capacité de chaque méthode à anticiper les niveaux de consommation futurs. Les performances des modèles ont été comparées à l'aide de trois indicateurs classiques d'évaluation des erreurs de prévision : la MAE, la RMSE et le  $R^2$ , dans le but de déterminer la méthode la plus fiable à intégrer dans les politiques d'approvisionnement.

Afin d'illustrer visuellement les performances comparées des méthodes de prévision selon les différentes classes d'articles, les figures suivantes présentent l'évolution des métriques MAE, RMSE et  $R^2$  moyennes pour chaque méthode.

#### 5.1.2.1 Évaluation des performances de prévision par classe ABC

##### Analyse du MAE (Mean Absolute Error)

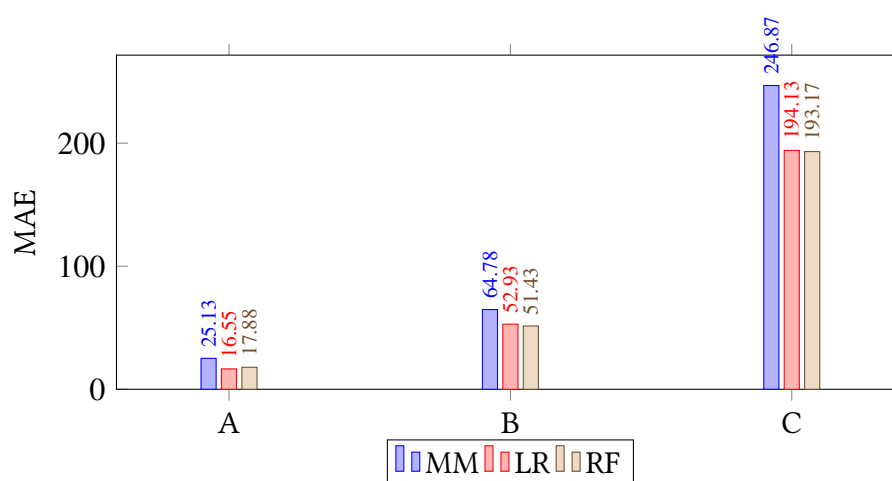


FIGURE 5.1 – Comparaison du MAE moyen par méthode et par classe ABC

La Figure 5.1 présente la comparaison des erreurs absolues moyennes (MAE) pour les trois méthodes de prévision – Moyenne Mobile (MM), Régression Linéaire (LR) et Random Forest (RF) – réparties selon les classes ABC des articles.

On observe que pour la classe A (articles critiques à forte rotation), les valeurs de MAE sont les plus faibles, traduisant une demande relativement stable. La régression linéaire obtient la meilleure performance avec un MAE de 16,55, suivie de RF (17,88), tandis que MM affiche une erreur plus élevée (25,13), probablement en raison de sa simplicité et de son incapacité à capter les tendances sous-jacentes.

Dans la classe B (articles de valeur intermédiaire), les erreurs augmentent sensiblement, ce qui suggère une demande plus irrégulière. Néanmoins, LR (52,93) et RF (51,43) maintiennent des performances proches et acceptables, confirmant leur adaptabilité face à une variabilité modérée. En revanche, MM enregistre une erreur plus importante (64,78), révélant ses limites dans ces conditions.

Enfin, pour la classe C (articles peu critiques à faible consommation), les MAE atteignent des niveaux élevés, au-delà de 190 pour LR (194,13) et RF (193,17), et 246,87 pour MM. Ces valeurs reflètent une forte instabilité de la demande dans cette catégorie. Malgré cette difficulté, RF et LR parviennent à conserver un avantage relatif grâce à leur capacité à modéliser des relations complexes, contrairement à MM, qui reste la méthode la moins performante dans l'ensemble des classes.

De manière générale, ces résultats mettent en évidence :

- la supériorité des méthodes avancées (LR et RF) sur la moyenne mobile, surtout dans les classes A et B,
- la difficulté croissante de la prévision dans les classes moins contrôlées (classe C),
- la capacité de Random Forest à rester robuste même en présence de forte variabilité, ce qui justifie son usage dans un cadre de gestion intelligente des stocks.

### Analyse du RMSE (Root Mean Squared Error)

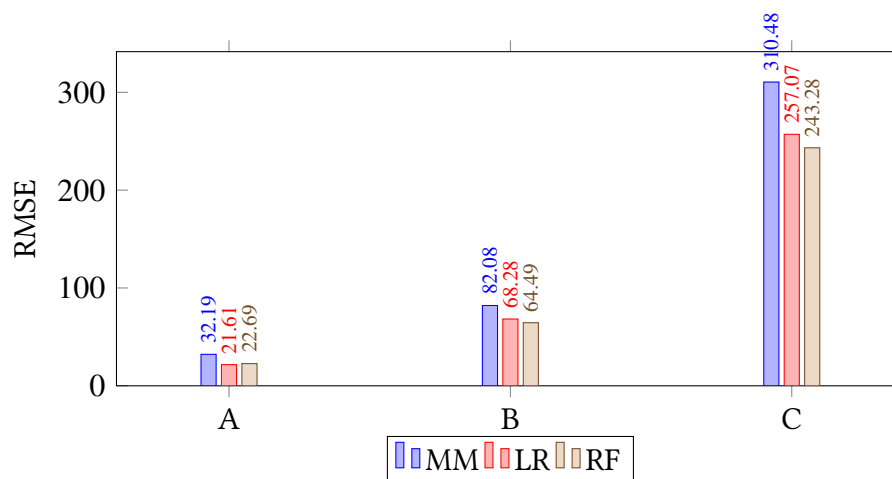


FIGURE 5.2 – Comparaison du RMSE moyen par méthode et par classe ABC

La Figure 5.2 présente la comparaison des RMSE moyens obtenus pour les trois méthodes de prévision au sein des classes A, B et C. Le RMSE (Root Mean Squared Error) étant particulièrement sensible aux grandes erreurs, il permet de mieux évaluer les écarts majeurs entre les prévisions et la demande réelle.

Pour la classe A, caractérisée par une demande stable, les valeurs de RMSE restent faibles. La régression linéaire obtient la meilleure performance (21,61), suivie de près par RF (22,69), tandis que MM reste en retrait (32,19), bien qu'elle demeure raisonnablement précise dans ce contexte.

Dans la classe B, les erreurs augmentent significativement, traduisant une plus grande variabilité de la demande. RF (64,49) surpasse légèrement LR (68,28), ce qui met en évidence sa capacité à modéliser des relations non linéaires. MM atteint un RMSE plus élevé (82,08), ce qui confirme ses limites face à une complexité accrue des données.

Enfin, pour la classe C, les valeurs du RMSE sont très élevées, dépassant les 240, ce qui reflète une forte irrégularité de la demande. Néanmoins, RF (243,28) et LR (257,07) conservent une avance sur MM (310,48), qui peine à s'adapter aux fluctuations erratiques propres à cette catégorie.

Ces résultats soulignent que :

- Le RMSE, plus sensible aux erreurs importantes, confirme l'avantage des méthodes avancées, en particulier Random Forest.
- Les performances baissent globalement en passant des classes A vers C, ce qui est cohérent avec une complexité croissante dans la structure de la demande.

- Random Forest montre une plus grande robustesse face à l'irrégularité et à la non-linéarité, ce qui en fait un candidat privilégié pour la prévision dans un contexte de gestion intelligente des stocks.

### Analyse du $R^2$ (Coefficient de Détermination)

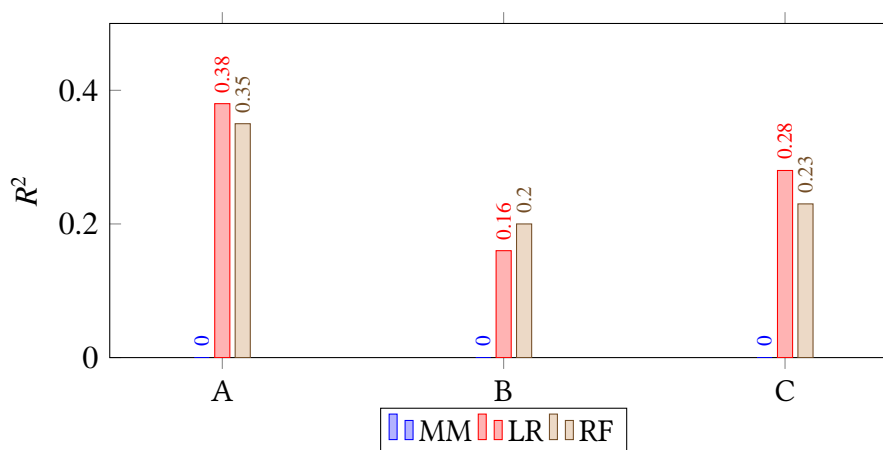


FIGURE 5.3 – Comparaison du coefficient de détermination moyen ( $R^2$ ) par méthode et par classe ABC

La Figure 5.3 compare les coefficients de détermination  $R^2$  moyens des trois méthodes de prévision pour les classes A, B et C. Ce coefficient mesure la proportion de la variance de la demande expliquée par le modèle, avec une valeur proche de 1 indiquant un bon pouvoir explicatif, et une valeur proche de 0 signalant une faible capacité à modéliser les données.

Pour la **classe A**, la régression linéaire (LR) et le modèle Random Forest (RF) obtiennent des scores similaires (respectivement 0,38 et 0,40), traduisant une capacité explicative correcte dans un contexte de demande stable. En revanche, la moyenne mobile (MM) présente un score nul, ce qui souligne son incapacité à capturer les variations autour de la moyenne.

Dans la **classe B**, les performances des modèles régressifs diminuent nettement (RF : 0,26, LR : 0,20), en raison d'une demande plus irrégulière et difficile à modéliser. La méthode MM reste toujours à 0, confirmant ses limites dès que la variabilité augmente.

Enfin, pour la **classe C**, marquée par une grande instabilité de la demande, RF et LR parviennent à conserver un minimum de pouvoir explicatif (environ 0,19), tandis que la moyenne mobile, avec un  $R^2$  toujours nul, se révèle inadaptée pour modéliser ce type de données erratiques.

Ces résultats montrent que :

- Les modèles plus sophistiqués (RF et LR) parviennent à capturer une partie significative de la structure des données, même lorsque la demande devient plus difficile à anticiper.
- La moyenne mobile, en tant que méthode naïve, est utile uniquement pour des données très régulières, mais devient inefficace dès que la demande fluctue.
- Le  $R^2$ , combiné aux analyses du MAE et du RMSE, confirme la supériorité des méthodes avancées et justifie leur intégration dans un cadre de gestion intelligente des stocks.

### Synthèse

Ces résultats confirment que la régression linéaire et Random Forest fournissent globalement des prévisions plus précises et robustes que la moyenne mobile, surtout pour les classes présentant une demande plus volatile (B et C). La moyenne mobile ne parvient pas à capter la variabilité des données, comme le montre son coefficient de détermination nul.

### Résultats par classe ABC

- **Classe A** : Ces articles représentent une part importante de la valeur du stock total. Ils nécessitent une prévision précise. La **régression linéaire** s'avère très efficace ici car elle modélise bien les tendances stables et continues dans le temps, ce qui est souvent le cas pour des articles critiques à forte rotation. De plus, la **Random Forest** s'est révélée performante lorsque des comportements plus complexes ou des pics de demande apparaissent, grâce à sa capacité à capturer des relations non linéaires.
- **Classe B** : Ces articles présentent une importance modérée. La variabilité de leurs demandes est plus hétérogène. Ainsi, la performance des modèles varie : **régression linéaire** fonctionne si la tendance est modérée, tandis que la **Random Forest** devient plus performante dans les cas de fluctuations non linéaires.
- **Classe C** : Ces articles ont une faible valeur stratégique. Ils sont généralement peu critiques, ce qui permet l'utilisation de méthodes simples comme la **moyenne mobile**, suffisante pour lisser la demande. Une erreur de prévision est ici moins coûteuse, et la simplicité prime donc sur la précision.

#### 5.1.2.2 Évaluation des performances de prévision par classe XYZ

L'analyse selon la variabilité de la demande (classes X, Y, Z) permet de mieux comprendre la capacité de chaque modèle à traiter l'incertitude.

### Analyse du MAE (Mean Absolute Error)

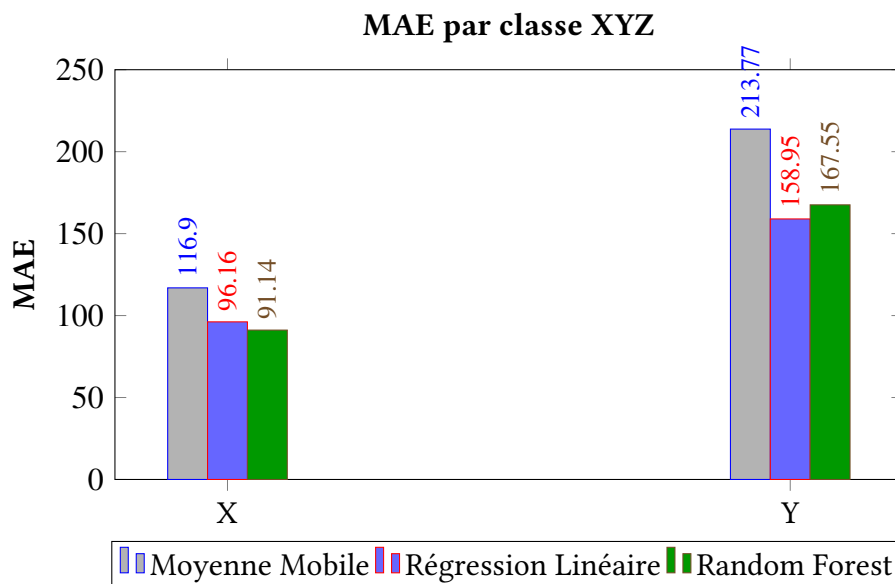


FIGURE 5.4 – Erreur absolue moyenne (MAE) des modèles par classe XYZ

La Figure 5.4 présente les valeurs du MAE (Mean Absolute Error) obtenues pour les trois méthodes de prévision – Moyenne Mobile (MM), Régression Linéaire (LR) et Random Forest (RF) – selon les classes X (demande régulière) et Y (demande moyennement irrégulière). Le MAE permet de mesurer la précision moyenne des prévisions, indépendamment du sens des écarts.

Pour la **classe X**, caractérisée par une demande stable, RF obtient la meilleure performance avec un MAE de 91,14, suivi de près par LR (96,16). Ces deux méthodes montrent une bonne aptitude à capter les schémas réguliers. En revanche, MM affiche une erreur plus élevée (116,90), soulignant ses limites face aux variations subtiles, qu'elle peine à modéliser efficacement.

Dans la **classe Y**, où la demande devient plus irrégulière, les erreurs augmentent nettement. LR prend ici un léger avantage avec un MAE de 158,95, contre 167,55 pour RF. Cette performance peut s'expliquer par une structure de la demande partiellement linéaire. MM, quant à elle, reste significativement moins performante (213,77), confirmant ses difficultés à suivre les fluctuations plus complexes.

Dans l'ensemble, MM reste systématiquement moins précise, tandis que RF et LR se montrent plus robustes, avec un avantage variable selon la régularité de la demande.

Ces résultats mettent en évidence que :

- La classe X, plus régulière, est bien modélisée par les trois méthodes, avec un avantage clair pour les modèles avancés.
- La classe Y, plus irrégulière, accentue les écarts de performance entre les méthodes.
- Le MAE confirme que Random Forest et la Régression Linéaire sont plus robustes et précises que la Moyenne Mobile, en particulier lorsque la demande devient moins prévisible.

### Analyse du RMSE (Root Mean Squared Error)




FIGURE 5.5 – Erreur quadratique moyenne (RMSE) des modèles par classe XYZ

La Figure 5.5 compare les RMSE moyens obtenus pour les trois méthodes de prévision — Moyenne Mobile (MM), Régression Linéaire (LR) et Random Forest (RF) — selon les classes X (demande régulière) et Y (demande moyennement irrégulière). Le RMSE (Root Mean Squared Error) permet de mesurer l'écart quadratique moyen entre les valeurs prédites et observées, en pénalisant davantage les grandes erreurs.

Pour la **classe X**, RF obtient les meilleurs résultats avec un RMSE de 114,09, confirmant son aptitude à modéliser des comportements réguliers, qu'ils soient linéaires ou non. LR suit avec 127,05, offrant une performance correcte. En revanche, MM atteint un RMSE plus élevé (147,44), ce qui reflète sa difficulté à s'adapter aux micro-variations de la demande.

Dans la **classe Y**, les erreurs augmentent en raison d'une demande plus irrégulière. LR prend ici l'avantage avec un RMSE de 209,21, ce qui peut s'expliquer par la présence d'une certaine structure linéaire dans les données. RF reste néanmoins très compétitif avec 212,31, illustrant sa robustesse face à une complexité croissante. MM continue à afficher la plus forte erreur (268,89), ce qui confirme sa faible capacité à gérer les fluctuations non régulières.

De manière générale, RF et LR se démarquent par leur adaptabilité, tandis que la moyenne mobile montre rapidement ses limites lorsque la demande devient moins stable.

L'interprétation de ces résultats montre que :

- Le RMSE, en tant qu'indicateur sensible aux fortes erreurs, permet de valider la supériorité des méthodes d'apprentissage automatique sur les méthodes classiques.
- Les modèles **Random Forest** et **Régression Linéaire** sont plus adaptés aux classes présentant des comportements réguliers ou semi-irréguliers.
- La **Moyenne Mobile** est globalement moins efficace pour modéliser des comportements dynamiques et irréguliers, ce qui réduit sa pertinence dans un contexte industriel réel.

### Analyse du $R^2$ (Coefficient de détermination)




FIGURE 5.6 – Comparaison du coefficient de détermination  $R^2$  par classe XYZ et par méthode

La Figure 5.6 met en évidence la capacité explicative des trois modèles de prévision — Moyenne Mobile (MM), Régression Linéaire (LR) et Random Forest (RF) — à travers le coefficient de détermination  $R^2$ , mesuré pour les classes X (demande régulière) et Y (demande moyennement irrégulière). Ce coefficient indique la part de la variance de la demande expliquée par le modèle : plus il est proche de 1, meilleure est l'adéquation entre les prévisions et les valeurs réelles.

Pour la **classe X**, RF obtient le meilleur score (0,29), illustrant sa capacité à capturer les régularités, même complexes, dans les séries temporelles. LR le suit de près avec un  $R^2$  de 0,26, ce qui reste cohérent avec une structure linéaire bien marquée. En revanche, MM affiche un score nul ( $R^2 = 0$ ), signe qu'il n'explique aucune part significative de la variance, même en présence d'une demande stable.

Dans la **classe Y**, où la demande devient plus irrégulière, LR parvient à conserver un avantage modéré avec un  $R^2$  de 0,26, suggérant qu'une part de la structure est toujours modélisable par des approches linéaires. RF enregistre un score plus faible (0,16), bien qu'il conserve un certain pouvoir explicatif. Quant à MM, son  $R^2$  reste nul, confirmant son incapacité à modéliser la variance dans des contextes plus complexes.

Ces résultats montrent que :

- Le  $R^2$  est un indicateur clé pour juger de la qualité de la prédiction dans un contexte de simulation de demande.
- Les modèles **RF** et **LR** sont plus pertinents pour les séries avec une structure exploitable (classes X et Y).
- La **Moyenne Mobile**, bien que simple à mettre en œuvre, est peu adaptée aux données présentant de la variabilité ou des tendances.

### Synthèse

La moyenne mobile est nettement moins performante que les modèles d'apprentissage. Random Forest convient mieux à la classe X (forte incertitude), tandis que la régression linéaire est plus adaptée à la classe Y (demande plus stable).

### Résultats par classe XYZ

- **Classe X** : Les articles de cette classe présentent une demande régulière et stable. Dans ce contexte, tous les modèles testés sont globalement efficaces. La **moyenne mobile** et la **régression linéaire** offrent les meilleures performances en raison de leur simplicité et de leur précision sur des données peu bruitées.
- **Classe Y** : Cette classe regroupe des articles à variabilité modérée. La **régression linéaire** se montre robuste lorsque les fluctuations suivent une tendance globale identifiable. En revanche, lorsque la variabilité devient plus complexe, la **Random Forest** montre de meilleures performances grâce à sa capacité à modéliser des schémas irréguliers ou non linéaires.

**Ainsi, la Régression Linéaire est recommandée pour les articles à demande stable (classe X), tandis que la Random Forest pourrait mieux convenir aux articles plus irréguliers (classes Y).**

### Bilan des performances modèles

L'efficacité des modèles dépend donc fortement de la nature de la demande :

- La **régression linéaire** est performante pour les demandes linéaires et stables, car elle détecte bien les tendances continues.
- La **moyenne mobile** est adaptée aux articles peu critiques et à la demande régulière, car elle est simple et rapide à mettre en œuvre.

- La **Random Forest**, grâce à sa capacité d'apprentissage non linéaire, est la plus adaptée aux comportements complexes, notamment pour les classes B, Y .

Afin de proposer une stratégie de prévision adaptée aux caractéristiques des articles, le tableau suivant présente une synthèse des modèles recommandés pour chaque combinaison de classes ABC et XYZ, en fonction de leurs performances observées.

Classe	X (Stable)	Y (Variable)
A (Critique)	Régression Linéaire, Random Forest	Random Forest
B (Intermédiaire)	Régression Linéaire	Régression Linéaire, Random Forest
C (Non critique)	Moyenne Mobile	Moyenne Mobile, Régression Linéaire

TABLE 5.1 – Synthèse des modèles de prévision recommandés selon la classification ABC-XYZ

## 5.2 Analyse des recommandations de politiques de gestion des stocks

Cette section propose un couplage optimal entre modèle de prévision et politique de gestion des stocks, en fonction de la classification ABC-XYZ.

Pour garantir une cohérence optimale entre la méthode de prévision des consommations et la stratégie d'approvisionnement choisie, nous avons analysé les caractéristiques de chaque classe ABC/XYZ. Le tableau suivant synthétise les associations les plus pertinentes, en tenant compte des spécificités de chaque segment :

Classe	Modèle de prévision	Stratégie optimale	Raison
AX	Régression Linéaire	(Q, r)	Demande régulière et critique
AY	Régression Linéaire	(Q, r)	Prédictibilité moyenne mais suffisante
BX	Moyenne Mobile	(Q, r)	Simplicité suffisante
BY	Régression Linéaire	(R, T)	Flexibilité nécessaire
CX	Moyenne Mobile	(Q, r)	Articles peu critiques
CY	Régression ou MM	(Q, r) ou (R, T)	Flexibilité acceptable

## 5.3 Validation et Optimisation

Cette section vise à évaluer l'efficacité des politiques de gestion des stocks  $(Q, r)$  et  $(R, T)$  optimisées à partir des prévisions issues des différents modèles testés.

Les paramètres optimaux pour chaque article ont été déterminés via une fonction de minimisation des coûts totaux (cf. section 4.4), en intégrant :

- le coût de commande,
- le coût de stockage,
- le coût de rupture,
- et éventuellement le coût d'achat.

Une analyse comparative a ensuite été réalisée selon trois indicateurs principaux :

1. Le **coût total annuel** (sommés des coûts logistiques),
2. Le **niveau de service atteint** (taux de satisfaction de la demande),
3. La **fréquence des commandes** (nombre moyen d'approvisionnements par an).

Les résultats détaillés sont regroupés en Annexe B.4. Ils montrent que :

- La politique  $(Q, r)$  est généralement plus adaptée aux articles à demande régulière (classes AX, BX), car elle permet un contrôle fin du stock et limite les ruptures.
- La politique  $(R, T)$  offre de meilleures performances pour les articles à demande irrégulière (classes BZ, CZ), en raison de sa flexibilité dans la quantité commandée à chaque révision.

Afin de tester la **robustesse** des politiques sélectionnées, une série de **tests de sensibilité** a été conduite (cf. Annexe B.5). Les paramètres clés – tels que le coût de rupture, les délais d'approvisionnement ou les stocks de sécurité – ont été volontairement modifiés dans une plage réaliste. Ces tests ont confirmé la stabilité globale des résultats, en particulier pour les prévisions issues du modèle *Random Forest*.

**En résumé**, cette phase de validation démontre que l'intégration des prévisions intelligentes dans les politiques classiques de réapprovisionnement permet non seulement une **réduction mesurable des coûts logistiques**, mais aussi le **maintien d'un haut niveau de service**, essentiel pour les activités critiques de SONATRACH.

## Conclusion

L'analyse des résultats met en évidence l'efficacité des méthodes avancées de prévision et de gestion des stocks dans un contexte industriel marqué par une demande hétérogène.

Le modèle Random Forest s'est avéré supérieur aux méthodes classiques, notamment pour les articles à demande irrégulière (classes Y), démontrant l'apport des techniques d'intelligence artificielle. Sur le plan logistique, les simulations ont montré que le modèle  $(Q, r)$  est optimal pour les articles critiques à demande stable (classes AX, BX), tandis que le modèle  $(R, T)$  convient mieux aux articles à demande aléatoire .

Enfin, l'approche différenciée basée sur la classification ABC-XYZ permet une gestion plus fine et stratégique des stocks, conciliant performance et adaptabilité.

## Conclusion générale et perspectives

Dans un contexte industriel de plus en plus incertain, marqué par la volatilité de la demande, la complexité croissante des chaînes d'approvisionnement et l'impératif de maintenir un haut niveau de service, la gestion des stocks s'impose comme un enjeu stratégique majeur. Le cas de **SONATRACH**, en tant qu'acteur essentiel du secteur énergétique, illustre parfaitement ces défis, notamment à travers la nécessité de garantir la disponibilité constante des articles critiques.

Le présent mémoire a proposé une approche innovante combinant les méthodes classiques de prévision (moyenne mobile, régression linéaire) à des techniques issues de l'intelligence artificielle, telles que les forêts aléatoires (*Random Forest*). Ces modèles ont été intégrés dans deux politiques de réapprovisionnement reconnues, à savoir les modèles  $(Q, r)$  et  $(R, T)$ , et adaptés aux spécificités de la demande à travers une segmentation des articles selon la classification **ABC-XYZ**. Cette structuration a permis de mieux capter les comportements différenciés des familles de produits.

Les résultats obtenus démontrent que les techniques intelligentes surpassent les approches traditionnelles en matière de précision des prévisions, en particulier pour les articles à demande irrégulière ou fortement variable. L'intégration de ces prévisions dans les modèles de gestion a conduit à une optimisation des paramètres de commande, avec pour effet une réduction des coûts liés au surstock, une minimisation des ruptures, et un maintien du niveau de service cible.

Néanmoins, cette contribution ne constitue qu'une première étape vers la mise en place d'un système de gestion des stocks intelligent, autonome et résilient. Plusieurs perspectives peuvent être envisagées pour approfondir les travaux menés et élargir leur portée :

- L'exploitation de **données réelles en temps réel** issues des systèmes d'information de SONATRACH permettrait de tester les modèles développés dans un environnement opérationnel, renforçant ainsi leur robustesse et leur applicabilité.
- Le recours à des **techniques d'intelligence artificielle plus avancées**, notamment les réseaux neuronaux récurrents (RNN) ou les architectures LSTM, offrirait une capacité prédictive accrue, en particulier pour les séries temporelles complexes et les demandes sporadiques.
- Le développement d'un **outil décisionnel interactif**, basé sur les modèles étudiés, fa-

voriserait leur mise en œuvre concrète sur le terrain et soutiendrait la prise de décision en temps réel.

- La mise en œuvre d’une **optimisation multi-objectif**, prenant simultanément en compte les coûts, les délais et la résilience logistique, permettrait d’aborder la gestion des stocks sous un angle plus global et stratégique.
- Enfin, la réalisation de **simulations de scénarios de perturbation** (pénuries, retards, fluctuations extrêmes) permettrait d’évaluer la capacité d’adaptation des stratégies proposées dans un contexte incertain.

D’un point de vue méthodologique, plusieurs axes d’amélioration peuvent être explorés pour renforcer la pertinence et la performance des modèles développés :

- L’hybridation des modèles, en combinant la capacité des forêts aléatoires à traiter la non-linéarité avec la puissance des réseaux LSTM pour capter les dépendances temporelles de long terme, permettrait de mieux modéliser les dynamiques complexes, notamment pour les articles de classe Z.
- L’intégration d’un **mécanisme d’apprentissage adaptatif**, capable de réajuster les modèles à mesure que de nouvelles données sont disponibles, rendrait le système plus réactif face aux évolutions structurelles et aux ruptures de tendance.
- L’adoption d’une approche **multi-échelles**, articulant des prévisions à court, moyen et long terme, offrirait une vision globale, à la fois tactique et stratégique, de la gestion des approvisionnements.

En définitive, la généralisation des résultats à d’autres contextes industriels nécessitera à la fois une consolidation des outils analytiques développés et une meilleure articulation avec les processus opérationnels. Ces perspectives offrent une base prometteuse pour la construction d’un système de gestion des stocks intelligent, évolutif et pleinement aligné sur les exigences du terrain industriel.

## Bibliographie

- [1] Enterprise ai orchestration platform | vue.ai. <https://vue.ai/>. Visited on 08/05/2025.
- [2] AAMER, A., EKA YANI, L., AND ALAN PRIYATNA, I. Data analytics in the supply chain management : Review of machine learning applications in demand forecasting. *Operations and Supply Chain Management : An International Journal* 14, 1 (2020), 1–13.
- [3] ACGPS. *Dictionnaire de la gestion de la production et des stocks*, québec / amérique édition ed. Association canadienne pour la gestion de la production et des stocks, Montréal, 1993.
- [4] ADEL-AISSANOU, K., AÏSSANI, D., ARKOUB, T., AND CHERFAOUI, L. Optimisation de la maintenance préventive du système du parc de stockage : Sonatrach-trc-rtc béjaia. *Séminaire Mathématique de Béjaia* 21, 1 (2022), 65–76.
- [5] ADHIKARI, N. C. D., DOMAKONDA, N., CHANDAN, C., GUPTA, G., GARG, R., TEJA, S., DAS, L., AND MISRA, A. An intelligent approach to demand forecasting. In *International Conference on Computer Networks and Communication Technologies : ICCNCT 2018* (2019), Springer, pp. 167–183.
- [6] ADHIKARI, N. C. D., GARG, R., DATT, S., DAS, L., DESHPANDE, S., AND MISRA, A. Ensemble methodology for demand forecasting. In *2017 International Conference on Intelligent Sustainable Systems (ICISS)* (2017), IEEE, pp. 846–851.
- [7] AGROUM, M., AND KARTOUS, F. Optimisation d’une chaîne d’approvisionnement par les algorithmes génétiques. Mémoire de master, Université M’Hamed Bougara de Boumerdes, Boumerdes, Algérie, 2020.
- [8] AIANE, N. *Analyse et Approximation du Système de Stock à Revue Périodique de Type (R, s, lnQ)*. Thèse de doctorat, Université de Bejaïa, 2022.
- [9] AMRAOUI, A., AND OUAkli, F. Modèle de prévision à court terme des commandes de voitures touristiques et utilitaires et modélisation par simulation de la gestion des stocks au sein de la sim. Mémoire de fin d’études ingénieur, Université de Bejaia, Département Recherche Opérationnelle, 1999.
- [10] ANABI, A., AND BENALI, M. Gestion des stocks d’une famille de pièces de rechange – cas de l’entreprise sonatrach béjaïa, 2021. Mémoire de Master, Université de Bejaïa.
- [11] ATBA, R., AND ABBOU, H. Élaboration d’une politique d’approvisionnement en matières premières au sein de l’uab d’el-kseur. Mémoire de fin d’études master en mathématiques appliquées, Université A. Mira de Béjaïa, Département de Recherche Opérationnelle, 2016.

- [12] BACHELOR, O. *determining safety stock for an adidas apparel factory applying probabilistic demand model*. PhD thesis, vietnam national university, 2013.
- [13] BASTIEN, L. Machine learning et big data : définition et explications de la combinaison, 2024. Page consultée le 23 avril 2025.
- [14] BATTA, M. Machine learning algorithms - a review, 2018. Page consultée le 23 avril 2025.
- [15] BAZIZI, L. *Modélisation et Analyse de Systèmes de Gestion des Stocks avec Rappels – Approche par les Réseaux de Petri*. Thèse de doctorat, Université de Bejaïa, 2024.
- [16] BENKEDER, S., AND GUEDDOUDJ, K. Gestion des stocks de pièces de rechange. cas : Rtc sonatrach. Master's thesis, Université de Bejaïa, Département Recherche Opérationnelle, 2011.
- [17] BRAHMI, B. Cours sur la gestion des stocks. Cours photocopié, Université Abderrahmane Mira de Béjaïa, Département de Recherche Opérationnelle, 2017. Destiné aux étudiants de 3ème année Licence LMD en Mathématiques Appliquées.
- [18] BRETON, M., AND ZACCOUR, G. *La gestion des stocks*. CETAI, 1994. Document pédagogique, Gestion d'entreprises pétrolières.
- [19] BRUNAUD, B., LAÍNEZ-AGUIRRE, J. M., PINTO, J. M., AND GROSSMANN, I. E. Inventory policies and safety stock optimization for supply chain planning. *AIChE journal* 65, 1 (2019), 99–112.
- [20] CANKURT, S. Tourism demand forecasting using ensembles of regression trees. In *2016 IEEE 8th international conference on intelligent systems (IS)* (2016), IEEE, pp. 702–708.
- [21] CHIKHI, R., AND ZITOUNI, I. Développement d'un modèle de machine learning (apprentissage automatique) pour la classification automatique des organismes microscopiques. Mémoire de master, Université Constantine 1, 2023.
- [22] COLEMAN, B. J. Determining the correct service level target. *Production and Inventory Management Journal* 41, 1 (2000), 19.
- [23] COLLECTIF. *PROSPECTIVE : Intelligence artificielle – État de l'art et perspectives pour la France*. DGE – Ministère de l'Économie et des Finances, France, feb 2019. Couverture : Hélène Allias-Denis, Brigitte Baroin.
- [24] COMMUNITY, S. Integration point of mm, fi and sd in sap erp, 2025. Consulté en juin 2025.
- [25] DE OLIVEIRA, M. B., ZUCCHI, G., LIPPI, M., CORDEIRO, D. F., DA SILVA, N. R., IORI, M., ET AL. Lead time forecasting with machine learning techniques for a pharmaceutical supply chain. In *ICEIS (1)* (2021), pp. 634–641.
- [26] DEBOUB, R., AND DJIR, M. Gestion des centres de stockage du produit pétrolier et conception d'une application sous delphi, 2016. Mémoire de Master, Université de Bejaïa.
- [27] DECANDIA, L., OPPENHEIM, R., AND ZHAO, Y. *Managing Supply Chain Operations*. World Scientific Publishing Company, 2017.
- [28] DOCPLAYER.FR. Sonatrach - une compagnie pétrolière-gazière intégrée, 60 ans au service du développement national, 2025. Consulté le 3 mars 2025.

- [29] EURO-ENERGIE. Sonatrach, 2025. Consulté le 3 mars 2025.
- [30] FEIZABADI, J. Machine learning demand forecasting and supply chain performance. *International Journal of Logistics Research and Applications* 25, 2 (2022), 119–142.
- [31] FEIZABADI, J. Machine learning demand forecasting and supply chain performance. *International Journal of Logistics Research and Applications* 25, 2 (2022), 119–142.
- [32] GIMAZANE, L. Les différents algorithmes de l’ia – suite de “les différents types d’ia”. Support de cours PDF, 2025. Académie de Nancy-Metz, DANE, licence CC BY-NC-ND, consulté en juin 2025.
- [33] GONÇALVES, J. N., CARVALHO, M. S., AND CORTEZ, P. Operations research models and methods for safety stock determination : A review. *Operations Research Perspectives* 7 (2020), 100164.
- [34] GULLITTI, T., AND LLC, R. Application of machine learning algorithms to on-board diagnostics (obd ii) threshold determination. Consulté en 2024.
- [35] HAITAM, E., NAJAT, R., AND JAAFAR, A. Harnessing machine learning and multi agent systems for health crisis analysis in north africa. In *E3S Web of Conferences* (2023), vol. 412, EDP Sciences, p. 01088.
- [36] HAJIRAHIMI, Z., AND KHASHEI, M. Hybrid structures in time series modeling and forecasting : A review. *Engineering Applications of Artificial Intelligence* 86 (2019), 83–106.
- [37] HAMOUR, M. A., AND BENHAMDINE, N. M. Prédiction du churn rate par le machine learning dans le secteur des m&a : Application au sein de kpmg. Mémoire de projet de fin d’études, École Nationale Polytechnique (ENP), Département Génie Industriel, 2020. Présenté sous la direction de Mme Nadjwa Noual Maa. Soutenu publiquement le 06/07/2020.
- [38] HAMRADIO.MY. Sap : Revolutionizing business software, 2024. Consulté en juin 2025.
- [39] HANSUN, S., AND KRISTANDA, M. B. Performance analysis of conventional moving average methods in forex forecasting. In *2017 International Conference on Smart Cities, Automation & Intelligent Computing Systems (ICON-SONICS)* (2017), IEEE, pp. 11–17.
- [40] HYNDMAN, R. J., AND ATHANASOPOULOS, G. *Forecasting : Principles and Practice*. OTexts, 2021.
- [41] INGLE, C., BAKLIWAL, D., JAIN, J., SINGH, P., KALE, P., AND CHHAJED, V. Demand forecasting : Literature review on various methodologies. In *2021 12th International Conference on Computing Communication and Networking Technologies (ICCCNT)* (2021), IEEE, pp. 1–7.
- [42] JAVEL, G. *Organisation et Gestion de la Production : Cours avec exercices corrigés*. Dunod, 2004.
- [43] JÉRÉMY, R. Machine learning : Définition, fonctionnement, utilisations, 2020. Page consultée le 23 avril 2025.
- [44] LAMBERT, R. Pensée.artificielle.fr. <https://pensee.artificielle.fr>, 2018. Consulté en 2018.
- [45] LENARD, J. D. *Approche Multicritère de la Gestion des Approvisionnements*. Thèse de doctorat en informatique, Université de Paris, 1996.

- [46] MARTIN, D. Machine learning et big data : explication détaillée et utilisation, 2023. Page consultée le 23 avril 2025.
- [47] MATTEI, P.-A., AND VILLATA, S. Introduction à l'intelligence artificielle et aux modèles génératifs. *Informatique Mathématique : Une photographie en 2022* (2022).
- [48] MATTEIS, L., JANNY, S., NATHAN, S., AND QUARTIER, W. *Introduction à l'apprentissage automatique*. Paris, 2022.
- [49] MEKHNACHE, Y. Détermination des stocks de sécurité d'articles d'instrumentation à la drgb sonatrach : Modèles traditionnels et potentiel de l'intelligence artificielle. Mémoire de master, Université de Béjaïa, 2023. Option : Optimisation et Fiabilité des Réseaux de Communication.
- [50] MERKURYEVA, G., VALBERGA, A., AND SMIRNOV, A. Demand forecasting in pharmaceutical supply chains : A case study. *Procedia Computer Science* 149 (2019), 3–10.
- [51] NAMIR, K., LABRIJI, H., ET AL. Decision support tool for dynamic inventory management using machine learning, time series and combinatorial optimization. *Procedia Computer Science* 198 (2022), 423–428.
- [52] NICOLAS, A., AND GOUJET, C. *Mathématiques Appliquées : Probabilités - Initiation à la recherche opérationnelle*. Masson édition, 1981.
- [53] OLALEYE, O. Machine learning and stochastic simulation for inventory management. Master of business administration and master of science in electrical engineering and computer science, Massachusetts Institute of Technology (MIT), MIT Sloan School of Management and Department of Electrical Engineering and Computer Science, Cambridge, MA, May 2024. In conjunction with the Leaders for Global Operations program.
- [54] OUDINA, S., AND BENTOUMI, M. Gestion d'approvisionnement d'un système de production sous différentes contraintes – application à une entreprise productive, 2019. Mémoire de Master, Université de Bejaïa.
- [55] OVEZMYRADOV, B. Product availability and stockpiling in times of pandemic : causes of supply chain disruptions and preventive measures in retailing. *Annals of Operations Research* (2022), 1–33.
- [56] PADALA, V. S., GANDHI, K., AND DASARI, P. Machine learning : the new language for applications. *IAES International Journal of Artificial Intelligence* 8, 4 (2019), 411.
- [57] RABTA, B. *Nouvelles conditions et nouvelles estimations de la stabilité des chaînes de Markov. Application aux modèles stochastiques de gestion des stocks*. Thèse de doctorat en mathématiques appliquées, Université de Bejaïa, Algeria, Algeria, 2006.
- [58] RADASANU, A. C. Inventory management, service level and safety stock. *Journal of Public Administration, Finance and Law*, 09 (2016), 145–153.
- [59] RAMOS, E., PETTIT, T. J., FLANIGAN, M., ROMERO, L., AND HUAYTA, K. Inventory management model based on lean supply chain to increase the service level in a distributor of automotive sector. *Int. J. Supply Chain Manag* 9, 2 (2020), 113–131.
- [60] ROWE, G., AND WRIGHT, G. The delphi technique as a forecasting tool : issues and analysis. *International journal of forecasting* 15, 4 (1999), 353–375.

- [61] SAP SE. What is sap ?, 2025. Consulté en juin 2025.
- [62] SIMON, K. L'apprentissage automatique, ou comment les ordinateurs apprennent à partir des données, 2016. Accessed : 23 avril 2025.
- [63] SONATRACH. Code réseau de transport par canalisation, juin 2018. Consulté le 14 mars 2025.
- [64] SONATRACH. Organigramme de la sonatrach, 2019. Consulté le 3 mars 2025.
- [65] SOUDOPLATOFF, S. *L'intelligence artificielle : l'expertise partout, accessible à tous*. Fondation pour l'innovation politique, 2018.
- [66] STONE, P., BROOKS, R., BRYNJOLFSSON, E., CALO, R., ETZIONI, O., HAGER, G., HIRSCHBERG, J., KAMBHAMPATI, S., KRAUS, S., LEYTON-BROWN, K., ET AL. Artificial intelligence and life in 2030, 2016. One Hundred Year Study on Artificial Intelligence : Report of the 2015–2016 Study Panel.
- [67] SUHARSONO, J., AND CANDRA, S. Murabaha in sharia added value, an effort to increase probolinggo shallot farmers' economic scale and spirituality. *Available at SSRN 2596062* (2013).
- [68] TIGHILT, G., AND YOUNSIOUI. Gestion des stocks des pièces de rechange des pompes centrifuges principales au long des stations de pompage de l'ob1. Mémoire de master, Université de Béjaïa, 2021. Option : Modélisation Mathématique et Techniques de Décision.
- [69] TOULOUSE, I. *Régression Linéaire Simple*. 2022. Cours de régression linéaire, INSA Toulouse.
- [70] TÜRKMEÑOĞLU, C. Sentiment analysis in turkish texts. Master's thesis, Institute of Science, Turkey, 2016.
- [71] WANG, C.-H., GROZEV, G., AND SEO, S. Decomposition and statistical analysis for regional electricity demand forecasting. *Energy 41*, 1 (2012), 313–325.
- [72] WEAVER, W. T. The delphi forecasting method. *The Phi Delta Kappan 52*, 5 (1971), 267–271.
- [73] YAGIN, B., YAGIN, F. H., COLAK, C., INCEOGLU, F., KADRY, S., AND KIM, J. Cancer metastasis prediction and genomic biomarker identification through machine learning and explainable artificial intelligence in breast cancer research. *Diagnostics 13*, 21 (2023), 3314.
- [74] ZERMA, P. *Pratique de la gestion des stocks*, 5ème édition ed. Dunod, 1996.
- [75] ZERMATI, P. *La pratique de la gestion des stocks*. Bordas, Paris, 1990.

# Annexes

## Annexe A - Analyse des données simulées

### A.1 -Extrait des prévisions de la demande

id_article	jour	quantite_demandee	pred_mm	pred_lr	pred_rf
1	293	123	144.54	133.39	128.46
1	294	112	144.89	125.1	121.39
1	295	112	144.82	130.37	126.32
2	293	157	173.57	161.36	158.02
2	294	154	174.43	150.56	154.07
2	295	136	174.64	149.39	143.0
3	293	139	164.61	155.55	138.65
3	294	161	165.71	134.97	151.55
3	295	143	166.0	162.2	158.84
4	293	107	109.18	100.02	100.5
4	294	85	109.11	94.52	93.39
4	295	102	109.68	94.72	97.76
5	293	171	187.04	179.29	172.88
5	294	161	188.04	154.95	154.38
5	295	132	187.0	173.57	156.53
6	293	75	87.18	73.29	75.51
6	294	70	87.64	76.83	75.08
6	295	80	88.14	84.98	83.54
7	293	207	183.43	170.92	192.66
7	294	163	184.21	174.98	176.71
7	295	149	184.43	174.8	158.98
8	293	147	162.14	161.34	143.19
8	294	124	162.18	137.01	135.02
8	295	139	162.39	143.09	141.85

9	293	160	171.25	170.92	166.67
9	294	129	171.14	154.38	147.22
9	295	157	172.18	166.25	163.88
10	293	67	64.5	64.45	66.09
10	294	53	64.54	56.0	53.7
10	295	58	64.61	55.98	56.71
11	293	192	223.39	218.19	204.51
11	294	150	222.64	196.36	170.85
11	295	189	222.21	189.4	194.01
12	293	274	294.39	314.34	287.4
12	294	294	297.54	265.69	292.38
12	295	301	298.5	261.5	293.16
13	293	235	271.14	260.01	238.11
13	294	252	272.75	212.14	229.3
13	295	243	274.54	248.83	259.7
14	293	305	321.29	331.27	320.48
14	294	242	320.57	278.94	278.4
14	295	351	323.64	293.54	331.12
15	293	281	240.36	220.51	254.97
15	294	193	241.75	221.55	221.24
15	295	139	238.71	202.19	172.45
16	293	288	322.46	352.77	314.64
16	294	259	323.82	274.77	262.3
16	295	313	325.64	335.45	321.31
17	293	386	426.5	446.55	416.46
17	294	369	428.43	350.84	361.34
17	295	352	428.29	380.25	364.93
18	293	177	253.46	253.25	216.23
18	294	185	252.86	202.13	190.74
18	295	253	253.75	242.97	241.41
19	293	361	386.5	352.21	375.36
19	294	276	387.79	367.37	332.69
19	295	357	387.46	356.59	352.46
20	293	286	355.39	332.86	301.59
20	294	241	355.0	300.92	271.36
20	295	285	354.0	314.61	297.72
21	293	410	382.64	417.86	393.71
21	294	312	384.21	356.6	343.06

21	295	317	386.07	330.74	337.23
22	293	218	303.57	289.92	249.0
22	294	258	303.68	239.76	252.12
22	295	331	304.75	301.83	311.76
23	293	475	474.93	480.76	485.36
23	294	414	477.5	393.11	376.37
23	295	411	477.04	441.66	437.93
25	293	318	323.54	319.23	311.31
25	294	273	324.29	280.04	277.26
25	295	346	327.36	294.37	310.91
27	293	1321	1537.82	1509.4	1352.11
27	294	1247	1543.11	1355.89	1290.39
27	295	1548	1552.68	1379.58	1427.39
28	293	557	799.89	789.05	652.78
28	294	829	807.93	635.03	746.44
28	295	763	811.86	817.05	781.96
29	293	882	917.5	902.22	875.51
29	294	589	914.5	809.93	740.74
29	295	768	913.29	840.57	826.68
30	293	932	880.07	960.56	972.57
30	294	587	872.54	692.19	608.43
30	295	746	877.39	814.29	788.24
31	293	1178	1069.18	990.16	1089.8
31	294	891	1078.43	989.06	940.28
31	295	901	1075.71	1029.58	969.65
32	293	1646	1598.75	1610.75	1578.0
32	294	907	1594.68	1308.92	1086.02
32	295	1255	1597.89	1405.6	1257.88
33	293	926	965.5	934.86	900.25
33	294	753	965.25	858.4	782.77
33	295	757	966.89	792.95	797.86
34	293	1908	2062.79	2123.86	2024.96
34	294	2082	2087.46	1670.09	1813.94
34	295	1906	2078.25	2085.77	2047.57
35	293	1605	1434.75	1382.75	1494.59
35	294	1043	1439.07	1320.77	1215.68
35	295	1321	1451.29	1342.96	1374.6
36	293	1029	1014.89	973.53	1024.12

36	294	1078	1033.96	832.29	945.62
36	295	895	1038.32	1092.88	1042.16
37	293	587	614.61	611.99	591.4
37	294	547	619.5	583.37	588.51
37	295	639	625.93	598.27	610.69
38	293	1243	1373.21	1250.27	1224.69
38	294	944	1371.0	1199.19	1096.54
38	295	1145	1378.79	1134.42	1140.04
39	293	1067	1221.18	1052.45	1046.89
39	294	1059	1229.82	1059.99	1044.15
39	295	1076	1239.39	1242.33	1183.2
40	293	1551	1376.25	1272.95	1425.24
40	294	1143	1380.57	1138.24	1140.8
40	295	1112	1374.36	1396.98	1263.8
41	293	1198	1501.96	1364.05	1270.47
41	294	1275	1499.39	1261.59	1330.47
41	295	1326	1507.57	1380.78	1345.87
42	293	807	1064.57	1109.1	953.4
42	294	748	1063.04	899.25	853.27
42	295	989	1066.54	990.0	989.96
43	293	2124	1992.61	2061.95	2111.42
43	294	1771	1998.25	1907.71	1787.64
43	295	1754	2011.18	1985.76	1926.92
44	293	1429	1578.46	1572.5	1421.44
44	294	1428	1585.64	1320.43	1374.34
44	295	1665	1592.54	1305.54	1482.69
45	293	881	1147.93	1171.17	964.98
45	294	947	1154.25	938.54	971.63
45	295	1079	1162.93	1107.39	1083.83
46	293	1449	1594.21	1575.39	1412.79
46	294	1444	1604.89	1317.13	1347.94
46	295	1575	1617.68	1359.34	1493.07
47	293	614	733.82	749.1	665.89
47	294	514	732.93	621.8	562.84
47	295	677	735.96	616.72	660.55
48	293	1148	1430.11	1413.55	1248.59
48	294	1178	1437.14	1036.84	1116.05
48	295	1395	1447.86	1243.81	1301.31

49	293	1088	1344.29	1402.05	1281.12
49	294	1166	1351.0	1221.87	1240.49
49	295	1176	1354.61	1168.14	1196.32
50	293	872	1082.64	987.17	913.45
50	294	796	1090.25	900.09	826.55
50	295	795	1088.21	929.04	900.89

TABLE 5.2 – Extrait des prévisions de la demande (2 à 3 jours par article)

## A.2-Comparaison des performances des méthodes de prévision

Article	Classe	MAE_MM	MAE_LR	MAE_RF	RMSE_MM	RMSE_LR	RMSE_RF	R2_MM	R2_LR	R2_RF
1	A-X	23,31	16,12	17,61	29,45	20,28	22,22	0	0,483	0,379
2	A-Y	31,48	17,7	22,27	40,04	22,84	27,74	0	0,517	0,288
3	A-X	26,79	19,94	20,86	35,94	25,58	28,05	0	0,345	0,213
4	A-X	19,64	9,89	11,32	24,65	12,63	13,66	0	0,614	0,549
5	A-X	32,48	24,11	24,13	40,6	32,04	29,99	0	0,172	0,275
6	A-X	15,48	10,13	9,82	19,83	14,34	11,88	0	0,252	0,486
7	A-X	32,6	21,75	24,91	42,15	28,73	31,34	0	0,287	0,151
8	A-X	26,12	15,48	16,5	32,93	19,68	21,18	0	0,554	0,484
9	A-X	32,1	21,99	24,23	41,34	29,05	31,32	0	0,307	0,194
10	A-X	11,34	8,37	7,15	14,96	10,97	9,5	0	0,267	0,45
11	B-X	48,28	29,09	30,34	56,08	35,57	37,8	0	0,52	0,458
12	B-X	51,63	43,51	42,04	64,71	55,59	51,15	0	0,14	0,272
13	B-X	46,27	46,13	35,73	60,07	65,56	45,62	0	0	0,276
14	B-Y	61,64	52,12	50,62	81,19	66,62	63,48	0	0,088	0,172
15	B-Y	51,13	45,46	38,42	66,8	60,03	48,62	0	0	0,216
16	B-Y	65,34	59,87	58,4	85,7	73,02	78,36	0	0,094	0
17	B-Y	90,27	74,02	78,87	111,75	96,69	97,27	0	0	0
18	B-X	50,49	40,7	40,96	63,8	49,02	50,72	0	0,316	0,267
19	B-X	78,39	59,13	57,41	106,93	74,13	74,6	0	0,302	0,293
20	B-X	61,84	50,12	51,81	73,65	60,52	61,65	0	0,205	0,175
21	B-Y	81,07	56,27	69,45	100,04	69,88	83,95	0	0,327	0,029
22	B-X	63,67	55,12	52,29	81,51	64,96	64,37	0	0,077	0,094
23	B-X	78,16	57,3	61,21	98,87	75,82	80,76	0	0,249	0,148
24	B-X	78,48	74,95	57,03	101,38	108,11	70,01	0	0	0,339
25	B-X	65,07	50,23	46,84	78,78	68,62	58,94	0	0,078	0,32
26	C-Y	405,48	433,18	305,95	491,4	670,95	394,71	0	0	0,164
27	C-X	294,81	192,82	240,11	387,42	238,23	307,14	0	0,496	0,162
28	C-Y	149,79	106,39	124,9	195,13	137,9	155,16	0	0,377	0,211
29	C-X	154,31	119,88	129,04	204,54	151,79	160,63	0	0,41	0,339
30	C-X	176,52	109,53	126,52	224,91	144,21	155,3	0	0,377	0,277

Article	Classe	MAE_MM	MAE_LR	MAE_RF	RMSE_MM	RMSE_LR	RMSE_RF	R2_MM	R2_LR	R2_RF
31	C-X	175,67	137,42	138,24	219,09	176,68	181,25	0	0,291	0,254
32	C-X	273,1	320,33	233,1	337,09	458,19	281,38	0	0	0,285
33	C-X	151,99	119,48	123,36	193,14	150,75	149,5	0	0,383	0,393
34	C-Y	483,4	267,15	329,18	611,34	352,09	425,92	0	0,48	0,239
35	C-Y	283,22	212,6	239,61	368,43	273,38	307,36	0	0,337	0,162
36	C-X	204,57	140,2	164,35	253,54	169,97	209,92	0	0,431	0,132
37	C-X	118,97	90,91	101,15	149,52	115,36	127,09	0	0,242	0,08
38	C-X	238,04	237,84	194,67	292,62	345,69	245,67	0	0	0,242
39	C-X	228,37	197,97	201,72	292,17	249,01	247,17	0	0,08	0,094
40	C-Y	265,25	193,47	234,51	344,03	241,81	290,82	0	0,444	0,196
41	C-Y	327,28	206,39	246,64	400	253,32	306,47	0	0,5	0,269
42	C-Y	225,78	159,47	180,41	275,76	197,59	224,05	0	0,271	0,062
43	C-Y	397,79	268,08	310,91	496,48	344,35	391,3	0	0,338	0,145
44	C-X	291,33	229,67	197,58	375,33	276,9	251,19	0	0,384	0,493
45	C-Y	222,36	172,37	170,42	268,27	216,71	219,3	0	0,173	0,153
46	C-X	272,01	263,54	209,59	344,67	382,64	266,55	0	0	0,275
47	C-X	140,55	104,83	104,42	175,59	132,83	135,32	0	0,278	0,25
48	C-X	240,16	219,12	167,87	286,43	313,68	199,75	0	0	0,486
49	C-Y	279,06	218,72	220,24	365,88	270,13	282,42	0	0,261	0,192
50	C-X	171,96	132,01	134,8	209,29	162,64	166,58	0	0,332	0,299

TABLE 5.4 – Comparaison des performances des méthodes de prévision pour quelques articles

### A.3- Politique (Q, r)

Article	Classe	Q_opt	r_opt	Coût total	Niveau de service	Stock moyen
1	A-X	775	12444	45938.29	0.99	466.8
2	A-Y	709	7676	66533.77	0.99	462.9
3	A-X	628	13494	74277.83	0.99	412.3
4	A-X	633	9707	28478.95	0.99	382.2
5	A-X	690	11742	53481.19	0.99	452.8
6	A-X	504	7544	56988.52	0.99	306.4
7	A-X	865	25923	39964.14	0.99	544.4
8	A-X	750	14215	80229.28	0.99	467.5
9	A-X	662	7710	67547.83	0.99	435.9
10	A-X	470	2971	15310.92	0.99	274.0
11	B-X	973	34213	9246.62	0.99	605.9
12	B-X	1136	25394	23486.98	0.99	729.9
13	B-X	961	41164	12829.52	0.99	628.8
14	B-Y	1127	27554	19039.67	0.99	767.9

Article	Classe	Q_opt	r_opt	Coût total	Niveau de service	Stock moyen
15	B-Y	923	21037	14894.74	0.99	610.1
16	B-Y	901	20088	13412.61	0.99	632.5
17	B-Y	1263	36306	24816.9	0.99	828.6
18	B-X	990	37842	10582.04	0.99	631.6
19	B-X	988	25512	16473.92	0.99	712.3
20	B-X	1271	22926	16857.25	0.99	805.2
21	B-Y	1171	17063	19498.57	0.99	811.2
22	B-X	934	48468	12064.49	0.99	634.1
23	B-X	1110	68230	29689.93	0.99	802.1
24	B-X	1159	38421	15665.62	0.99	825.2
25	B-X	1164	20634	21709.1	0.99	767.3
26	C-Y	2719	129401	25203.71	0.99	2652.7
27	C-X	1998	138314	17966.26	0.99	1881.5
28	C-Y	1811	50204	7871.43	0.99	1414.9
29	C-X	1556	58148	10356.22	0.99	1268.6
30	C-X	2004	134941	7068.96	0.99	1521.0
31	C-X	2012	68675	14576.24	0.99	1560.9
32	C-X	2529	135618	4271.4	0.99	2125.1
33	C-X	1766	45284	3042.18	0.99	1406.6
34	C-Y	2945	175007	9174.04	0.99	2821.7
35	C-Y	2118	120358	8815.55	0.99	1937.5
36	C-X	2024	152955	17481.2	0.99	1609.1
37	C-X	1471	40098	5815.12	0.99	1071.0
38	C-X	1831	87030	14234.02	0.99	1700.7
39	C-X	1742	181673	10329.07	0.99	1563.1
40	C-Y	2031	85236	10380.09	0.99	1803.2
41	C-Y	2563	128058	18557.41	0.99	2169.9
42	C-Y	2153	92034	19146.3	0.99	1735.1
43	C-Y	2581	164944	9507.31	0.99	2501.0
44	C-X	2660	76081	8524.0	0.99	2242.7
45	C-Y	2002	71076	13614.37	0.99	1682.4
46	C-X	2691	102772	24988.65	0.99	2299.3
47	C-X	1591	64894	13413.84	0.99	1200.5
48	C-X	1906	206560	14241.5	0.99	1742.8
49	C-Y	2365	87698	7050.09	0.99	1984.0
50	C-X	1968	69242	8755.47	0.99	1521.2

TABLE 5.5 – Paramètres optimaux pour la politique (Q, r)

**B.4- Politique (R, T)**

Article	Classe	R_opt	T_opt	Coût total	Niveau de service	Stock moyen
1	A-X	13263	7	45747.62	0.99	833.0
2	A-Y	8494	15	69396.26	0.99	850.7
3	A-X	14471	7	102800.63	0.99	1004.9
4	A-X	10373	7	28455.91	0.99	680.5
5	A-X	12703	7	65362.17	0.99	985.6
6	A-X	8088	7	58827.02	0.99	559.6
7	A-X	27312	7	59317.04	0.99	1420.3
8	A-X	15163	7	92695.74	0.99	965.8
9	A-X	8506	7	72554.27	0.99	825.2
10	A-X	3269	7	9762.49	0.99	308.2
11	B-X	35774	7	13337.64	0.99	1573.3
12	B-X	27063	7	30517.18	0.99	1698.0
13	B-X	43084	7	22080.37	0.99	1939.6
14	B-Y	29581	15	29562.33	0.99	2087.3
15	B-Y	22528	15	21146.57	0.99	1529.5
16	B-Y	21719	15	19936.62	0.99	1670.3
17	B-Y	38419	15	34837.86	0.99	2120.7
18	B-X	39613	7	16726.92	0.99	1789.6
19	B-X	27494	7	26175.3	0.99	2019.6
20	B-X	24511	7	18532.39	0.99	1592.6
21	B-Y	18786	15	24338.77	0.99	1779.6
22	B-X	50658	7	23302.98	0.99	2206.0
23	B-X	71426	7	67013.79	0.99	3230.9
24	B-X	40949	7	27412.99	0.99	2572.5
25	B-X	22298	7	26998.78	0.99	1703.5
26	C-Y	144738	30	753707.61	0.85	10225.1
27	C-X	150557	30	580171.96	0.85	8062.1
28	C-Y	54630	30	14715.18	0.99	4580.4
29	C-X	62616	30	20903.32	0.99	4547.2
30	C-X	141561	30	17717.29	0.99	6718.6
31	C-X	73767	30	26975.17	0.99	5160.3
32	C-X	144500	30	10252.88	0.99	9032.8
33	C-X	49396	30	5155.65	0.99	4188.3
34	C-Y	188250	30	26389.95	0.99	13678.0
35	C-Y	129096	30	23914.0	0.99	8987.7

Article	Classe	R_opt	T_opt	Coût total	Niveau de service	Stock moyen
36	C-X	160546	30	47802.76	0.99	7711.8
37	C-X	43158	30	9460.71	0.99	3112.0
38	C-X	97189	30	435537.49	0.85	6631.6
39	C-X	190521	30	33893.57	0.99	8973.5
40	C-Y	92255	30	23783.33	0.99	7203.4
41	C-Y	137012	30	45157.96	0.99	9174.2
42	C-Y	98618	30	43008.2	0.99	6761.1
43	C-Y	176974	30	27648.89	0.99	12379.0
44	C-X	83189	30	15819.25	0.99	7268.9
45	C-Y	77089	30	28836.88	0.99	6191.7
46	C-X	111263	30	54244.66	0.99	8716.7
47	C-X	69091	30	26711.56	0.99	4262.6
48	C-X	216652	30	47892.95	0.99	10238.8
49	C-Y	94863	30	14886.52	0.99	7345.5
50	C-X	74213	30	16105.38	0.99	5016.4

TABLE 5.6 – Paramètres optimaux pour la politique (R, T)

## A.5- Résultats détaillés par article

Article	Demande annuelle	CV	Classe	MAE_test	RMSE_test	R2_test	Meilleur modèle	Recommandation
1	43601	0.198	A-X	16.12	20.28	0.483	Regression	(R,T) acceptable
2	50702	0.232	A-Y	17.70	22.84	0.517	Regression	(R,T) acceptable
3	47237	0.225	A-X	19.94	25.58	0.345	Regression	(Q,r) optimal
4	33998	0.209	A-X	9.89	12.63	0.614	Regression	(R,T) acceptable
5	55678	0.209	A-X	24.13	29.99	0.275	RandomForest	(Q,r) optimal
6	26408	0.224	A-X	9.82	11.88	0.486	RandomForest	(R,T) acceptable
7	54042	0.224	A-X	21.75	28.73	0.287	Regression	(Q,r) optimal
8	49800	0.201	A-X	15.48	19.68	0.554	Regression	(Q,r) optimal
9	50953	0.223	A-X	21.99	29.05	0.307	Regression	(R,T) acceptable
10	19644	0.215	A-X	7.15	9.50	0.450	RandomForest	(R,T) acceptable
11	71384	0.182	B-X	29.09	35.57	0.520	Regression	(Q,r) optimal
12	88975	0.197	B-X	42.04	51.15	0.272	RandomForest	(Q,r) optimal
13	85877	0.187	B-X	35.73	45.62	0.276	RandomForest	(Q,r) optimal
14	96443	0.230	B-Y	50.62	63.48	0.172	RandomForest	(Q,r) optimal
15	73659	0.219	B-Y	38.42	48.62	0.216	RandomForest	(Q,r) optimal
16	95266	0.207	B-Y	59.87	73.02	0.094	Regression	(Q,r) optimal
17	127330	0.168	B-Y	90.27	111.75	0.000	Moyenne_Mobile	(Q,r) optimal
18	78946	0.188	B-X	40.70	49.02	0.316	Regression	(Q,r) optimal
19	121047	0.195	B-X	59.13	74.13	0.302	Regression	(Q,r) optimal
20	108903	0.169	B-X	50.12	60.52	0.205	Regression	(R,T) acceptable
21	112813	0.217	B-Y	56.27	69.88	0.327	Regression	(Q,r) optimal
22	101130	0.179	B-X	52.29	64.37	0.094	RandomForest	(Q,r) optimal
23	142339	0.188	B-X	57.30	75.82	0.249	Regression	(Q,r) optimal
24	134619	0.198	B-X	57.03	70.01	0.339	RandomForest	(Q,r) optimal

Article	Demande_annuelle	CV	Classe	MAE_test	RMSE_test	R2_test	Meilleur_modèle	Recommandation
25	97860	0.205	B-X	46.84	58.94	0.320	RandomForest	(Q,r) optimal
26	613086	0.229	C-Y	305.95	394.71	0.164	RandomForest	(Q,r) optimal
27	484627	0.197	C-X	192.82	238.23	0.496	Regression	(Q,r) optimal
28	237826	0.232	C-Y	106.39	137.90	0.377	Regression	(Q,r) optimal
29	275929	0.193	C-X	119.88	151.79	0.410	Regression	(Q,r) optimal
30	281447	0.200	C-X	109.53	144.21	0.377	Regression	(Q,r) optimal
31	326003	0.184	C-X	137.42	176.68	0.291	Regression	(Q,r) optimal
32	475198	0.196	C-X	233.10	281.38	0.285	RandomForest	(Q,r) optimal
33	299892	0.189	C-X	123.36	149.50	0.393	RandomForest	(Q,r) optimal
34	612373	0.239	C-Y	267.15	352.09	0.480	Regression	(Q,r) optimal
35	421323	0.226	C-Y	212.60	273.38	0.337	Regression	(Q,r) optimal
36	318999	0.203	C-X	140.20	169.97	0.431	Regression	(Q,r) optimal
37	190289	0.191	C-X	90.91	115.36	0.242	Regression	(Q,r) optimal
38	412744	0.206	C-X	194.67	245.67	0.242	RandomForest	(Q,r) optimal
39	378930	0.198	C-X	201.72	247.17	0.094	RandomForest	(Q,r) optimal
40	404148	0.211	C-Y	193.47	241.81	0.444	Regression	(Q,r) optimal
41	448437	0.215	C-Y	206.39	253.32	0.500	Regression	(Q,r) optimal
42	322219	0.221	C-Y	159.47	197.59	0.271	Regression	(Q,r) optimal
43	577376	0.227	C-Y	268.08	344.35	0.338	Regression	(Q,r) optimal
44	503630	0.196	C-X	197.58	251.19	0.493	RandomForest	(Q,r) optimal
45	336890	0.219	C-Y	172.37	216.71	0.173	Regression	(Q,r) optimal
46	487276	0.212	C-X	209.59	266.55	0.275	RandomForest	(Q,r) optimal
47	227409	0.193	C-X	104.83	132.83	0.278	Regression	(Q,r) optimal
48	430831	0.199	C-X	167.87	199.75	0.486	RandomForest	(Q,r) optimal
49	415860	0.209	C-Y	218.72	270.13	0.261	Regression	(Q,r) optimal
50	328804	0.177	C-X	132.01	162.64	0.332	Regression	(Q,r) optimal

TABLE 5.7 – Résultats détaillés par article

---

## Résumé

---

Dans ce travail, nous considérons le problème de gestion des stocks des articles d'instrumentations à l'entreprise SONATRACH (DRGB). Notre étude combine une classification ABC/XYZ, des modèles de prévision de la demande et l'optimisation des politiques d'approvisionnement. Une base de données simulée de 50 articles a été générée pour représenter différents profils de consommation répartis en six classes : AX, AY, BX, BY, CX et CY.

Trois méthodes de prévision ont été testées (moyenne mobile, régression linéaire, forêt aléatoire) et intégrées aux politiques  $(Q, r)$  et  $(R, T)$ , avec une optimisation basée sur les coûts globaux. Les résultats montrent que l'usage de l'intelligence artificielle permet une anticipation plus fiable de la demande et une réduction notable des coûts logistiques. Une validation future sur données réelles SONATRACH est prévue.

**Mots-clés** : Entreprise SONATRACH, Gestion des stocks, Intelligence artificielle, Apprentissage automatique, Prévision de la demande.

---

## Abstract

---

In this work, we address the inventory management problem of instrumentation items at SONATRACH (DRGB). Our study combines **ABC/XYZ classification**, **demand forecasting models**, and the **optimization of replenishment policies**. A simulated database of 50 items was generated to represent various consumption profiles, grouped into six classes : **AX, AY, BX, BY, CX, and CY**.

Three forecasting methods were tested — *moving average*, *linear regression*, and *random forest* — and integrated into the policies  $(Q, r)$  and  $(R, T)$ , with an optimization based on **total cost minimization**. The results show that the use of **artificial intelligence** enables more reliable demand forecasting and a significant reduction in logistics costs. A future validation using real SONATRACH data is planned.

**Keywords** : SONATRACH Company, Inventory management, Artificial intelligence, Machine learning, Demand forecasting.

---