



HAL
open science

Prévision de la demande et pilotage des flux en approvisionnement lointain

Thibault Hubert

► **To cite this version:**

Thibault Hubert. Prévision de la demande et pilotage des flux en approvisionnement lointain. Autre. Ecole Centrale Paris, 2013. Français. NNT : 2013ECAP0012 . tel-00879853

HAL Id: tel-00879853

<https://theses.hal.science/tel-00879853>

Submitted on 5 Nov 2013

HAL is a multi-disciplinary open access archive for the deposit and dissemination of scientific research documents, whether they are published or not. The documents may come from teaching and research institutions in France or abroad, or from public or private research centers.

L'archive ouverte pluridisciplinaire **HAL**, est destinée au dépôt et à la diffusion de documents scientifiques de niveau recherche, publiés ou non, émanant des établissements d'enseignement et de recherche français ou étrangers, des laboratoires publics ou privés.



ÉCOLE CENTRALE DES ARTS
ET MANUFACTURES
« ÉCOLE CENTRALE PARIS »

Thèse de doctorat
Spécialité : Génie Industriel

Présentée par

Thibault HUBERT

Pour l'obtention du

GRADE DE DOCTEUR

SUJET :

Prévision de la demande et pilotage des flux en
approvisionnement lointain

Soutenue le 30 Janvier 2013 à l'Ecole Centrale Paris devant le jury composé de :

ARTIBA Abdelhakim	Université de Valenciennes	Rapporteur
DOLGUI Alexandre	Ecole des Mines de Saint Etienne	Rapporteur
DALBOUSSIÈRE Franck	PSA Peugeot Citroën	Examineur
GIARD Vincent	Université Paris Dauphine	Examineur
JEMAI Zied	Ecole Centrale Paris	Co-Encadrant
CHU Chengbin	Ecole Centrale Paris	Directeur de thèse

Laboratoire Génie Industriel
Ecole Centrale Paris
Grande voie des Vignes
92295 Châtenay-Malabry Cedex

2013ECAP0012

Sommaire

Sommaire	i
Liste des figures.....	v
Liste des tableaux.....	vii
Introduction générale.....	1
A. Contexte et motivations.....	1
B. Objectifs de ce travail et principales contributions.....	2
C. Organisation du rapport.....	3
Chapitre 1 : Amélioration de l'utilisation de la prévision	5
Présentation de l'existant	6
I. Les Méthodes de Prévisions.....	6
A. Introduction.....	6
B. La réalisation des prévisions.....	7
C. Les méthodes de prévisions	8
1. Méthodes qualitatives.....	10
2. Méthodes quantitatives	10
2. Les stratégies de prévisions et les agrégations	18
IV. La validation et le suivi des modèles.....	18
V. Conclusion	22
Processus de choix d'une méthode de prévision appropriée.....	23
I. Choix de méthodes et de modèles de prévisions	23
A. Deuxième méthode : choix initial et limité	24
B. Troisième méthode : adaptation.....	25
1. Classification de la demande et des produits.....	25
2. Recherche et validation du modèle adapté	27
II. Méthode développée.....	29
A. Classification amont	29
B. Méthode de choix de modèle quantitatif	30
1. Phase d'initialisation	31
2. Phase d'utilisation	33
III. Conclusions	34
Applications industrielles	36
I. Application à démarche prospective : la mise en place de prévision de flux dans le cadre d'une plate-forme de transport Gefco.....	36
A. Contexte et objectifs de l'étude.....	36

1.	Contexte	36
2.	Objectifs.....	37
3.	Utilisation des prévisions : Réalisation de la planification	37
B.	Etude réalisée.....	38
1.	Echantillon d'étude :	38
2.	Réalisation :	39
C.	Conclusion	43
II.	Application à démarche comparative : Comparaison de la qualité des prévisions obtenues par PSA et celle obtenue en utilisant la méthode proposée dans le cadre de prévision de pièces de rechanges.	43
A.	Contexte et processus de gestion des pièces de rechanges (PR).....	43
1.	Les catégories de pièces	44
2.	L'aspect commercial.....	44
3.	Le schéma logistique	45
4.	La réalisation des prévisions.....	46
5.	Conclusion	47
B.	Etude réalisée.....	47
1.	Echantillon d'étude :	47
2.	Réalisation :	47
C.	Conclusion	49
III.	Conclusion	50
	Conclusion	52
	Chapitre 2 : Modélisation de l'incertitude prévisionnelle	53
	Présentation de l'existant	54
I.	Les incertitudes	54
II.	Incertitude sur la demande.....	56
III.	Conclusion	59
	Le modèle mixte : modèle théorique et validation sur cas réels.....	61
I.	Modèle théorique	61
A.	Modèle absolu:.....	61
B.	Modèle relatif:.....	62
C.	Modèle mixte :	62
D.	Exemple numérique	62
II.	Obtention des paramètres à partir d'un historique des données.....	65
III.	Validation du modèle obtenu sur un jeu de données	66
IV.	Conclusion	69
	Le modèle évolutif : modèle théorique et validation sur cas réels.....	70
I.	Un modèle théorique	70

II. Obtention des paramètres à partir d'un historique	71
III. Validation du modèle obtenu sur un jeu de données réelles.....	72
IV. Conclusion	77
Conclusion	78
Chapitre 3 : Pilotage de flux et sécurisation des approvisionnements dans le cadre du Global Sourcing.....	79
Les politiques classiques de pilotage de flux	80
I. La gestion des stocks classique	80
A. Introduction.....	80
B. Le pilotage de flux dans les chaînes logistiques	80
1. Notion de chaîne logistique.....	80
2. Pilotage de flux.....	81
C. Les différentes politiques de pilotage de flux	82
1. Politiques de pilotage par renouvellement de la consommation	82
2. Politiques de pilotage par les besoins futurs	88
D. Classification des politiques suivant le type de l'information sur la demande	90
1. Information sur la demande.....	90
2. Pilotage de flux et information sur la demande.....	91
E. Conclusions.....	93
II. La gestion de flux sous incertitudes	93
A. Le stock et le délai de sécurité	94
B. Règles de lot-sizing	94
C. Plan Directeur de Production (master production schedule)	96
D. Applications au cas de la méthode MRP	96
III. Conclusion	97
Le Global Sourcing.....	98
I. Introduction	98
II. Présentation du Global Sourcing.....	98
A. Qu'est-ce que le Global Sourcing ?.....	99
B. Pourquoi le Global Sourcing	99
C. Les contraintes du Global Sourcing	100
D. La littérature sur le Global Sourcing.....	102
III. Conclusion	104
Le pilotage de flux en Global Sourcing.....	105
I. Objectifs de recherche	105
II. Méthode de recherche	105
III. Présentation du modèle de pilotage des flux en Global Sourcing.....	106

A.	Présentation des paramètres des modèles de gestion de flux	107
B.	Fonction objectif et contraintes des modèles.....	107
1.	Fonction objectif.....	108
2.	Contraintes	108
C.	Gestion des flux avec prise en compte de l'historique des erreurs dans le cas du Global Sourcing 109	
IV.	Présentation des résultats	111
A.	Application de notre méthode	112
B.	Horizon safety stock	112
V.	Conclusion	114
	Application au cas de PSA et comparaison avec les modèles de la littérature.	116
I.	Méthode de calcul de stock de sécurité utilisée par PSA	116
A.	La problématique de l'approvisionnement lointain chez PSA	116
B.	Méthodes étudiées.....	118
1.	Abaque « C&R ».....	118
2.	Coefficient de consommation K	119
3.	Etapes de calcul du coefficient de flexibilité	119
II.	Comparaison avec le modèle proposé.....	121
A.	Comparaison entre la méthode HSS et la politique (T,s)	122
B.	Comparaison politique industrielle	123
C.	Comparaison entre la méthode HSS et la politique (T,s _k)	127
III.	Réalisation d'un outil de simulation de gestion des stocks à destination de l'industrie	
	128	
A.	Présentation des paramètres variables.....	128
1.	La demande	128
2.	Modèles de prévision :	128
3.	Délai d'approvisionnement	129
4.	Paramètres du modèle HSS.....	129
B.	Présentation des résultats de simulation.....	129
1.	Effet de la variation de α pour une demande stationnaire entre 500 et 1000 pièces	129
2.	Effet de la variation de α pour une demande croissante entre 100 et 1000 pièces...	130
3.	Effet de la variation de α pour une demande décroissante entre 100 et 1000 pièces	131
	Conclusion	132
	Conclusion et perspectives	133
A.	Conclusion :	133
B.	Perspectives :	134
	Bibliographie	137

Liste des figures

Figure 1: Place de la prévision dans la chaîne logistique globale	6
Figure 2: Etapes de réalisation de la prévision des ventes	7
Figure 3: Les différentes méthodes de prévision.....	9
Figure 4: Les piliers d'un outil de prévisions	9
Figure 5: Algorithme de choix du modèle de prévision	30
Figure 6: Phase d'initialisation de l'algorithme de choix du modèle de prévision	31
Figure 7: Phase d'utilisation de l'algorithme de choix du modèle de prévision	33
Figure 8: Présentation des différents types de contrats de location de moyen de transport et de leurs spécificités	37
Figure 9: Schéma logistique de la plate forme de cross-docking étudiée	38
Figure 10: Algorithme de classification des cas de changement de modèle.....	40
Figure 11: Schéma logistique de distribution des pièces de rechanges	45
Figure 12: Prévisions et incertitudes prévisionnelles	56
Figure 13: Fiabilisation de la prévision par la mise en place de l'incertitude prévisionnelle	57
Figure 14: Bullwhipeffect ou effet coup de fouet.....	58
Figure 15: Valeur absolue de l'erreur de prévision en fonction de la prévision pour trois types d'incertitudes prévisionnelles	63
Figure 16: Evolution des trois types d'incertitudes prévisionnelles en fonction des prévisions....	64
Figure 17: Illustration de l'hypothèse de prévision non biaisée (1).....	64
Figure 18: Illustration de l'hypothèse de prévision non biaisée (2).....	65
Figure 19: Tracer de la droite de tendance modélisant l'incertitude prévisionnelle mixte	65
Figure 20: Détermination des paramètres de l'incertitude prévisionnelle mixte sur deux horizons différents	66
Figure 21: Evolution de l'incertitude modèle « Exponentiel max ».....	71
Figure 22: Evolution de l'incertitude prévisionnelle en fonction de l'horizon d'extrapolation.....	72
Figure 23: Modélisation de l'évolution de l'erreur absolue moyenne et de l'écart type de l'erreur absolue moyenne en fonction de l'horizon de prévision	73
Figure 24: Modélisation de l'évolution de l'erreur relative moyenne et de l'écart type de l'erreur relative moyenne en fonction de l'horizon de prévision	73
Figure 25: Evolution de l'erreur de prévision en fonction de l'horizon de prévision (cas des pièces de rechanges)	74
Figure 26: Evolution et répartition relative de l'erreur de prévision en fonction de l'horizon de prévision	76
Figure 27: Le pilotage de flux dans la chaîne logistique	82
Figure 28: Schéma d'une politique de gestion des stocks classique	83
Figure 29: Evolution du stock avec la politique (r,Q).....	84
Figure 30: Evolution du stock avec la politique (T,S)	84
Figure 31: Evolution du stock avec la politique (s,S)	85
Figure 32: Evolution du stock dans la politique (T,r,S)	86
Figure 33: Evolution du stock dans la politique (T,r,Q).....	86
Figure 34: La politique Kanban dans un système à deux étages	87
Figure 35: Visibilité sur la demande et incertitude.....	91
Figure 36: Classification des politiques de pilotage de flux en fonction du type de l'information sur la demande.....	92
Figure 37: Information sur la demande et méthodes de pilotage.....	93
Figure 38: Techniques de planification généralement utilisées	97

Figure 39: Présentation schématique du cas d'étude	106
Figure 40: Présentation du TSL	108
Figure 41: Présentation du niveau de stock de sécurité à horizon (HSS) pour quatre paramètres α différents et un TSL=100%	110
Figure 42: Présentation du niveau de stock de sécurité à horizon (HSS) pour quatre paramètres TSL différents et un $\alpha=21$ jours	111
Figure 43: Présentation du niveau de stock physique en fonction de α pour six valeurs de TSL.	113
Figure 44: Présentation du niveau de taux de service réel en fonction de α pour six valeurs de TSL	113
Figure 45: Présentation du niveau du taux de service réel en fonction du niveau du stock physique pour l'ensemble des simulations réalisées	114
Figure 46: Illustration de la problématique de l'approvisionnement lointain chez PSA	117
Figure 47: Illustration de l'incertitude sur la demande en approvisionnement lointain chez PSA	117
Figure 48: Fiabilité des prévisions.....	118
Figure 49: Illustration du calcul de coefficient de flexibilité	119
Figure 50: recherche dichotomique.....	121
Figure 51: Présentation du taux de service réel et du stock physique moyen pour différents taux de service cible (50% à 99%) pour le modèle (T, s).....	122
Figure 52: Comparaison "Taux de service et niveau moyen de stock" pour la politique (1,s) et le modèle HSS.....	123
Figure 53: Comparaison "taux de service et niveau moyen de stock" pour le modèle industriel et le modèle HSS.....	125
Figure 54: Stock moyen modèle HSS vs Stock moyen modèle industriel	126
Figure 55: Taux de service moyen modèle HSS vs Taux de service moyen modèle industriel.....	126
Figure 56: Comparaison "taux de service et niveau moyen de stock" pour le modèle (T,sk)et le modèle HSS.....	127
Figure 57: Présentation de différents profils d'évolution de demande	128
Figure 58: Présentation de la demande aléatoire et de l'évolution du stock pour différents paramètres de sécurisation α	129
Figure 59: Présentation de la demande croissante et de l'évolution du stock pour différents paramètres de sécurisation α	130
Figure 60: Présentation de la demande décroissante et de l'évolution du stock pour différents paramètres de sécurisation α	131

Liste des tableaux

Tableau 1: Classification de Williams.....	26
Tableau 2: Classification de Ghobbar	26
Tableau 3: Classification de Eaves	26
Tableau 4: Classification des demandes en fonction de l'historique des demandes disponible ...	30
Tableau 5: Classification des modèles de prévision en fonction du type de demande (cas des demandes continues).....	32
Tableau 6: Erreur de prévisions (MAD) selon les méthodes utilisées et caractéristiques de la demande des flux aval de la plate-forme de cross-docking étudiée.....	39
Tableau 7: Type de changements de modèle pour les flux aval de la plate-forme de cross-docking étudiée sur l'horizon d'étude.....	41
Tableau 8: Analyse des types de changement et qualité de prévision obtenue pour les flux aval de la plate-forme de cross-docking étudiée.....	42
Tableau 9: Analyse de la qualité des prévisions suivant la méthode utilisée.....	42
Tableau 10: Catégories de pièces de rechanges en fonction du type de demande et de la famille marketing des pièces.....	45
Tableau 11: Analyse de la qualité des prévisions suivant la méthode utilisée pour les différents types de produits.....	48
Tableau 12: Analyse des types de changement et qualité de prévision obtenue pour les différents types de produits étudiés.....	49
Tableau 13: Analyse de la qualité des prévisions suivant la méthode utilisée.....	49
Tableau 14: classification des références en termes d'incertitudes	55
Tableau 15: Travaux prenant en compte l'incertitude de la demande dans la planification	59
Tableau 16: Exemple numérique d'incertitude prévisionnelle.....	63
Tableau 17: Incertitudes prévisionnelles pour chacun des produits de l'échantillon et pour les différents horizons de prévisions.....	67
Tableau 18: Comparaison corrélation modèles relatif, absolu et mixte et gains associés.....	68
Tableau 19: Synthèse des résultats des paramètres des modèles d'évolutions	74
Tableau 20: Synthèse des résultats des paramètres des modèles d'évolutions (cas des pièces de rechanges).....	75
Tableau 21: Présentation des résultats des simulations pour le modèle HSS.....	115
Tableau 22: Extrait de l'abaque C&R de PSA	118
Tableau 23: Exemple 1 pour le calcul du coefficient de flexibilité	120
Tableau 24: Exemple 2 pour le calcul du coefficient de flexibilité	121
Tableau 25: Comparaison des niveaux de stock et du Taux de Service du modèle HSS par rapport au modèle industriel	124
Tableau 26: Présentation des résultats de la simulation d'une demande aléatoire dans l'intervalle [500; 1000]	129
Tableau 27: Présentation des résultats de la simulation d'une demande croissante dans l'intervalle [100; 1000]	130
Tableau 28: Présentation des résultats de la simulation d'une demande décroissante dans l'intervalle [100; 1000]	131

Introduction générale

A. Contexte et motivations

Ce travail de recherche a été guidé tout au long de sa réalisation par l'envie d'améliorer le pilotage de flux dans le contexte particulier du Global Sourcing, appelé aussi approvisionnement lointain. Ce domaine est aujourd'hui en pleine expansion car il offre aux entreprises une source potentielle de compétitivité dans un environnement de plus en plus concurrentiel. Néanmoins, il génère aussi une complexification des flux et une fragilisation de la Supply Chain Globale et offre de ce fait un challenge important à la fois sur le plan théorique et en termes d'applications industrielles. La problématique du Global Sourcing est vaste et touche les différents niveaux de décision de l'entreprise. Pour cela nous nous sommes focalisé dans ce travail sur les aspects tactiques et opérationnels de ce domaine. Nous avons abordé ainsi diverses questions : Quels leviers d'action pour un pilotage efficace des flux en approvisionnement lointain ? Comment sécuriser les approvisionnements lointains dans le contexte industriel actuel ? Les politiques classiques de pilotage de flux sont-elles suffisantes pour les approvisionnements lointains ?

L'analyse de la littérature existante et les interactions fructueuses avec les partenaires industriels de la Chaire Supply Chain de l'Ecole Centrale Paris ont montré que l'utilisation de la prévision était nécessaire afin d'estimer la demande des semaines voire des mois à l'avance du fait des délais généralement longs en approvisionnement lointain. L'utilisation de la prévision nous permet de commander le juste nécessaire. Cependant, les propriétés intrinsèques des prévisions impliquent l'existence d'erreurs qui, dans un contexte de Global Sourcing, s'amplifient par l'allongement des délais. Cette augmentation des erreurs de prévision amène à une augmentation des stocks nécessaires à la sécurisation de la chaîne d'approvisionnement et fait émerger plusieurs problématiques : comment fiabiliser les prévisions, et comment mesurer et quantifier leur erreurs. En allant plus loin, cette erreur est-elle modélisable ? Et si c'est le cas, comment ? Nous avons donc étudié les limitations actuelles de la littérature dans ces domaines et nous avons proposé une nouvelle méthode de choix de modèle de prévisions afin d'être réactifs à l'évolution de la qualité des prévisions et garder ainsi un niveau de performance acceptable. Nous avons également proposé une modélisation de l'erreur de prévisions en fonction à la fois de la demande et de l'horizon de réalisation de la prévision.

En effet, si nous pouvions avoir une bonne prévision, une bonne connaissance de l'erreur probable de prévision, nous pourrions alors définir un stock de sécurité permettant d'absorber les erreurs inévitables de prévision et ainsi permettre un approvisionnement au plus juste en termes de coût.

En pilotage de flux, la caractérisation de l'erreur prévisionnelle permet de calculer les paramètres de la politique de gestion des stocks et en particulier le stock de sécurité. Nous avons étudié les politiques classiques comme la politique stationnaire à reapprovisionnement périodique (T,S) et la politique (T,S_k) proposée par (Babai, 2009). Nous montrons que dans un contexte de Global Sourcing, ces politiques ne sont pas adaptées et aboutissent à des stocks de sécurité surdimensionnés. Nous nous sommes inspirés de ses travaux afin de proposer des modèles plus adaptés à notre

problématique qui, nous le verrons, apportent de meilleures performances. L'objectif étant d'avoir un stock dimensionné au juste nécessaire pour un taux de service élevé.

Ce travail de thèse a été réalisé dans le cadre de la Chaire Supply Chain du laboratoire Génie Industriel de l'Ecole Centrale Paris. Cette opportunité nous a permis de travailler en collaboration avec les sept entreprises partenaires, à savoir Carrefour ; Danone ; DHL ; Gefco ; Louis Vuitton ; PSA et Vallourec. Ces collaborations nous ont permis de travailler sur des problèmes réels et d'apporter des solutions applicables dans le monde industriel. Nous avons pu, ainsi, concilier une recherche académique avec une mise en application de nos travaux pour des cas industriels réels. Les interactions entre les partenaires industriels dans le cadre de la Chaire nous ont permis de profiter d'un cadre propice aux échanges d'expériences et de bonnes pratiques et d'une vision multisectorielle sur les différents sujets traités.

B. Objectifs de ce travail et principales contributions

Les objectifs de notre travail de recherche sont doubles. Le premier objectif est le développement de connaissances théoriques valorisées dans le milieu académique. Le second objectif est le développement de méthodes applicables dans le monde industriel. Ces méthodes ont pu être mises en place pour les entreprises partenaires de la Chaire afin de valider nos propositions et d'améliorer leur performance.

Pour cela, nous avons adopté une vision globale pour la problématique de l'approvisionnement lointain qui comporte trois éléments d'études reliés entre eux, à savoir :

1. choix de modèles de prévision
2. caractérisation de la qualité de prévisions
3. pilotage des flux basé sur prévisions

Chacun de ces éléments constitue à lui seul un champ de recherche important. Il n'existe pas encore, à notre connaissance, de travaux traitant ces éléments simultanément, malgré le lien très fort entre eux.

Concernant le premier axe, nous avons donné une vue globale des modèles de prévision utilisables rapidement dans un contexte industriel. Nous avons également présenté les avantages et inconvénients des modèles étudiés. Nous avons proposé enfin une méthodologie permettant d'améliorer significativement la qualité des prévisions. Cette méthodologie a été appliquée pour la prévision des besoins en transport pour GEFECO ainsi que pour la prévision de la demande en pièces de rechange chez PSA.

Suite à ce premier travail, nous nous sommes intéressés à la modélisation de l'incertitude prévisionnelle et nous avons proposé deux modèles permettant de déterminer l'incertitude prévisionnelle à venir. Le premier est un modèle mixte de l'incertitude prévisionnelle et le second un modèle de l'évolution de l'incertitude prévisionnelle en fonction de l'horizon de prévision. Nous avons également présenté là une méthode de détermination des paramètres de ses modèles afin de permettre une utilisation concrète et rapide de ces travaux d'un point de vue industriel. Une application réelle sur des données issues de PSA a été réalisée afin de montrer la qualité des modélisations proposées.

Dans le troisième axe de travail, nous avons réalisé une présentation qui, tout en n'étant pas exhaustive, se veut la plus complète possible sur le Global Sourcing et en particulier sur les travaux

académiques portant sur ce sujet. Nous avons ensuite montré l'intérêt de considérer la prévision et son incertitude pour sécuriser correctement la chaîne logistique en particulier dans le cas d'approvisionnement lointain. Nous avons alors présenté une méthode de pilotage de flux et de sécurisation de la Supply Chain dans le cas d'approvisionnement lointain avec prise en compte de la variabilité commerciale. Un outil de simulation spécifiquement adapté aux tests des modèles développés en fonction des profils de demandes prévues a également été réalisé afin de servir d'outils d'aide à la décision pour les industriels confrontés à la mise en place de flux internationaux et soucieux de sécuriser leur Supply Chain à moindres coûts. Une application sur les approvisionnements lointains de PSA a été réalisée et a permis de réduire significativement les niveaux de stock tout en gardant un niveau de service objectif.

Enfin, nous donnons des pistes de recherches directement exploitables afin d'améliorer les méthodes proposées et ainsi apporter des contributions académiques applicables rapidement dans l'industrie.

C. Organisation du rapport

Ce rapport est structuré autour des trois éléments d'études présentés précédemment. Nous commençons dans le premier chapitre par exposer notre travail sur la méthodologie de choix de modèles de prévision. Pour cela, nous débutons par présenter un état de l'art avec une étude de l'existant au niveau des modèles de prévisions et en particulier concernant les méthodes de choix de modèles de prévision. Nous détaillons ensuite notre méthode de sélection de modèle. Pour finir ce chapitre, nous présentons deux applications industrielles de cette méthode avec les améliorations qui en découlent.

Dans le second chapitre, nous traitons l'incertitude prévisionnelle. Nous proposons d'abord un état de l'art sur la modélisation de l'incertitude prévisionnelle. Suite à cela, nous présentons les deux modèles que nous avons développés, à savoir le modèle d'incertitude prévisionnelle mixte et le modèle d'incertitude prévisionnelle évolutif. Pour cela, nous détaillons dans les deux cas une méthode permettant de déterminer les paramètres du modèle, et enfin une application industrielle de ce modèle grâce aux données de nos partenaires industriels.

Le troisième chapitre de ce mémoire porte sur le pilotage des flux. Nous commençons par rappeler les différentes politiques existantes de pilotage des flux. Suite à cela, nous nous concentrons sur le pilotage des flux dans le cadre du Global Sourcing et nous présentons une synthèse de la littérature sur la problématique de pilotage des flux en approvisionnements lointains. Nous détaillons par la suite le modèle proposé et nous finirons le chapitre par les applications industrielles de la méthode de pilotage des flux en approvisionnements lointains que nous avons proposée ainsi que les résultats obtenus.

La dernière partie du rapport est consacrée à la conclusion générale sur les travaux développés et sur les applications effectuées ainsi que les pistes de recherche qui nous paraissent importantes.

Chapitre 1 : Amélioration de l'utilisation de la prévision

Le besoin d'une bonne estimation de la demande à venir est fondamental pour avoir un pilotage des flux efficace dans une chaîne logistique basé sur la réponse immédiate à une demande d'un client. Pour cela, il est nécessaire d'effectuer des prévisions de la demande et de les intégrer dans les modèles de pilotage des flux, en particulier dans des contextes où la demande est très variable. Les prévisions n'étant par nature que rarement exactes, il est important d'obtenir la meilleure qualité de prévision possible. Pour cela, différents modèles de prévisions ont été élaborés par le passé, en particulier dans le domaine statistique. Les questions qui se posent alors sont : Quels sont les modèles existants, quels sont leurs avantages et inconvénients respectifs ? Comment choisir le modèle de prévision le plus performant pour l'application en question ? C'est à ces réflexions que nous essayons d'apporter des solutions dans ce chapitre.

Avant de passer à l'étude des politiques de pilotage des flux avec prévisions, nous allons commencer, dans ce premier chapitre, par présenter les modèles de prévisions ainsi que les méthodes permettant de choisir quels modèles de prévisions utiliser selon le type de demande à prévoir. Nous présenterons dans une seconde section la méthode que nous avons développée afin d'automatiser le choix de modèle permettant d'obtenir la meilleure prévision possible en un temps raisonnable. Le but de cette méthode est son application dans un contexte industriel. Pour finir ce chapitre, nous présenterons dans une troisième section deux applications de notre méthode sur des cas industriels réels mettant en évidence les apports que présente notre méthode en comparaison avec une réalisation classique de la prévision.

Présentation de l'existant

Nous commençons par présenter les méthodes générales de prévision ainsi que les modèles mathématiques utilisés. Nous détaillerons ensuite les techniques actuelles ainsi que les pistes de recherches dans le domaine du choix de méthode et de modèle dans les cas industriels.

I. Les Méthodes de Prévisions

A. Introduction

Pour la plupart des entreprises, l'établissement de prévisions est un préalable pour une gestion efficace des stocks. Comme l'explique (Lai *et al.* 2006), les prévisions sont la base de tous les systèmes de gestion de production. Toute la Supply Chain s'articule à partir des données issues des modèles de prévisions. Le choix d'une méthode de prévision peut donc influencer le choix d'une politique de gestion des stocks et l'estimation de ses paramètres. Mais le niveau et la fiabilité des stocks vont également influencer d'autres secteurs clés de l'industrie tels que les décisions d'investissements, l'achat d'équipements, la gestion des capacités ou encore la gestion financière de l'entreprise.

Dans (Fleischmann *et al.* 2002), les auteurs montrent l'utilité de la prévision et de la réalisation d'un planning comme un outil d'aide à la décision permettant d'organiser la Supply Chain sur tous les horizons de temps et à tous les niveaux.

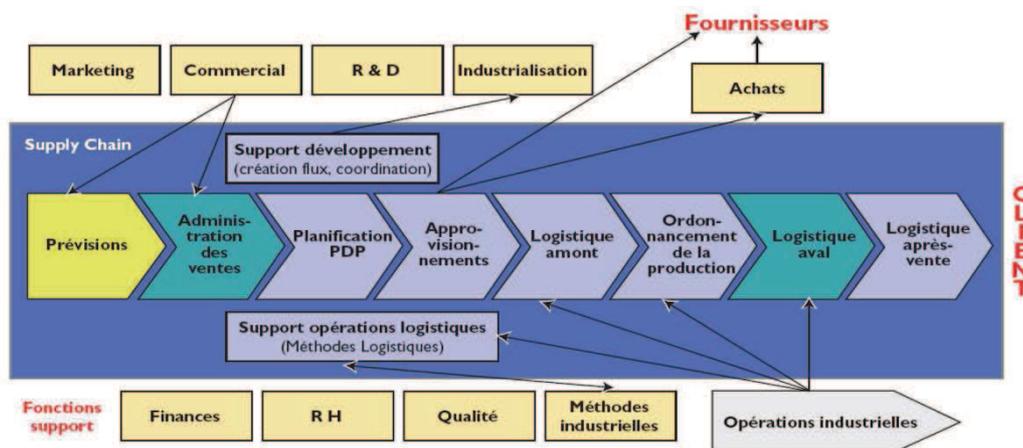


Figure 1: Place de la prévision dans la chaîne logistique globale

La réalisation de cette prévision est donc primordiale pour la compétitivité des entreprises. Les questions à se poser afin de répondre à cette problématique et ainsi pouvoir bien comprendre le processus de réalisation et d'utilisation de ces prévisions sont les suivantes : Quelle demande prévoir ? Qui s'en occupe ? Quel est l'horizon de prévision ? Quelles sont les techniques de prévisions ? Le niveau d'agrégation ? Où se situe la collecte des données ? Quelle est la fréquence de révision ou d'actualisation de cette prévision ? Les modèles utilisés sont-ils testés, validés, remis en cause ? Enfin, y-a-t-il une analyse des écarts constatés ?

Les différentes sources permettant de réaliser ces prévisions se situent tout au long de la chaîne logistique en incluant la partie commerciale de l'entreprise. La demande finale du produit venant de sa consommation, c'est en grande partie l'analyse de cette source qui va permettre de construire la base de la prévision de la demande future. Au final, les sources permettant de construire les prévisions sont donc multiples.

Dans le domaine académique, la prévision occupe une place importante. Étant donné le rôle primordial de la prévision, on comprend pourquoi de nombreux modèles ont été élaborés depuis le début du 20^{ème} siècle. Les recherches se sont principalement développées à partir des années 50 avec l'utilisation de modèles mathématiques. Une revue de la littérature a été effectuée par (Stadtler 2005). On y retrouve l'intérêt de la prévision pour la Supply Chain globale dans le but d'intégrer les différentes organisations et de coordonner leurs flux afin de satisfaire le consommateur final.

B. La réalisation des prévisions

La réalisation de prévision est un processus complexe où chaque tâche se doit d'être réalisée avec la plus grande attention sous peine de dégrader le résultat final de façon non négligeable. La présentation de ce processus complet incluant notamment la récupération des informations, point prépondérant pour permettre une bonne mise en place de la prévision (Lee *et al.* 1997), (Chen *et al.* 2007), n'est pas l'objet de la recherche qui nous intéresse. Nous ne présenterons donc que la partie mise en œuvre de la réalisation pratique de la prévision.

Le schéma ci-dessous tiré de (Bourbonnais & Usunier 2007) présente les étapes classiques de la prévision des ventes.

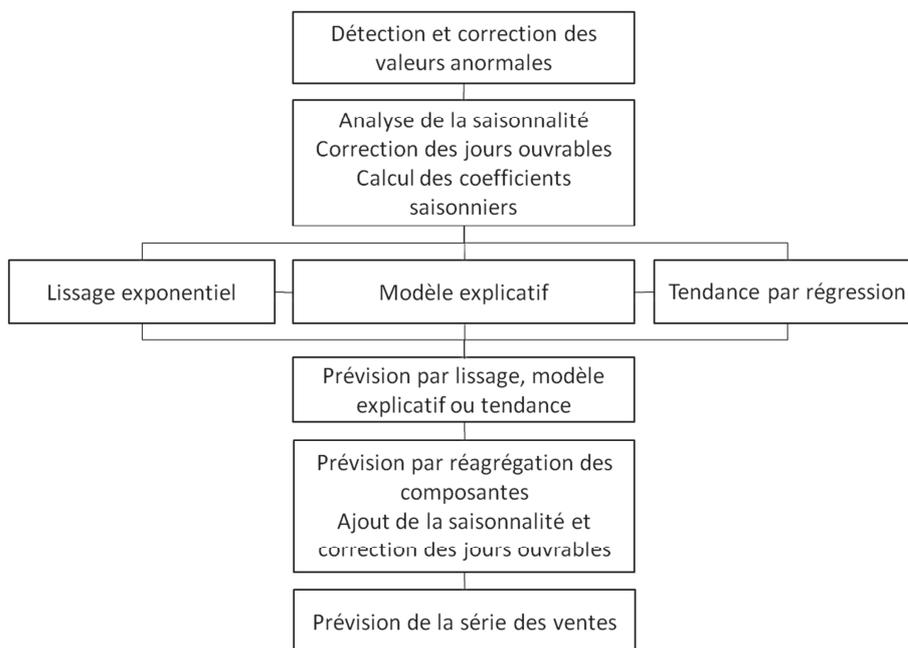


Figure 2: Etapes de réalisation de la prévision des ventes

La détection et la correction de valeurs anormales peuvent se faire selon différentes techniques comme la méthode de l'intervalle (simple ou double) de confiance, la méthode du test de moyenne, ou la détection par régression. La correction peut se faire manuellement, grâce à l'intervalle de confiance ou par estimation par prévision.

L'étape de correction doit également prendre en compte la différence entre les ventes réelles et la demande. En effet, lors de la rupture de stock, la demande n'est pas nulle tandis que les ventes le sont. Pour corriger ces données, plusieurs méthodes ont été élaborées à partir de l'étude du stock disponible et la comparaison entre les ventes moyennes et les ventes relevées. On peut imaginer par

exemple un produit ayant une demande moyenne de cinquante produits par jour avec une faible dispersion. Si dans l'historique, nous observons une demande inférieure à dix produits, une interrogation sur la validité de l'observation est nécessaire. Cette analyse fait partie de l'analyse indispensable précédant le traitement des données préliminaire à la réalisation des prévisions. (Tyagi 2002) met en relief ce problème avec la prise en compte de l'historique des ventes sans traitements lors de la réalisation de prévision dans nombre de cas industriels.

Le calcul de la saisonnalité est important dans le prétraitement des données. Suivant les cas, ce calcul doit se faire à un niveau d'agrégation plus ou moins élevé. En effet, si le calcul de la saisonnalité se fait à un niveau plus agrégé, les résultats seront plus robustes car effectués sur un plus grand nombre de données, de plus, l'effet d'un cannibalisme entre références de même famille est neutralisé. De la même façon, une référence nouvelle ayant un faible historique va pouvoir être rattachée à sa famille de saisonnalité. Par rapport à la saisonnalité, il est important de rester critique vis-à-vis des modélisations présentes dans la littérature. Une majorité de travaux considère la demande comme stationnaire (mais aléatoire) et non variable (avec saisonnalité par exemple), contrairement à la majorité des applications industrielles.

C. Les méthodes de prévisions

Nous présentons ici les principales méthodes de prévisions. Suivant les besoins, chacune de ces méthodes trouve son application. En fonction de l'horizon de prévision, on va pouvoir partager les informations à différents niveaux. Nous retiendrons ici trois horizons.

Une prévision à moyen terme va concerner une planification relevant du Plan Industriel et Commercial (PIC) qui impliquera le lancement ou non de nouveaux produits et la mise en place de moyens de production supplémentaires. Le degré d'agrégation pour cette prévision se situe à la maille de la grande famille de produits (laitage, monospace...). Pour établir cette prévision, il faut principalement réaliser des études de marché.

Une prévision à court terme alimente le Plan Directeur de Production (PDP) établissant la planification des ressources en fonction de la capacité. Nous considérerons ici les familles de produits (yaourt nature, yaourt avec base particulière, monospace avec motorisation essence, ...). Pour réaliser cette prévision, des méthodes statistiques (causales, associatives,...) basées sur des tendances, des saisonnalités, des cannibalisations ou autres vont être utilisées. Certains auteurs comme (Stadtler & Kilger 2005) expliquent que la différence entre une pure prévision de la demande et une planification de la demande est l'adjonction de paramètres exceptionnels à la prévision classique. Ces paramètres sont principalement des données quantitatives comme on le verra par la suite.

Enfin, les prévisions à très court terme vont impacter sur le lancement en production et sur la réalisation finale des produits. La maille utilisée à ce niveau est l'unité de livraison (palette, caisse, monospace couleur vert motorisation 1.6 finition luxe...). Ici encore, des modèles statistiques vont être utilisés.

Dans la Figure 3, nous retrouvons les principales méthodes que nous détaillerons par la suite. Nous pouvons scinder les méthodes de prévisions en deux parties. D'un côté, les méthodes qualitatives regroupant les méthodes s'appuyant sur l'avis d'experts, les enquêtes consommateurs ou les données non quantifiables. De l'autre côté, se trouvent les méthodes quantitatives s'appuyant sur l'étude des données statistiques comme les historiques de demandes ou les corrélations entre les demandes à prévoir et des indicateurs externes (production industrielle, évolution PIB, ...). Nous nous intéresserons dans notre étude principalement aux méthodes quantitatives qui jouent un rôle important dans l'amélioration de la qualité de ces prévisions (Lawrence *et al.* 2006).

L'horizon de prévision qui va être utilisé lors de notre étude se situe entre le court et le moyen terme. En effet, suivant les produits, leurs processus de fabrication, d'approvisionnement, et de

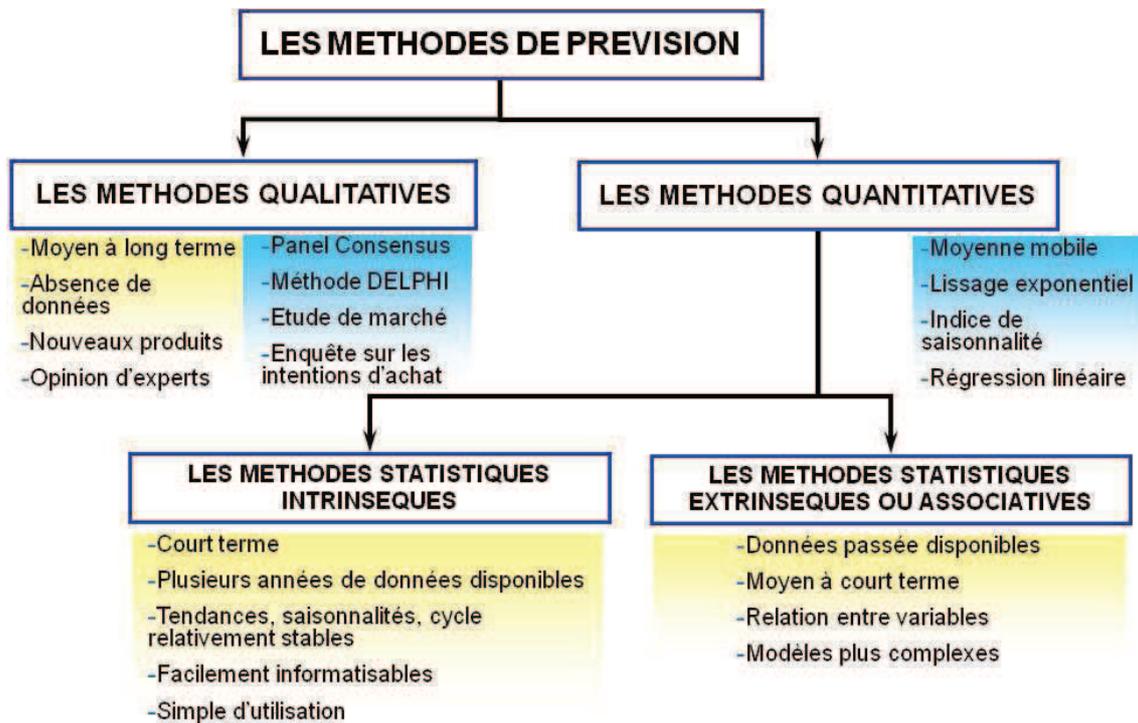


Figure 3: Les différentes méthodes de prévision

demande, ces horizons prennent des échelles différentes.

Une revue des principales méthodes de prévisions (extrapolation, méthodes statistiques, méthodes quantitatives etc.) avec une classification par objectifs et par type d'approche a été réalisée récemment par (Fildes *et al.* 2008). On y trouve également une revue des méthodes de mesure de la précision des prévisions et de l'incertitude prévisionnelle.

Du point de vue de l'outil informatique de prévision, il faut retenir que les critères de choix de l'outil ne sont pas que la rigueur scientifique. En effet, si l'outil intègre l'ensemble des modèles de prévisions de la littérature mais ne permet pas le suivi de la prévision ni de sa fiabilité ou encore

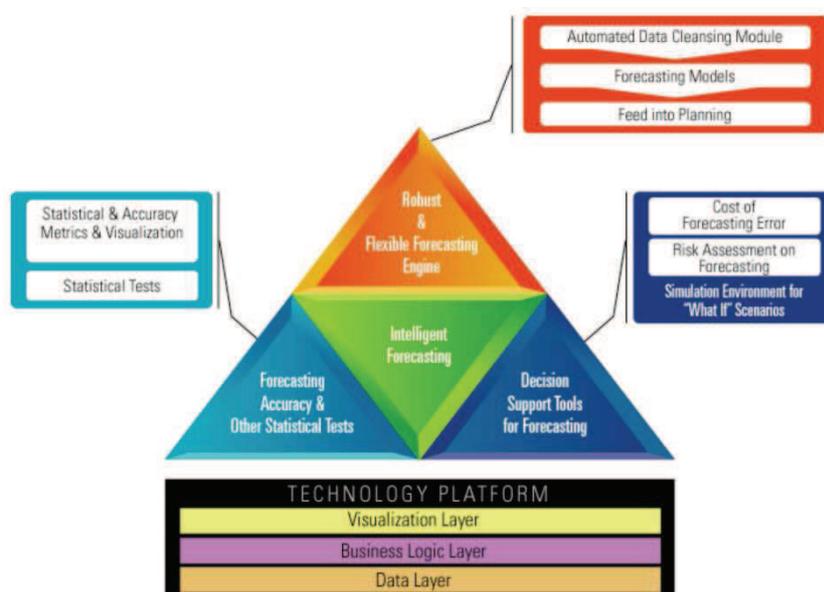


Figure 4: Les piliers d'un outil de prévisions

l'adaptation des modèles aux produits étudiés ou aux spécificités de l'industriel, l'outil n'apportera pas grand-chose. Son intégration dans le système d'information de la chaîne logistique est donc primordiale. Tirée d'un document de l'entreprise Infosys, la Figure 4 illustre clairement les piliers d'un outil de prévisions.

Un point qui est souvent oublié dans le processus de réalisation de prévision est la phase précédant le calcul de la prévision. En effet, les données, une fois récupérées, sont analysées et transformées afin de pouvoir être traitées par des modèles de prévision. Cette transformation permet par exemple d'enlever la saisonnalité ou la tendance pour ne travailler que sur une partie de la série temporelle. Une des méthodes de transformation les plus répandues est celle élaborée par (Box *et al.* 1976). Cette transformation dans certains cas joue un rôle prépondérant dans le résultat final de la prévision comme l'explique (Fukuda 2006). Dans notre étude nous ne nous intéresserons pas à cette partie.

1. Méthodes qualitatives

Les méthodes qualitatives utilisent des données subjectives. Le résultat dépend donc du jugement, de l'expérience et de l'expertise de ceux qui formulent les prévisions. Elles se basent principalement sur :

- Opinion des vendeurs
- Opinion des consommateurs (enquête)
- Opinion d'experts
- Opinion des cadres

Les méthodes qualitatives les plus connues sont :

- Les enquêtes auprès des consommateurs
- Les panels d'experts
- La méthode Delphi
- Les analogies historiques

Les méthodes qualitatives permettent, à l'inverse des méthodes quantitatives, de prendre en compte des facteurs intangibles. De plus, lorsqu'il n'existe que très peu de données comme par exemple lors de l'introduction d'un nouveau produit ou lors de la pénétration d'un nouveau marché, ces méthodes peuvent s'avérer particulièrement pertinentes.

Cependant, le processus de consultation d'experts ou de consommateurs peut être long et coûteux. Il existe également un risque d'obtenir une prévision biaisée ou arbitraire. Enfin, la précision de ce type de prévision est limitée.

2. Méthodes quantitatives

Les méthodes quantitatives sont basées sur des données historiques ou sur des associations entre des variables de l'environnement comme par exemple les ventes mensuelles réalisées au cours des dernières années, les indices boursiers et économiques et les achats de produits complémentaires.

Deux grandes familles de méthodes quantitatives existent : les méthodes de séries chronologiques (suite d'observations dans le temps prises à intervalles réguliers) qui permettent de prévoir la demande en fonction des données historiques, et les méthodes causales (prévisions associatives) qui permettent d'établir des relations de cause à effet entre certaines variables de l'environnement et la demande.

L'avantage des méthodes quantitatives est la rapidité de traitement une fois le modèle développé. Malheureusement, le recueil des données peut parfois impliquer des investissements conséquents. Dans certains cas, ces données sont déjà présentes dans les systèmes d'information de

l'entreprise (ex. ventes des mois passés) ou facilement accessibles (ex. indices économiques) et peuvent alors être plus facilement utilisés.

Malgré cela, des limites à ces méthodes existent. En effet, elles ne tiennent pas compte des facteurs « nouveaux ». De façon à limiter leur complexité, le nombre de paramètres pris en compte est également limité, ce qui impose des choix arbitraires. Enfin, en citant l'adage « *Conduire son entreprise en ayant recours à des prévisions basées sur l'étude de séries chronologiques, c'est comme conduire son automobile en ne regardant que dans son rétroviseur.* », il ne faut pas oublier de toujours garder un œil sur le présent et sur l'avenir.

a) *Les méthodes de séries chronologiques*

1) Moyenne mobile (moving average)

Ce modèle est l'un des plus simples. Dans ce cas, la demande prévue est simplement la moyenne des n dernières demandes. Cette méthode est particulièrement adaptée aux produits ayant une demande quasi constante avec une faible variance. Cette méthode permet également d'éliminer les variations erratiques perturbant les séries. On peut par exemple penser aux produits basiques et de première nécessité. L'expression de cette moyenne est la suivante.

$$p_t = \frac{\sum_{k=1}^n d_{t-k}}{n}$$

p_t est la prévision pour la période t , d_t est la demande réelle pour la période t , et n , le nombre de périodes prises en compte.

Une variante de ce modèle est la moyenne mobile pondérée. Dans ce cas, un poids différent est donné aux demandes des périodes passées.

$$p_t = 2 \cdot \frac{nd_{t-1} + (n-1)d_{t-2} + (n-2)d_{t-3} + \dots + 2d_{t-(n+2)} + d_{t-(n+1)}}{n(n+1)}$$

p_t est la prévision pour la période t , d_t est la demande réelle pour la période t , et n , le nombre de périodes prises en compte. Ce nombre peut varier selon les cas d'étude. Il est difficile de donner une valeur standard. Selon la période de prévision, ce nombre évoluera.

2) Lissage exponentiel

Le lissage exponentiel permet une pondération particulière des données passées. Cette pondération exponentielle permet de donner un poids dégressif aux données passées en fonction de leur éloignement temporel. Le coefficient de pondération permet de choisir le degré de réactivité et de dégressivité de l'importance portée aux données passées. Un coefficient proche de 1 ($\alpha \approx 1$) favorisera les données récentes contrairement à un coefficient proche de 0 ($\alpha \approx 0$) qui donnera un poids similaire à l'ensemble des valeurs prise en compte. Ce modèle est basé sur le principe généralement reconnu que l'histoire récente est une meilleure information que l'histoire ancienne.

$$p_t = p_{t-1} + \alpha(d_t - p_{t-1})$$

$$p_t = \alpha \cdot d_t + (1 - \alpha)p_{t-1}$$

où p_t est la prévision pour la période t , d_t est la demande pour la période t , et α le coefficient de lissage avec $\alpha \in [0; 1]$.

Ce type de modèle est principalement utilisé dans les cas où l'historique proche est une bonne image du futur comparé au passé éloigné. (Tyagi 2002) préconise donc son utilisation dans les cas de saisonnalité sans tendance ou de sensibilité à la météo avec une prévision à une maille temporelle courte (période quotidienne ou hebdomadaire) par exemple. Le modèle va ainsi pouvoir réagir rapidement aux dernières valeurs et adapter la prévision aux dernières observations.

3) Les lissages exponentiels doubles et triples : méthodes de Brown, de Holt et de Winters

Le lissage exponentiel double permet une modélisation de séries chronologiques avec tendances contrairement au lissage exponentiel simple qui nécessite des données stationnaires.

Trois principales variantes du lissage exponentiel simple existent. Il s'agit du modèle de Brown (lissage exponentiel double à paramètre simple), du modèle de Holt (lissage exponentiel double à paramètres doubles) et le modèle de Winters ou Holt/Winters (lissage exponentiel triple) (Cogger 1973). Les modèles de Brown et de Holt sont les premières approches permettant une modélisation de séries chronologiques intégrant une tendance sans saisonnalité. Le modèle de Winters, plus récent, intègre à la fois la tendance et la saisonnalité. Ces modèles sont aujourd'hui très répandus dans les progiciels de prévision. Cependant, la recherche sur ces modèles continue d'être très active, comme on peut le voir dans (Bermúdez *et al.* 2006) avec la modification du modèle de Holt/Winters.

I. Modèle de Brown (lissage double à paramètre simple)

La prévision pour la période $t + h$ est donnée par

$$p_{t+h} = a_{0t} + a_{1t} \cdot h$$

où p_{t+h} est la prévision pour la période $t + h$. h représente l'horizon de la prévision. a_{0t} est le coefficient de la moyenne de la demande et a_{1t} celui de la tendance. Ces coefficients sont déterminés de la façon suivante :

$$\begin{cases} a_{0t} = 2S_t - SS_t \\ a_{1t} = \frac{\alpha}{1-\alpha} (S_t - SS_t) \end{cases}$$

Avec S_t et SS_t (représentant les deux termes de lissage) définis de la façon suivante

$$\begin{aligned} S_t &= \alpha \cdot d_t + (1 - \alpha)S_{t-1} \\ SS_t &= \alpha \cdot S_t + (1 - \alpha)SS_{t-1} \end{aligned}$$

d_t est la demande réelle à la période t .

Et α le coefficient de lissage avec $\alpha \in [0; 1]$.

II. Modèle de Holt (lissage double à paramètre double)

La prévision pour la période $t + h$ est donnée par

$$p_{t+h} = a_{0t} + a_{1t} \cdot h$$

où p_{t+h} est la prévision pour la période $t + h$. h représente l'horizon de la prévision. d_t est la demande réelle à la période t . a_{0t} est la moyenne lissée de la série en t et a_{1t} la pente de la tendance estimée en t . Ces coefficients sont déterminés de la façon suivante :

$$\begin{cases} a_{0t} = \alpha \cdot d_t + (1 - \alpha)(a_{0t-1} + a_{1t-1}) \\ a_{1t} = \beta(a_{0t} - a_{0t-1}) + (1 - \beta)a_{1t-1} \end{cases}$$

Et α est le coefficient de lissage de la moyenne ($\alpha \in [0; 1]$) et β est le coefficient de lissage de la tendance ($\beta \in [0; 1]$).

Pour l'initialisation, $a_{01} = x_1$ et $a_{11} = 0$.

III. Modèle de Holt Winters (lissage triple)

Pour pouvoir utiliser ce modèle, il est nécessaire de définir la périodicité des données : $p = 12$ en mensuel, $p = 4$ en trimestriel pour une périodicité annuelle.

La prévision est alors donnée pour la période $t + h$ par

$$\begin{aligned} p_{t+h} &= (a_{0t} + a_{1t} \cdot h) \cdot S_{t-p+h} & \text{si } 1 \leq h \leq p \\ p_{t+h} &= (a_{0t} + a_{1t} \cdot h) \cdot S_{t-p+2h} & \text{si } p + 1 \leq h \leq 2p \end{aligned}$$

où p_{t+h} est la prévision pour la période $t + h$. h représente l'horizon de la prévision. d_t est la demande réelle à la période t . a_{0t} est la moyenne lissée de la série en t et a_{1t} la pente de la tendance estimée en t . S_t est le coefficient saisonnier en t . Ces coefficients sont déterminés de la façon suivante :

$$\begin{cases} a_{0t} = \alpha \cdot (d_t/S_{t-p}) + (1 - \alpha)(a_{0t-1} + a_{1t-1}) \\ a_{1t} = \beta(a_{0t} - a_{0t-1}) + (1 - \beta)a_{1t-1} \\ S_t = \gamma \cdot (d_t/a_{0t}) + (1 - \gamma)S_{t-p} \end{cases}$$

Et α est le coefficient de lissage de la moyenne ($\alpha \in [0; 1]$), β est le coefficient de lissage de la tendance ($\beta \in [0; 1]$) et γ le coefficient de lissage de la saisonnalité ($\gamma \in [0; 1]$).

Pour l'initialisation, $a_{0p} = \bar{d}$, $a_{1p} = 0$ et $S_t = d_t/\bar{d}$ où \bar{d} est la moyenne des p premières observations de la demande.

L'implémentation du modèle de Winters est présentée en détail par (Lai *et al.* 2006).

Notons que pour les trois exemples de lissages précédents, les paramètres α, β, γ sont fournis par l'utilisateur en début de simulation. Ils sont ensuite raffinés en comparant a posteriori les prévisions passées et les demandes réelles.

4) Modèle de Croston

Dans le cas de produit à rotation très lente (slow moving items), l'historique des ventes est souvent composé de valeurs soit très faibles soit nulles pour certaines périodes ; nous parlerons alors de demande erratique.

Dans ce contexte, l'utilisation de modèle à base de lissage n'est pas appropriée. En effet, pour ce genre de produit, l'apparition d'une commande présage plutôt d'une non-commande pour la période suivante. Dans l'industrie aéronautique par exemple, pour plus de 80% des pièces de rechange, la demande est moins de cinq unités par an, ce qui implique un grand nombre de périodes avec une demande nulle (Ghobbar & Friend 2003), (Regattieri *et al.* 2005).

Une méthode pour ces produits est celle de (Croston 1972) fondée sur deux paramètres : La fréquence de commandes (nombre de périodes séparant deux commandes, et la commande moyenne (nombre moyen d'articles commandés lorsqu'il existe une commande). Comme l'historique est caractérisé par beaucoup de périodes où la demande est nulle, l'approche originale permettant de tenir compte de ces périodes spécifiques est alors d'utiliser la formule du lissage exponentiel pour essayer de prévoir séparément:

- d'une part toutes les valeurs positives de l'historique, c'est-à-dire toutes les sorties de stock (non zero demand) d_t ;
- d'autre part l'intervalle moyen entre chaque sortie (le nombre de périodes durant lesquelles aucune vente n'a lieu) i_t .

Etant donnée la nature aléatoire et probabiliste de la demande, les valeurs de celle-ci sont représentées par une répartition normale de moyenne μ et d'écart type σ : $N(\mu, \sigma^2)$ et les demandes non nulles auront eu lieu selon un processus de Bernoulli de probabilité $1/p$.

Si la demande actuelle à la période t est nulle ($d_t = 0$) alors $p_t = p_{t-1}$ où p_t est la prévision de demande pour la période t , et $i_t = i_{t-1}$ où i_t est l'estimation de l'intervalle séparant deux demandes non nulles et successives (temps d'inter arrivées). Remarquons que les prévisions ne sont pas mises à jour quand il n'y a aucune demande qui arrive à la période t . Alternativement, si la demande actuelle à la période t est non nulle ($d_t \neq 0$), alors $p_t = p_{t-1} + \alpha(d_t - p_{t-1})$ et $i_t = i_{t-1} + \alpha(q - i_{t-1})$ où α est le coefficient de lissage et q une variable mesurant le temps écoulé depuis que la dernière demande non nulle a été observée. Par conséquent, la prévision de la demande par période au temps t est égale à :

$$CR_t = p_t / i_t.$$

Cette méthode a prouvé sa fiabilité et sa précision (Willemain *et al.* 1994) par rapport au lissage exponentiel et a été incorporée dans nombreux progiciels de prévision.

Plusieurs modifications ont été apportées, par la suite, sur le modèle de Croston. Nous retenons essentiellement la modification de (Syntetos & Boylan 2001) et celle de (Snyder 2002) qui permettent d'améliorer la prévision en allant plus loin dans la modélisation de la demande :

- (Syntetos & Boylan 2001) et (Syntetos & Boylan 2005) ont prouvé que la méthode de Croston mène à une évaluation biaisée de la demande par unité de temps dans le cas de produits à forte demande intermittente (fast moving items – demande intermittente avec valeur de demande importante). Ils ont proposé un nouvel estimateur qui n'est rien d'autre que l'estimateur de Croston multiplié par le coefficient $(1 - \alpha/2)$ où α représente le coefficient de lissage. L'estimation de la demande à la période t est alors :

$$SB_t = (1 - \alpha/2) \cdot (p_t/i_t)$$

L'idée de base de cet estimateur repose sur le fait que la moyenne des demandes par période est différente de la moyenne de la demande sur la moyenne des périodes : $Moy(p_t/i_t) \neq Moy(p_t)/Moy(i_t)$ contrairement à Croston où les calculs sont essentiellement basés sur cette dernière relation.

- La modification de (Snyder 2002) repose sur le fait que l'estimation de la demande par période selon la méthode de Croston peut prendre des valeurs négatives. Cela est incompatible avec la réalité. Snyder propose alors la formule suivante pour l'estimation de la demande :

$$p_t = \begin{cases} \log(p_t^+) & \text{si } x_t = 1 \\ \text{valeur arbitraire} & \text{si } x_t = 0 \end{cases}$$

$$p_t^+ = x_t \cdot \exp(p_t)$$

p_t^+ est la prévision de la demande à la période t , et x_t est la valeur de la loi de Bernoulli de probabilité p .

Snyder a également proposé une autre équation, différente de celle de Croston, permettant de détecter la variabilité de la demande d'une part, et de savoir de combien cette variabilité change au cours du temps d'autre part.

5) Technique de ré-échantillonnage avec remise

Toujours dans le cas des produits à faible rotation et à demande intermittente, la méthode de ré-échantillonnage avec remise (bootstrapping) a été proposée par (Willemain *et al.* 2004). L'avantage de cette méthode réside dans l'estimation directe par échantillonnage de l'historique.

Le principe consiste à faire de l'inférence statistique sur de "nouveaux" échantillons tirés à partir d'un échantillon initial. Disposant d'un échantillon destiné à donner une certaine information sur une population, on tire au sort avec remise, parmi la sous population réduite à cet échantillon, un nouvel échantillon de même taille n . On répète cette opération B fois, B étant grand. On analyse ensuite les nouvelles observations ainsi obtenues pour affiner l'inférence faite sur les observations initiales. On obtient ainsi une répartition des demandes sur un intervalle de temps donné. La moyenne de la demande peut alors être déterminée et permettre de déterminer le niveau de stock en fonction du délai de réapprovisionnement.

Des informations plus détaillées concernant le bootstrap sont données par (Willemain *et al.* 2004).

6) Méthode de Support Vector machine (SVMs)

Une autre méthode appliquée aux produits à faible demande ou demande intermittente, comme dans les pièces de rechange pour la maintenance d'une machine, est celle des Support Vector Machine (SVMs). L'idée originale des SVM a été publiée par (Vapnik 2000). Elle est basée sur l'utilisation de fonctions dites *noyau (kernel)* qui permettent une séparation optimale des points du plan en différentes catégories. La méthode fait appel à un jeu de données d'apprentissage, qui permet d'établir un hyperplan séparant au mieux les points. Dans le cas des pièces ayant une demande faible et intermittente, cette méthode permet d'évaluer la probabilité de défaillance des pièces constituant la machine étudiée ainsi que la politique de maintenance de la machine. A partir de ces deux variables, une demande moyenne peut être modélisée. Cette approche est généralement utilisée dans le cadre de la modélisation des problèmes de réseaux de neurones. Cette méthode est développée par (Hua & Zhang 2006) afin de modéliser l'auto corrélation de la demande des pièces de rechange et prévoir la probabilité d'occurrence des demandes non nulles.

En comparaison avec la méthode Croston, la technique de ré-échantillonnage et d'autres méthodes, (Hua & Zhang 2006) ont montré que cette approche donne une meilleure estimation de la demande intermittente. Cependant, sa complexité ne permet pas aujourd'hui de l'implémenter de façon efficace.

7) Modèle avec réseaux de neurones

L'utilisation des réseaux de neurones est relativement récente dans le monde de la prévision. Après avoir été majoritairement utilisé dans des cas stationnaires et avoir donné de bons résultats, (Kang 1991) et d'autres chercheurs dont (G. Zhang *et al.* 1998) ont étudié les applications possibles dans le cas de séries temporelles avec tendances et saisonnalités. La détection simultanée de la tendance et de la saisonnalité offrant la perspective d'avoir un résultat fiable et rapide. Cependant, (Zhang & Qi 2005) ont démontré les limites des réseaux de neurones par rapport à une approche plus traditionnelle avec des modèles tels que celui de Box and Jenkins ou d'autres modèles de type ARIMA principalement à cause du pré-processing des données. De plus, la remise en place de la saisonnalité et de la tendance peut fortement diminuer la précision de la prévision.

a) Les méthodes causales

Les méthodes causales permettent d'établir la relation de cause à effet entre la demande et des paramètres appelés facteurs explicatifs, comme par exemple la consommation d'eau avec la température.

1) Les facteurs explicatifs :

Le choix des variables explicatives est un point essentiel pour l'établissement de bonnes prévisions. Selon les indicateurs retenus, un prétraitement des données afin de corriger les séries statistiques affectées d'une saisonnalité doit être réalisé au risque de masquer la relation entre les ventes et les indicateurs. Dans ces cas, il peut s'avérer nécessaire de les rendre stationnaires pour les intégrer à un modèle donné. Différentes techniques existent comme le lissage par moyenne mobile.

Lorsque plusieurs facteurs ont été retenus, les coefficients de ces paramètres dans le modèle vont être estimés avec des techniques de régression. Pour évaluer l'effet d'un paramètre sur la série, une régression entre ce ou ces facteurs et la série temporelle est réalisée. A partir de là, une fonction apparaissant sous la forme d'une relation peut être définie (régression linéaire, quadratique,...) et ajustée afin de correspondre à la série étudiée. La limite de ces techniques est la recherche et la mise en évidence des facteurs explicatifs. Du fait de l'interdépendance de nombreux paramètres, une approche rigoureuse doit être adoptée.

Cette méthode est utilisée dans les cas où les ventes d'un produit sont corrélées uniquement avec les historiques de ventes d'autres produits (cas des nomenclatures de sous-produits par exemple). (Tyagi 2002) explique que cette méthode fonctionne bien lorsque l'historique des ventes ne permet pas d'avoir une idée de son évolution et qu'il n'apparaît pas de facteurs explicatifs évidents. Des exemples sont les produits de mode ou les produits frais.

2) Modèle ARIMA (Seasonal Autoregressive integrated moving average)

La modélisation de la saisonnalité et de la tendance dans les séries temporelles est une des grosses problématiques de la recherche en prévision. Tout comme le modèle de Winters, les modèles de type ARIMA permettent de modéliser à la fois la tendance et la saisonnalité comme le montrent (Chandra & Grabis 2005). Les premiers travaux datent de 1920 avec la décomposition de Persons. Les premiers modèles de type ARIMA datent de 1960. Cette méthode permet de combiner la puissance de l'auto-régression avec la simplicité de la moyenne mobile. La mise en œuvre de cette méthode implique le choix et la pondération des coefficients explicatifs. Pour cela, plusieurs méthodes existent dont deux principales présentées et comparées par (Kalapanidas & Avouris 2003). Les auteurs utilisent ces méthodes afin de sélectionner les données à inclure pour un modèle de prévision de qualité de l'air. Ces méthodes sont la méthode de filtrage (filtering method) et la méthode d'enveloppe (wrapper method). Les auteurs présentent également l'utilisation d'un algorithme génétique appliqué à la méthode d'enveloppe pour sélectionner les données.

Cependant, son gros désavantage est le prétraitement des données avec la saisonnalité et la tendance de façon à ne modéliser que des données stationnaires. Le modèle de prétraitement ayant eu le plus grand nombre d'applications est celui de (Box & Genkis 1976) sur les modèles ARIMA saisonniers. Ce modèle est celui qui est majoritairement implémenté dans les outils informatiques. Cela n'empêche pas les travaux de recherche sur ce sujet. Après avoir présenté de façon claire et détaillée cette méthode, (Zhang & Qi 2005) étudient le pré-processing des données dans la performance des prévisions. Cette technique nécessite donc des interventions manuelles, que ce soit dans le choix des facteurs explicatifs, ou dans le prétraitement des données. Cependant, cette technique est aujourd'hui l'une des plus efficaces une fois bien mise en place.

Les applications sont multiples comme le montre (Voudouris *et al.* 2006). Les auteurs présentent un outil de planification de ressources humaines à partir d'une prévision obtenue grâce à la méthode ARIMA. D'autres applications, que ce soit pour des exemples de l'industrie lourde avec les appareillages électriques ou l'automobile peuvent être modélisées grâce à ce genre de modèles.

3) La prévision par jugement (judgmental forecasting)

Une revue de la recherche au niveau de la prévision par jugement a été réalisée récemment par (Lawrence *et al.* 2006). Le premier point à retenir de cette revue est l'importance réelle du jugement dans la prévision. Contrairement à ce qui a pu être dit dans les années 80, une prévision ne peut pas se baser uniquement sur des historiques et des modèles mathématiques. Une pondération plus ou moins forte par l'homme en fonction de la connaissance, de son jugement est important et dans certains cas nécessaire afin d'avoir une prévision cohérente. Cependant, cette pondération doit être limitée. En effet, des biais peuvent apparaître (pessimisme, optimisme, influence,...). Des pondérations négatives peuvent également avoir lieu dans certains cas de façon à faire apparaître un résultat voulu et ne correspondant pas à la réalité. La pondération peut donc elle aussi être suivie afin d'en assurer une bonne qualité. La mise en évidence de l'importance et de l'influence de l'historique pour la réalisation de la prévision par jugement est faite par les auteurs.

Comme on peut s'en douter, le fait de prendre en compte des facteurs explicatifs en plus des méthodes mathématiques permet une réelle amélioration des modèles. (Voudouris *et al.* 2006)

préconisent par exemple de prendre en compte les prévisions météorologiques, les vacances et les informations culturelles (événements sportifs, ...) afin de permettre aux prévisionnistes de faire les ajustements nécessaires. (Lawrence *et al.* 2006) vont plus loin en conseillant de toujours coupler une prévision « mathématique » à une prévision « par jugement ». Les bénéfiques sont une amélioration des informations à intégrer grâce à une information toujours à jour, et la possibilité d'intégrer des données non modélisables. Des exemples et applications de la combinaison de méthodes mathématiques et par jugement sont présentés par les auteurs. Enfin, une raison à l'utilisation de la prévision par jugement est la peur de certains managers face à l'utilisation de modèles. (Chen *et al.* 2007) expliquent que parfois, les managers préfèrent se baser sur leur expérience plutôt que sur des outils informatiques.

b) Méthodes associant les méthodes à séries chronologiques avec les méthodes causales

1) Le modèle à indicateurs en avance et la logique du secteur amont

Le recours aux « leading indicators » à des fins de prévisions est relativement classique (Shiskin 1964). Cette méthode s'appuie sur la prise en compte de plusieurs facteurs influençant la demande finale mais à différents niveaux temporels. La prise en compte de différentes variables à décalage temporel variable est également possible. Les hypothèses pour ce type de modèles sont un décalage constant dans le temps ainsi que l'indépendance entre les variables explicatives. Le problème de ces modèles est la difficulté de la multi-colinéarité. De plus, la redondance explicative apporte un flou qui affaiblit le modèle. Un exemple récent de ce type de modèles est donné par (Grogger 2007). L'auteur présente un modèle permettant de prévoir le besoin en traitement de dossiers administratifs d'allocation à partir de l'évolution du marché de l'emploi aux États-Unis. L'auteur présente une nouvelle approche basée sur les chaînes de Markov à la place de séries temporelles et économétriques. Cela permet de mieux prévoir les changements de tendances avec un recalage plus rapide de l'évolution de la demande.

La logique du secteur amont quant à elle s'explique aisément par le décalage qui existe entre la demande en produits finis et la demande en matière première et en produit d'équipement industriel. A partir de la demande en produits finis, nous pouvons remonter à la demande en matière première grâce à la nomenclature des produits. Nous pouvons par exemple penser à l'industrie lourde où la prise en compte de variables explicatives associées à un décalage temporel peut permettre d'avoir une bonne idée du marché futur.

2) Les algorithmes génétiques

Une autre méthode permettant la réalisation de prévision est l'utilisation d'algorithmes génétiques. (Liang & Huang 2006) présentent par exemple une application dans un domaine multi-échelle où ils comparent leur méthode avec trois autres méthodes : une prévision empirique avec coordination entre les échelons ; une prévision réalisée par une moyenne mobile ; une prévision par lissage exponentiel. En moyenne, la prévision par algorithme génétique est la meilleure suivie par la prévision empirique, la moyenne mobile et le lissage exponentiel. Parmi les objectifs, l'optimisation globale de la Supply Chain via le partage d'information et de connaissances est mise en avant pour la réalisation de la prévision.

Le principal avantage apporté par leur technique est l'intégration et la coordination entre les différents acteurs de la Supply Chain via l'algorithme génétique. L'utilisation d'un algorithme génétique permet également une prévision avec un historique plus faible. Afin de limiter l'espace de recherche de solutions, les auteurs préconisent de définir un espace de solutions à partir de la connaissance d'experts.

2. Les stratégies de prévisions et les agrégations

Dans la littérature, il existe deux principales stratégies de prévisions en fonction des agrégations selon (Luna et Ballini 2011) :

- La stratégie top-down consiste à faire des prévisions à partir des données agrégées (agrégation temporelle, par type de produit ou ligne de produit, par région géographique,...). Il s'agit là d'agrèger les produits ayant à peu près les mêmes comportements, puis de faire une désagrégation selon des clefs de répartition définies permettant de faire des prévisions à des niveaux plus fins.

- La stratégie bottom-up consiste à faire l'inverse. Dans cette stratégie, on fait des prévisions pour chaque référence de produit. Ce qui, contrairement au cas du top-down, permet d'analyser les fluctuations au plus fin. On additionne ensuite les prévisions sur les unités de produits afin d'avoir une prévision sur un groupe d'agrégation.

On peut comparer la performance de ces deux stratégies en les appliquant respectivement aux données historiques disponibles.

Selon (Lapide 2006), il est mieux de faire des prévisions sur des groupes d'agrégats, pour descendre à la prévision du niveau le plus fin. Toutefois, cette stratégie est efficace si les agrégats ont des comportements similaires. Dans le cas contraire la meilleure stratégie est le bottom-up.

IV. La validation et le suivi des modèles

Dans la partie précédente, nous avons passé en revue les principaux modèles et méthodes de prévision. Malgré ce nombre considérable de modèles, aucune approche ne peut être jugée comme étant a priori la meilleure technique. C'est pourquoi nous allons voir maintenant les méthodes de validation et de suivis des modèles de prévisions.

Une fois un modèle défini, il va falloir le valider et mettre en place un suivi permettant d'obtenir des valeurs cohérentes et de vérifier ses qualités prévisionnelles pour éventuellement lui apporter des modifications afin de le rendre plus pertinent. (Tanwari & Betts 1999) insiste sur le fait de mesurer l'erreur de prévision et de la suivre afin de faire ressortir des tendances et ainsi mieux comprendre le marché modélisé par la prévision.

Dans le monde industriel, il faut que la validation et le suivi de la prévision soient compréhensibles. En effet, malgré la présence de suivi efficace, si celui-ci n'est pas compris par le responsable de la prévision, des réajustements inutiles peuvent-être faits alors qu'au contraire des erreurs apparemment bénignes peuvent engendrer des dépenses importantes. (Shah *et al.* 2009) insiste sur ce point en s'appuyant sur l'aspect pratique du suivi des prévisions. Les nombreux paramètres de mesure d'erreur peuvent amener une certaine confusion dans leur interprétation respective. Il est donc important de choisir les bons. (Lai *et al.* 2006) par exemple étudie l'influence de la mesure de l'erreur sur la qualité de la prévision réalisée avec un modèle de Winters. Les auteurs étudient également l'impact de cette erreur sur les performances d'un système de production.

- **Validation statistique**

Pour valider la qualité statistique d'un modèle contenant plusieurs facteurs explicatifs, différentes techniques de mesure peuvent être adoptées. On retiendra par exemple le coefficient de détermination, les ratios de Student, ou encore le test de Durbin et Watson qui vont permettre de mesurer la dispersion des coefficients, donc la significativité des variables pour les modèles causaux.

- **Validation économique**

En plus de la validation statistique, il faut valider économiquement le modèle. Des corrélations aberrantes peuvent en effet conduire à des prévisions absurdes ; par exemple, un niveau de stocks chez les clients, corrélé positivement aux ventes futures, ce qui pourrait donner l'impression de doper les ventes (plus de produits à disposition pour les consommateurs) engendre en réalité un arrêt des commandes (stock client plein).

Passons maintenant aux techniques de suivis des modèles de prévisions. Ce suivi est assuré principalement grâce à des indicateurs de performance spécifiquement adaptés aux prévisions. Le but principal est de mesurer la qualité de la prévision par rapport à la demande réelle. C'est ce que l'on appelle la mesure de la justesse de prévision ou Forecast Accuracy (FA). Cette mesure se fait principalement avec des outils mathématiques. En voici un certain nombre offrant différents avantages et inconvénients.

- **Moyenne du pourcentage d'erreur absolue(MPEA) ou Mean absolute percentage error (MAPE)**

Le MAPE est donnée à partir de la distribution de l'erreur pour un ensemble de prévision

$$MAPE = \frac{\sum_{t=1}^n \frac{|e_t|}{d_t}}{n} * 100$$

où n est le nombre d'observations dans la distribution d'erreur, $e_t = p_t - d_t$ est l'erreur de prévision pour la période t , p_t est la prévision pour la période t , et d_t la demande réelle observée pour la période t . L'utilisation de cette mesure n'est pas possible lorsque la demande prend la valeur zéro sur certaines périodes (demande intermittente). Pour pallier à ce problème, (Flores 1986) propose de prendre une erreur de 100% dans ces cas-ci afin de pouvoir utiliser cet indicateur.

- **Écarts moyen absolu (EAM) ou mean absolute deviation (MAD)**

L'écart absolu moyen est défini par le ratio de la somme des écarts en valeur absolue par le nombre d'observations

$$MAD = \frac{\sum_{t=1}^n |e_t|}{n}$$

où n est le nombre d'observations dans la distribution d'erreur, e_t est l'erreur de prévision pour la période t . L'écart absolu moyen est toujours positif. Plus il est faible, plus l'écart entre la prévision et la demande est petit. Cet indicateur n'est pas utilisé dans le cas de demande intermittente ou erratique. En effet, la méthode de Croston aura dans ce cas un EAM très élevé par rapport à celui du lissage exponentiel puisque la série des données inclue un grand nombre de périodes où la demande est nulle malgré que le modèle de Croston ne soit pas moins précis que le lissage exponentiel (Willemain *et al.* 2004), (Teunter & Sani 2009).

- **Carré moyen des écarts (CME) ou medium square error (MSE)**

Le carré moyen des écarts est défini par la somme des carrés des différences entre la prévision et la demande réelle divisé par le nombre d'observations :

$$MSE = \frac{\sum_{t=1}^n e_t^2}{n}$$

Le carré moyen des écarts est préféré à l'écart absolu moyen car il permet de privilégier un système qui introduit plusieurs erreurs ayant de faibles écarts à un système introduisant des erreurs moins fréquentes mais avec des écarts plus importants.

- **Erreur moyenne (EM) ou mean error (ME)**

L'erreur moyenne est tout simplement la moyenne des erreurs de prévision sur les n périodes. Elle est calculée de la façon suivante.

$$ME = \frac{\sum_{t=1}^n e_t}{n}$$

L'erreur moyenne n'est généralement pas incluse dans les analyses du fait de sa limitation. Elle ne prend pas en compte la dispersion des données. Cependant, elle permet de voir si la prévision est biaisée et tend vers une sur- ou sous-estimation.

- **Moyenne normalisée du pourcentage d'erreur absolue (MNPEA) ou mean absolute normalized percentage error (MANPE)**

Cet indicateur est proche du MAPE vu précédemment. Il prend en plus compte de la déviation des données.

$$MANPE = \frac{\sum_{t=1}^n \frac{|e_t|}{\sigma_t}}{n} * 100$$

où σ_t est l'écart-type de la demande sur les période 1 à n . L'intérêt de cet indicateur est sa non-sensibilité à la présence d'aberration ou d'erreurs de mesure contrairement à la majorité des indicateurs de performance. Dans le cas où les séries temporelles étudiées comportent des points aberrants ou des possibilités de grosses erreurs ponctuelles de mesures, cet indicateur est intéressant du fait de son aspect relatif. Il permet par exemple de comparer les performances de méthodes de prévisions réalisées à des niveaux différents. (Schreuder & Klaassen 1984), (Flores *et al.* 1993).

- **Tracking signal (indicateur d'alerte) – mesure du biais**

Un « tracking signal » est une mesure permettant d'indiquer si la prévision moyenne suit les variations principales de la demande réelle, que ce soit en augmentation ou en diminution.

La mise en place de ce suivi peut permettre d'alerter lorsque des écarts de prévision supérieurs à une valeur donnée sont relevés. L'indicateur d'alerte permet d'évaluer de façon continue la méthode de prévision en déterminant si la méthode utilisée nécessite une remise en cause et des modifications. L'objectif est d'améliorer son efficacité en suivant son évolution. Les écarts acceptés pour la prévision sont déterminés par le prévisionniste en fonction de paramètres classiques (précision souhaitée). Son utilisation peut se comparer à un filtre appliqué à la variation de l'erreur ou du processus suivi, lui laissant une certaine flexibilité.

Les applications du « tracking signal » sont donc l'évaluation de méthodes de prévisions, l'indication de changement dans l'évolution de la demande. Les suivis des niveaux de stocks peuvent également être réalisés de cette façon. Un exemple de choix, de mise en place et d'utilisation des « tracking signals » est présenté par (Alstrom & Madsen 1996). Les indicateurs d'alertes sont donc préconisés pour détecter les changements de niveaux, de tendance et de saisonnalité des produits.

Les avantages de cette méthode sont une mesure permettant de voir si l'évolution est positive ou négative d'un point de vue mathématique contrairement à des indicateurs tels que le MAD. Ainsi l'évolution de l'erreur est clairement suivie. Sa grande polyvalence lui permet également de suivre la majorité des méthodes de prévisions. Enfin, les qualités dynamiques des indicateurs d'alertes ont été mises en évidence par (Sastri *et al.* 1989).

La détermination du Tracking Signal se fait avec la relation suivante.

$$TS = \frac{\sum_{t=1}^n e_t}{MAD}$$

Cependant, cet indicateur peut fournir des résultats aberrants lors d'erreur de prévision, donc de MAD, très faible. Enfin, suivant les limites choisies, une petite déviation sans conséquence peut causer une alerte. Enfin, comme le montre (Alstrom & Madsen 1996), le choix de l'indicateur en fonction de la méthode de prévision n'est pas sans importance et sans difficulté.

Une autre application du tracking signal est présentée par (Voudouris *et al.* 2006) avec la mise en place d'alerte afin de vérifier les modèles de prévisions et les variations de la demande.

- **Etude de l'incertitude prévisionnelle**

L'incertitude prévisionnelle est d'une grande importance dans toute décision basée sur des estimations de demandes futures, comme les décisions de planification de la production et de pilotage des flux. En gestion des stocks, (Brown 1959) a montré l'importance de l'utilisation de l'incertitude prévisionnelle, notamment pour le calcul des stocks de sécurité.

Les incertitudes prévisionnelles représentent l'écart entre les demandes réelles et les prévisions. En pratique, il est important d'étudier les incertitudes prévisionnelles, parce qu'elles permettent d'analyser la précision des prévisions passées, pour comprendre quelles erreurs ont pu être faites dans leur détermination. Pour avoir une bonne estimation de l'incertitude prévisionnelle, il est donc indispensable de commencer par étudier et analyser l'historique des prévisions et ensuite, d'utiliser une méthode fiable pour la détermination de l'incertitude prévisionnelle.

Plusieurs méthodes sont proposées dans la littérature pour la détermination de l'incertitude prévisionnelle. Elles sont regroupées, comme les prévisions de la demande, en deux familles : Les méthodes qualitatives et les méthodes quantitatives.

Ces incertitudes ne sont pas uniquement des incertitudes sur la demande. Le rendement ou le temps de cycle d'un outil industriel peuvent également engendrer des incertitudes. Dans le cas de la gestion des stocks, l'incertitude sur la quantité et la date de réapprovisionnement dans le cas mono-produit avec demande non stationnaire a été étudiée par (Graves 1999) avec le développement d'une heuristique.

L'étude de l'incertitude prévisionnelle fait l'objet de notre second chapitre. Nous reviendrons donc plus en détails sur ce point par la suite.

- **Mesure économique de la qualité de la prévision**

Malgré le grand nombre d'indicateurs statistiques que nous avons vus précédemment, la qualité d'une prévision n'est pas forcément mesurée au mieux avec ces outils. En effet, suivant les différents coûts engendrés par une erreur de prévision (rupture ou surstock), une sur-prévision n'aura pas les mêmes conséquences, que son opposé. (Roberts & Whybark 1974) explique alors que le coût impliqué par chaque erreur de prévision est sans doute la meilleure mesure de la qualité de la méthode de prévision. Par conséquent, une mesure économique de la prévision se révèle être un excellent indicateur afin d'avoir une mesure de la prévision permettant de manager la Supply Chain vers le coût optimal. C'est ce que (Wright 1986) a mis en évidence en insistant sur le fait que le coût n'est pas forcément symétrique, ce qui implique qu'une moyenne de zéro au niveau de l'erreur de prévision n'est pas forcément optimale. A partir de ces travaux, des indicateurs ont été proposés comme celui de (Flores *et al.* 1993) qu'ils ont utilisé dans le secteur de l'industrie électronique. La qualité de la prévision est mesurée à partir du coût engendré par l'erreur de prévision : Total Cost = C (inventory cost) + L (opportunity carrying cost of a lost sale) + P (ordering cost).

Le problème du coût de l'erreur de prévision et son biais par rapport aux indicateurs statistiques est également abordé par (Lai *et al.* 2006). Les auteurs se penchent sur l'étude de l'influence de la mesure de l'erreur et la prise en compte du coût de l'erreur sur le choix des paramètres pour le

Material Requirement Planning (MRP). Leur conclusion est que l'utilisation d'indicateurs statistiques classiques ne permet pas l'obtention d'un coût d'erreur minimum.

Pour de plus amples précisions quant aux modèles mathématiques de prévisions, nous pourrions nous référer à (Bourbonnais & Usunier 2007).

V. Conclusion

Dans ce chapitre, nous avons présenté les principaux modèles de prévision utilisés dans le domaine industriel ainsi que les travaux portant sur ces thématiques. En plus des méthodes de prévisions, nous avons également présenté les indicateurs permettant de mesurer la qualité des prévisions.

En regard de ces présentations et des travaux portant sur ces sujets, nous voyons bien l'intérêt que présente un système permettant de réaliser des prévisions de qualité pour le bon fonctionnement de la Supply Chain. En effet, il est clair que, dans le cas de produits de grande consommation nécessitant des temps de fabrication supérieurs au délai acceptable par le consommateur, l'utilisation de prévision est la meilleure solution pour assurer un bon fonctionnement de la chaîne d'approvisionnement des flux logistiques. L'amélioration de cette dernière afin d'ajuster au mieux les approvisionnements en fonction de la demande réelle est nécessaire pour, dans un second temps, optimiser le fonctionnement de toute la chaîne d'approvisionnement. Pour cela, la prévision ne pouvant être parfaite, la mise en place d'une sécurisation de la variabilité commerciale grâce à l'étude de l'erreur de prévision (également appelée « incertitude prévisionnelle »), la mise en place de stocks de sécurité adaptés ou encore la collaboration entre les différentes personnes intervenant dans la Supply Chain doit être maximisée.

Nous allons maintenant nous attacher à améliorer la qualité des prévisions. C'est à cette fin que nous avons développé une méthode permettant de déterminer quel modèle utiliser et quand le remettre en cause. La section suivante présente cette méthode.

Processus de choix d'une méthode de prévision appropriée

Suite à l'introduction de la prévision et des modèles existants, nous allons maintenant présenter la méthode de choix de modèle de prévision que nous avons développée au cours de notre travail de recherche. Cette méthode, comme nous allons le voir, s'inspire des travaux de la littérature afin de proposer une méthode innovante permettant un fonctionnement rapide pour des besoins industriels et performante afin de garantir une qualité de prévision qui pourra s'adapter aux besoins de l'utilisateur. De plus, cette méthode peut être rapidement implémentée dans un contexte industriel et se lier à tout type d'ERP industriel.

Nous allons donc commencer par présenter les méthodes de choix de modèles de prévisions existantes pour dans un second temps présenter la méthode développée avec son algorithme de choix de modèle de prévision à proprement parler.

I. Choix de méthodes et de modèles de prévisions

La littérature contient nombre de références mettant en évidence l'inexistence d'un modèle générique de prévision adapté à chacun des cas possibles. (Makridakis 1986) par exemple explique que le fait d'imaginer qu'un unique modèle de prévision puisse fonctionner dans toutes les situations n'est pas raisonnable vis-à-vis de l'évidence empirique. Il apparaît donc clairement qu'il va falloir choisir un modèle de prévision différent selon les cas afin de pouvoir obtenir la meilleure prévision possible. Mais, comme l'explique (Fleischmann *et al.* 2002), il existe plusieurs objectifs en ce qui concerne la réalisation de prévisions, et il n'est pas toujours utile d'avoir le modèle donnant la meilleure prévision, si par exemple, la configuration du modèle en question nécessite des ressources particulières. C'est pourquoi un compromis est nécessaire entre les différentes contraintes et les objectifs de prévisions. De plus, du fait du grand nombre d'alternatives au niveau des modèles de prévision permettant d'avoir des solutions acceptables, nous assistons à une complexification du problème de choix de méthodes et de modèles de prévisions.

Face à ce problème, trois solutions sont possibles. La plus simple consiste à appliquer un modèle de prévision unique pour l'ensemble des cas rencontrés (en générale une moyenne mobile ou un lissage exponentiel). L'unique avantage de cette méthode est une mise en place simple et rapide. En effet, une seule méthode de prévision est à implémenter pour l'ensemble des produits dont la prévision de la demande va être réalisée. Contrairement à ce qui pourrait être imaginé, cette méthode est encore utilisée aujourd'hui pour certaines applications industrielles. Du fait de la limitation de ses performances par son côté statique et uni-modèle, nous n'étudierons pas cette première méthode dans la suite. Une deuxième solution, plus intéressante consiste à tester l'ensemble des modèles de prévisions aux produits étudiés afin de retenir le meilleur. Aujourd'hui, la majorité des approches se font uniquement par comparaison des différentes méthodes après simulation. Le problème de cette méthode est son caractère chronophage. Une troisième solution est donc proposée. Après avoir classé les produits considérés en famille homogène au niveau du type de demande, un algorithme de choix de modèle de prévision peut être proposé afin de

présélectionner pour chaque famille définie un type de modèle de prévision adapté. Cette méthode est d'après (Syntetos *et al.* 2004) actuellement implémentée dans les progiciels de prévision. Cependant, les auteurs critiquent le côté arbitraire de la catégorisation de la demande. Comme l'explique (Shah *et al.* 2009), il est important pour avoir des prévisions de qualité que celles-ci soient continuellement adaptées aux produits étudiés. L'outil proposé permet donc de suivre de façon continue les paramètres de la demande ainsi que la qualité de la prévision afin d'adapter le modèle de prévision à celle-ci. Ainsi, des changements au niveau des méthodes et modèles de calcul de la prévision peuvent être réalisés. La mise en place d'un processus d'auto-adaptation de la méthode de prévision permettrait donc d'améliorer la flexibilité et l'efficacité du système de prévision.

Nous allons maintenant présenter de façon plus précise les deux dernières méthodes que nous avons introduites.

A. Deuxième méthode : choix initial et limité

La seconde méthode que l'on retrouve dans le monde industriel est plus performante mais reste limitée dans son utilisation. Dans ce cas, la méthode consiste à modéliser et tester un ensemble de méthodes de prévision donné pour un unique cas particulier jugé représentatif des produits de l'entreprise. Après avoir comparé les différents modèles à l'aide d'indicateurs de performances, un modèle de prévision est sélectionné et appliqué à l'ensemble des produits de l'entreprise. Cette méthode va donc bien fonctionner sous la condition d'avoir des produits homogènes ayant des caractéristiques très proches. Il faut également avoir un panel de modèles assez large lors de la phase de choix de modèle. Dans la pratique, les modèles retenus sont principalement les moyennes mobiles, les lissages exponentiels (modèle de Brown, Holt ou Winters) et le modèle de Croston pour les demandes erratiques. Les modèles plus complexes (type ARIMA) ne sont pas implémentés car souvent trop compliqués par rapport aux gains espérés et à la probabilité d'être adaptés au cas étudié.

Au niveau de la comparaison des différents modèles de prévisions, la littérature est très vaste. Une des méthodes permettant de comparer efficacement les modèles de prévision est celle utilisée entre autre par (Lawrence *et al.* 2006) et initiée par (Makridakis *et al.* 1982). Il s'agit de la méthode « M1 Forecasting Competition » qui compare la qualité de la plus grande majorité des modèles de prévision à partir d'un ensemble de 1001 séries temporelles (annuelles, trimestrielles ou mensuelles) tirées d'applications réelles dans des domaines variés tels que les stocks, les ventes, la démographie ou la finance. Il existe dans la littérature un certain nombre de travaux portant sur l'étude et la comparaison des modèles de prévisions. Parmi les plus récents, (Voudouris *et al.* 2006) compare le modèle de Holt-Winters à des modèles particuliers tels que le Conditional Probability Forecast with Empirical Adjustment Coefficient, le Conditional Probability Forecast with Actual Correlation Coefficient ou encore le modèle ARIMA. Les gains calculés sont de l'ordre de 64% au niveau de l'indicateur MSE entre une prévision manuelle et le modèle ARIMA.

Au niveau des demandes intermittentes, le modèle de Croston, ses variantes, les méthodes traditionnelles de prévision et la technique de ré-échantillonnage avec remise ont été comparées dans un grand nombre d'études. Citons par exemple (Willemain *et al.* 1994), (Johnston & Boylan 1996), (Sani & Kingsman 1997) ou encore (Eaves & Kingsman 2004). Les conclusions de ses nombreuses comparaisons sont que le modèle de Croston est globalement meilleur que le lissage exponentiel simple pour les séries intermittentes dont la proportion de demandes nulles est d'au moins 66%.

Cependant, le modèle de Croston ne semble pas être le meilleur. En effet, les résultats ont montré que la technique de ré-échantillonnage avec remise et la modification de Syntetos étaient les meilleurs estimateurs de la demande intermittente (Regattieri *et al.* 2005), (Syntetos & Boylan 2005).

Ce résultat se base également sur l'étude de l'indicateur PMR (pourcentage moyen de regret) correspondant au rapport du taux de service réalisé sur le taux de service maximal possible.

La fiabilité du modèle de Syntetos et Boylan a toutefois été minorée par (Teunter & Sani 2009) qui ont montré que le modèle de Croston était faiblement biaisé lorsque $1/i$ était grand (i : intervalle entre deux demandes non nulles, donc peu de demandes nulles) tandis que la modification de Syntetos/Boylan était moins biaisée dans les autres cas ($1/i$ petit, c'est-à-dire beaucoup de demandes nulles).

En ce qui concerne la technique de ré-échantillonnage et le SVMs, les seuls résultats proviennent de (Willemain *et al.* 2004) et (Hua & Zhang 2006) qui ont comparé ces méthodes avec des indicateurs purement statistiques. Ils trouvent alors que la méthode des SVMs est la meilleure dans le cas des demandes intermittentes.

B. Troisième méthode : adaptation

La 3^{ème} méthode la plus complexe mais aussi la plus efficace repose sur deux phases. La première consiste à classer les produits en familles homogènes vis-à-vis de leur demande. La seconde consiste en la recherche et la validation d'un modèle pour chacune de ces familles. Il faut donc avoir un panel de modèles de prévision suffisamment large permettant de choisir de façon sélective et dynamique le modèle le plus approprié à chacune des familles identifiées. Cette technique a l'avantage de permettre d'éviter une fastidieuse modélisation de tous les modèles. De plus, son caractère automatisable doit lui permettre d'avoir un suivi dynamique du modèle de prévision, et ainsi garantir sur chaque période, pour chaque produit, une prévision la plus juste. Nous allons commencer par présenter la phase de classification de la demande et des produits avant de rentrer dans la phase de recherche et de validation du modèle.

1. Classification de la demande et des produits

a) Demande intermittente

(1) Classification de Williams

(Williams 1984) propose une classification basée sur la sporadicité de la demande. Cette classification est particulièrement adaptée au cas des pièces de rechanges ayant une demande intermittente. Trois types de demande sont définis :

- Demande régulière : Smooth demand
- Demande à rotation lente : Slow moving
- Demande intermittente : intermittent demand

Cette classification est basée sur la décomposition de la variance de la demande durant le délai d'approvisionnement en trois variabilités : celle du nombre de commandes arrivant durant le délai d'approvisionnement, celle de la taille de la demande et celle du délai d'approvisionnement. L'équation de Williams est alors définie comme suit :

$$C_{LTD}^2 = \frac{C_n^2}{L} + \frac{C_z^2}{\bar{n}L} + C_L^2$$

où C_{LTD}^2 est le coefficient de variation de la demande durant le délai d'approvisionnement, C_n^2 le coefficient de variation du nombre de commandes, C_z^2 le coefficient de variation de la taille de la demande et C_L^2 celui du délai d'approvisionnement. \bar{L} représente le délai moyen d'approvisionnement et \bar{n} le nombre moyen de transactions.

Dans le cas d'une demande qui suit une loi de Poisson, par exemple, cette relation prend la forme suivante

$$C_{LTD}^2 = \frac{1}{\lambda\bar{L}} + \frac{C_z^2}{\lambda\bar{L}} + C_L^2$$

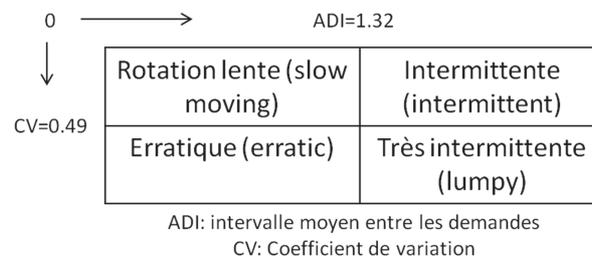
D'après Williams, la demande peut être alors répertoriée de la façon suivante :

Tableau 1: Classification de Williams

$1/\lambda\bar{L}$	$C_z^2/\lambda\bar{L}$	C_L^2	Type de demande
Low			Smooth
High	Low		Slow-moving
High	High	Low	Sporadic
High	High	High	Sporadic, with highly variable lead time

Williams précise cependant que cette classification est limitée car elle ne considère que le cas d'une demande qui suit une loi de Poisson. D'autres classifications reprenant la variabilité de la demande ont donc été élaborées. Les auteurs ayant travaillé sur ce point sont (Ghobbar & Friend 2003), (Eaves & Kingsman 2004) ou encore (Regattieri *et al.* 2005). Leur classification peut être résumée par la figure suivante.

Tableau 2: Classification de Ghobbar

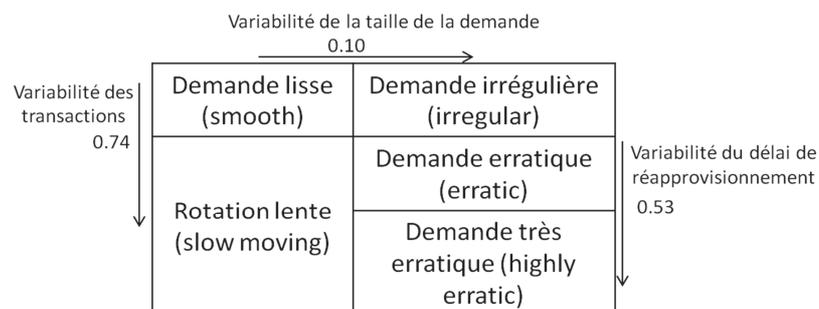


On remarque ici que la demande est classifiée en quatre catégories en fonction de la variation du coefficient de variation de la demande et du temps moyen entre les demandes non nulles.

(2) Classification de Eaves

Cette classification diffère quelque peu de celle de Ghobbar. (Eaves & Kingsman 2004) a estimé que la classification de Ghobbar était limitée par sa non prise en compte de la variabilité des transactions. Il a donc donné une autre classification basée sur la variabilité du taux de transactions, la variabilité de la taille de la demande ainsi que la variabilité du délai de réapprovisionnement.

Tableau 3: Classification de Eaves



b) Demande intermittente et continue

Cette classification a été utilisée par (Flores *et al.* 1993) afin d'en définir une plus large permettant une présélection du type de modèle de prévision. Cependant, dans cette classification les modèles utilisés ne prennent pas en compte la saisonnalité. Elle se base sur l'historique des ventes et la qualité de prévision escomptée :

- Nouveaux produits pour lesquels il n'y a pas d'historique.
La méthode de prévision devra dans ce cas ajuster rapidement sa réponse aux premières erreurs détectées et poser au fur et à mesure des ajustements de la prévision avec la construction de l'historique. Les propositions de (Flores *et al.* 1993) sont l'utilisation du lissage exponentiel avec la recherche du coefficient de lissage adéquat.
- Les produits pour lesquels un historique de la demande est disponible
Dans ce cas, le besoin est une méthode utilisant un algorithme de prévision efficace comme la moyenne mobile ou le lissage exponentiel. Dans ce cas, (Flores *et al.* 1993) propose le lissage exponentiel double avec paramètre unique de Brown.
- Les produits avec historique de demande et pour lesquels une forte qualité de prévision est nécessaire
Cette situation requiert des modèles plus variés et des combinaisons de méthodes de prévision. Les différentes méthodes doivent être testées. L'utilisation d'une méthode de prévision adaptée à partir d'un lissage exponentiel simple est testée par (Flores *et al.* 1993).
- Produits pouvant tolérer une faible qualité de prévision
Ces produits doivent impliquer de faible coût. Les erreurs auront donc un faible impact économique d'où l'utilisation de modèle basique. Pour ce cas basique, l'utilisation d'une moyenne mobile est suffisante.

Une classification très importante est celle reprenant le type de demande. Des critères comme la rotation, la variabilité, la tendance ou la saisonnalité peuvent permettre de départager les familles. L'expérience du prévisionniste peut également permettre de travailler sur ce point. On a pu voir que certains modèles ne permettaient pas de traiter les cas avec saisonnalité contrairement à d'autres. Il faut donc, lors de la classification, définir un algorithme de choix de famille de plus en plus spécifique afin de l'adapter aux produits étudiés et aux modèles de prévision disponibles.

2. Recherche et validation du modèle adapté

Dans les prévisions, bien souvent, une technique particulière va se révéler être la meilleure à un moment donné tandis qu'une autre technique sera plus performante à un autre moment. A chaque fois qu'une prévision est réalisée, un outil de prévision doit permettre un choix dynamique permettant de choisir pour quelle technique opter. Cette méthode de prévision est appelée prévision adaptative ou « pick-best » (Tyagi 2002). Elle est nécessaire dans les cas où une grande qualité de prévision est nécessaire sur chaque intervalle de temps. Comme on l'a dit, ce choix de méthode de prévision va être réalisé en fonction du type de demande à étudier. Une demande stable sera approchée avec une moyenne mobile et/ou un lissage exponentiel simple. Une demande avec tendance pourra être prévue via un lissage exponentiel double et/ou une prise en compte de cette tendance. Si la demande à prévoir est fortement influencée par la saisonnalité, le modèle de prévision devra également la prendre en compte.

Parmi les travaux récents sur les méthodes de choix de modèle, (Bermúdez *et al.* 2006) s'intéresse au choix du modèle tout en restant dans la classe des modèles de prévision par lissage exponentiel (modèle de Holt-Winters). Les auteurs ont intégré les phases d'estimation et de sélection

dans une unique structure d'optimisation permettant d'identifier les solutions les plus robustes. Après l'initialisation des modèles de prévisions en les adaptant aux données, ils sont optimisés suivant les critères de mesures de performances. Le meilleur est ensuite sélectionné grâce à une approche multicritère (fuzzy multicriteria approach). Cette approche est très intéressante dans sa démarche et donne de très bons résultats. Cependant, les modèles causaux ne sont pas intégrés, ce qui donne des perspectives d'améliorations supplémentaires.

En effet, c'est dans la façon de bâtir et de comparer les modèles de prévision que la différence peut se faire et apporter la dynamique nécessaire à cette évaluation. (Shah *et al.* 2009) propose l'approche suivante pour la prévision du besoin en ressource humaine dans le cadre d'un centre d'appel gérant la mise à disposition de techniciens ayant des compétences différentes et étant situés sur des zones géographiques également différentes. Trois axes de prévisions qualifiant la demande ont donc été identifiés : La rapidité d'intervention souhaitée, la compétence nécessaire et la zone géographique concernée. A partir de là, les auteurs proposent de partir de modèles de prévision simples pour aller vers des modèles plus complexes tant que cela apporte un gain au niveau de la qualité de la prévision. Du fait de la volatilité de la demande au niveau désagrégé, les auteurs conseillent de partir du niveau agrégé et de descendre ensuite en affinant le modèle. Cette idée a été précédemment émise par (Simchi-Levi *et al.* 2000). Ils ont montré que l'incertitude diminuait avec l'agrégation des données. L'idée présentée par (Shah *et al.* 2009) s'applique pour la désagrégation de la prévision. Il faut bâtir des modèles robustes pour commencer dans une des trois dimensions de la demande (ici, la zone géographique), les confronter aux données réelles, puis préparer les modèles pour la maille inférieure (ici, le domaine géographique). Une fois la qualité de la prévision jugée suffisante, les auteurs proposent d'éclater ces modèles en fonction des deux autres dimensions : la compétence et la gestion du temps dans leur exemple. Cette approche permet de bien cerner la perte de justesse dans la prévision et ainsi se concentrer sur les points les plus sensibles en termes de qualité de prévision. Un des points clefs est donc la prise en compte des particularités de la demande les unes après les autres. L'étude des ressemblances entre les différentes demandes permet également de gagner du temps en travaillant par comparaison. Au niveau de la définition de l'agrégation des données, (Chen *et al.* 2007) ont étudié l'effet de la prévision et de l'agrégation des données sur les stocks de sécurité et l'organisation du planning de production et l'effet de la corrélation des demandes sur le choix du demand planning.

Enfin, des points importants à ne pas négliger sont d'une part, que la conjugaison de différents modèles de prévision peut permettre d'apporter une plus grande stabilité à la prévision avec, dans certains cas, une perte au niveau de la qualité de la prévision. Un compromis doit donc être trouvé afin d'avoir une prévision la plus stable avec une qualité définie. D'autre part, il est évidemment important de laisser au prévisionniste la possibilité de modifier sa prévision comme le préconise (Voudouris *et al.* 2006).

Comme on l'a vu en introduction, cette troisième méthode a été critiquée par (Syntetos *et al.* 2004) du fait de la catégorisation arbitraire de la demande. Les auteurs proposent donc une autre solution. Celle-ci consiste en la comparaison de trois modèles de prévision (EWMA, Croston et Croston-Syntetos-Boylan) en fonction du type de demande intermittente. Cette comparaison permet de définir des domaines de supériorité entre les modèles vus précédemment. Les demandes à prévoir sont ensuite classées parmi ces domaines de supériorité, ce qui permet de leur affecter un modèle de prévision qui peut alors être optimisé. Dans l'exemple proposé par les auteurs, les deux paramètres de catégorisations sont la moyenne des temps d'inter-arrivées de demandes et le coefficient de variation de ces demandes. L'utilisation de paramètres supplémentaires induirait un

chevauchement des domaines de supériorité ce qui poserait des problèmes de choix de modèle. La comparaison se fait grâce à l'indicateur statistique MSE du fait de sa facilité de suivi.

Ces méthodes, bien que performantes pour des cas statiques peuvent être améliorées en combinant une rapidité d'exécution grâce à la limitation de la remise en cause du modèle utilisé et qualité en permettant l'utilisation d'un modèle de prévision spécifiquement adapté au cas de prévision étudié. En effet, les deux méthodes que nous avons présentées de façon détaillée ne permettent pas une remise en cause du modèle, que celui-ci soit issu d'un choix suite à une comparaison de la performance de différents modèles, ou qu'il soit issu d'un choix suite à la catégorisation de la demande. De ce fait, la qualité de la prévision réalisée a de grande chance de se dégrader en particulier si les produits ont des profils de demande changeant. C'est la raison pour laquelle nous proposons une nouvelle méthode de choix dynamique de modèles de prévision.

II. Méthode développée

A la lumière des études présentées précédemment, notre but a été de proposer une nouvelle méthode qui permet de sélectionner la méthode de prévision correspondant le mieux à l'objectif recherché que ce soit en terme de qualité de prévision ou de rapidité d'exécution propre à une utilisation industrielle pratique.

Pour cela, nous avons choisi de définir une classification amont qui permet de déterminer si nous allons nous orienter vers une prévision à dominante qualitative ou une prévision à dominante quantitative. Cette classification amont s'appuie sur l'historique des données disponibles. Suite à cela, nous appliquons notre méthode adaptée aux modèles quantitatifs.

A. Classification amont

Nous allons commencer par regarder si un historique est disponible. Si c'est le cas, nous allons nous orienter vers une prévision à base de méthodes quantitatives qui pourra cependant être mixé *in fine* avec des méthodes qualitatives. Cette catégorie peut ensuite encore être divisée en fonction de la taille d'historique disponible. En effet, selon que l'historique est supérieur à 24 mois ou inférieur à 3 mois, les modèles quantitatifs utilisables ne seront pas les mêmes, il faut donc utiliser les modèles de prévision adaptés au cas dans lequel on se trouve.

S'il n'y a pas d'historique disponible, plusieurs informations vont nous permettre de réaliser une prévision. Les méthodes utilisées dans ce cas sont principalement des méthodes qualitatives. Nous regardons d'abord s'il existe un produit similaire. Si c'est le cas, une comparaison du produit dont nous cherchons à réaliser la prévision de vente avec un produit similaire pourra nous donner le profil prévisionnel de la demande et permettre la réalisation d'une prévision par extrapolation. Cette comparaison pourra également nous informer sur le marché du produit et donc l'évolution possible des ventes (cas d'un produit de remplacement). Dernière possibilité d'étude avec un produit similaire, s'il s'agit d'un produit identique mais appartenant à un lot différent (cas de produit vendu en pack ou à l'unité), le profil de vente du nouveau produit pourra être extrapolé à partir de la demande du produit comparé.

Enfin, dans le cas où il n'y aurait pas de produit comparable, l'analyse du cycle de vie du produit doit donner une information permettant de savoir si la demande va augmenter, stagner ou diminuer. La particularité du produit (durée de vie courte comme les produits culturels (livre, musique, ...) ou long comme les pièces automobiles) permet également de préciser le profil de demande du produit et son évolution.

Tous ces critères sont représentés sur le Tableau 4.

Tableau 4: Classification des demandes en fonction de l'historique des demandes disponible

Etude de l'historique											
Présence d'un historique de demande du produit											
Oui Utilisation de méthodes quantitatives (et qualitatives)				Non Utilisation de méthodes qualitatives (et quantitatives)							
plus de deux ans	1 à 2 ans (plus de 12 périodes)	3 à 12 mois (entre 6 et 12 périodes)	0 à 3 mois (Moins de 6 périodes)	Existence produit similaire							
				Oui			Non				
				Comparaison par rapport à un/des produit(s) similaire(s)			Cycle de vie du produit				
				Profil de demande similaire	Produit de remplacement	Produit identique mais lot différent	Durée de vie courte	Durée de vie longue			
Phase de démarrage	Phase de décollage	Phase de maturité	Phase de déclin								
1	2	3	4	5	6	7	8	9	10	11	12

B. Méthode de choix de modèle quantitatif

Cette méthode concerne le cas où un historique de plus de 12 mois est disponible. Deux principales phases décrivent cette méthode dont l'algorithme général est présenté dans la Figure 5. La première phase est une étape d'initialisation et n'est à réaliser qu'une fois. Elle consiste à initialiser notre méthode afin de pouvoir l'utiliser de façon cyclique dans la seconde phase qui est celle d'utilisation.

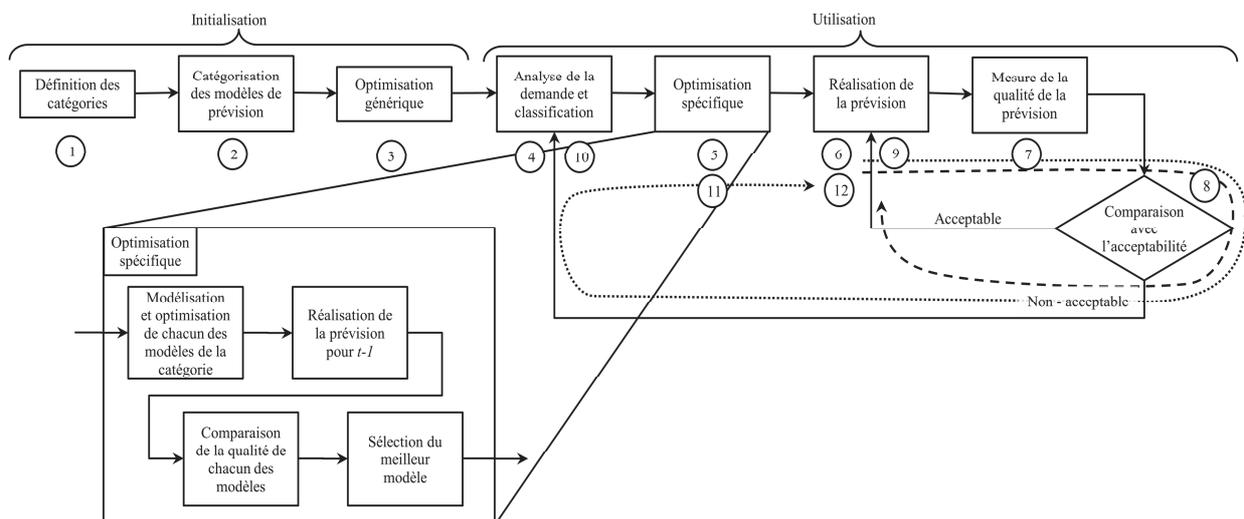


Figure 5: Algorithme de choix du modèle de prévision

1. Phase d'initialisation

La phase d'initialisation comporte trois étapes comme on le voit sur la Figure 6.

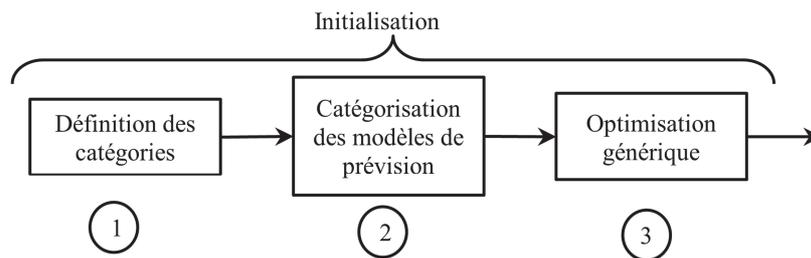


Figure 6:Phase d'initialisation de l'algorithme de choix du modèle de prévision

- **Définition des familles de demande**

La première consiste à définir les familles que nous allons considérer par la suite pour classifier notre profil de demande. Dans notre travail, nous avons retenu 16 familles distinctes pour les demandes continues uniquement. Les demandes discontinues également appelées demandes intermittentes peuvent être classifiées selon trois méthodes différentes. La classification de (Williams 1984) est basée sur la variabilité et l'intermittence de la demande, suite à cela, (Eaves & Kingsman 2004) ont proposé une classification des demandes intermittentes à partir de la variabilité de la taille de la demande, et du délai moyen entre les arrivées de demande. (Syntetos *et al.* 2005) ont également proposé une classification reprenant les éléments précédents en ajoutant le coefficient de variation du temps moyen d'inter-arrivées. Etant donnée la quantité de recherche ayant porté sur ce sujet, nous ne nous y sommes pas intéressés. Un état de l'art sur ce sujet a été réalisé par (Boylan & Syntetos 2010) ou encore (Chitturi *et al.* 2010).

Nous nous intéressons donc dans la suite aux seules demandes continues. Cette demande va pouvoir être différenciée selon quatre critères.

Le premier critère est la saisonnalité. Celle-ci peut avoir plusieurs formes. Selon la période de prévision (mois, semaine, jour), sa mise en évidence sera différente. Dans tous les cas, il faut valider la saisonnalité par un test statistique comme le test de « Student ».

Le deuxième critère est la tendance. Cette tendance peut également prendre plusieurs formes. Généralement, celle-ci s'établit sur une variation linéaire sur au moins trois périodes. Pour la mettre en évidence, une corrélation entre la série chronologique et une droite affine est généralement utilisée.

Le troisième critère retenu est la corrélation avec un paramètre extérieur. Cette mise en évidence se fait classiquement via une régression avec les données de ce ou ces paramètres extérieurs permettant d'expliquer l'évolution de la demande. Un exemple classique est la météo. Les produits comme les boissons rafraichissantes ou les soupes sont fortement « météo-sensibles ».

Enfin, le quatrième critère est le coefficient de variation de la série. En moyenne, soit celui-ci est supérieur à 0,5 et la demande sera dite variable, soit il est inférieur à 0,5 et la série sera dite stable.

Nous obtenons alors la classification présentée dans le Tableau 5.

Tableau 5: Classification des modèles de prévision en fonction du type de demande (cas des demandes continues)

Demande continue																
Saisonnalité																
Tendance																
Influence																
Type de demande	Demande basique		Demande avec saisonnalité		Demande avec tendance		Demande liée à un ou plusieurs paramètres extérieurs		Demande avec tendance et saisonnalité		Demande avec saisonnalité et liée à un ou plusieurs paramètres extérieurs		Demande avec tendance et liée à un ou plusieurs paramètres extérieurs		Demande avec tendance, saisonnalité et liée à un ou plusieurs paramètres extérieurs	
C.V.	< CV1	> CV1	< CV2	> CV2	< CV3	> CV3	< CV4	> CV4	< CV5	> CV5	< CV6	> CV6	< CV7	> CV7	< CV8	> CV8
Modèle de prévision	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16

- **Catégorisation des modèles de prévision**

La seconde étape est la catégorisation des modèles de prévision génériques à chacune de ces familles de demandes. Chaque catégorie va ainsi comporter deux ou trois modèles de prévision spécifiquement adaptés à la famille considérée. Les modèles qui vont entrer dans cette catégorisation sont les modèles simples tels que la prévision naïve, les moyennes mobiles de différents ordres, les moyennes mobiles pondérées, ou des modèles plus élaborés tels que les lissages exponentiels simple (Modèle de Brown) ; double (Modèle de Holt) ou triple (Modèle de Winters) ; le modèle de Gompertz, le modèle logistique, ou encore les modèles de régression comme le modèle ARIMA. A chaque catégorie, un nombre réduit de modèles est affecté afin de réduire le temps de modélisation et donc permettre d’avoir une bonne prévision plus rapidement, ce qui est le but de ce travail.

- **Optimisation générique des modèles**

Ces modèles sont dans une troisième phase spécifiquement optimisés pour le profil de demande de la famille à laquelle ils sont affectés. L’ensemble des coefficients permettant de paramétrer les différents modèles de prévisions vont être bornés afin de faciliter la détermination des coefficients par la suite. Cette étape permet de réduire le temps d’optimisation spécifique dans la phase cyclique d’utilisation.

Ces trois étapes ne sont à réaliser que lorsque toutes les classifications sont remises en cause, ce qui est rare (maximum une fois par an). Ces trois étapes correspondent à la définition de nos différentes catégories ou familles. Cette définition est importante car elle va permettre par la suite de ne sélectionner qu’une partie des modèles existants en fonction du type de la demande. Ceci va permettre de gagner du temps sur la réalisation des prévisions et donc pouvoir traiter un plus grand nombre de données. Cela est particulièrement vrai dans les cas où l’optimisation se fait au cas par cas ou manuellement. Le prévisionniste va ainsi pouvoir se concentrer sur les quelques modèles susceptibles de donner la meilleure prévision et non sur l’ensemble des modèles existants. Les catégories sont ainsi déclinées en fonction des caractéristiques de la demande. Elles sont faites pour être suffisamment précises pour ne concerner qu’un nombre réduit de modèles et en encadrant leurs paramètres respectifs toujours dans le but de rendre la phase d’optimisation spécifique plus rapide. Cette catégorisation a été réalisée à partir de l’étude de la littérature et des spécificités des modèles de prévision. L’analyse de cas d’études réels nous a également permis de déterminer les

paramètres à prendre en compte aussi bien pour la définition de la méthodologie que pour le choix des catégories retenues.

Une fois ces étapes faites, le processus cyclique présenté dans la section suivante peut être lancé.

2. Phase d'utilisation

La première étape de la phase d'utilisation, ou phase « cyclique », est l'analyse de la demande du produit considéré. A partir de cette analyse, la demande est identifiée en fonction des quatre paramètres que nous avons retenus à savoir : Saisonnalité, tendance, influence de la demande par un ou plusieurs paramètres externes, variabilité.

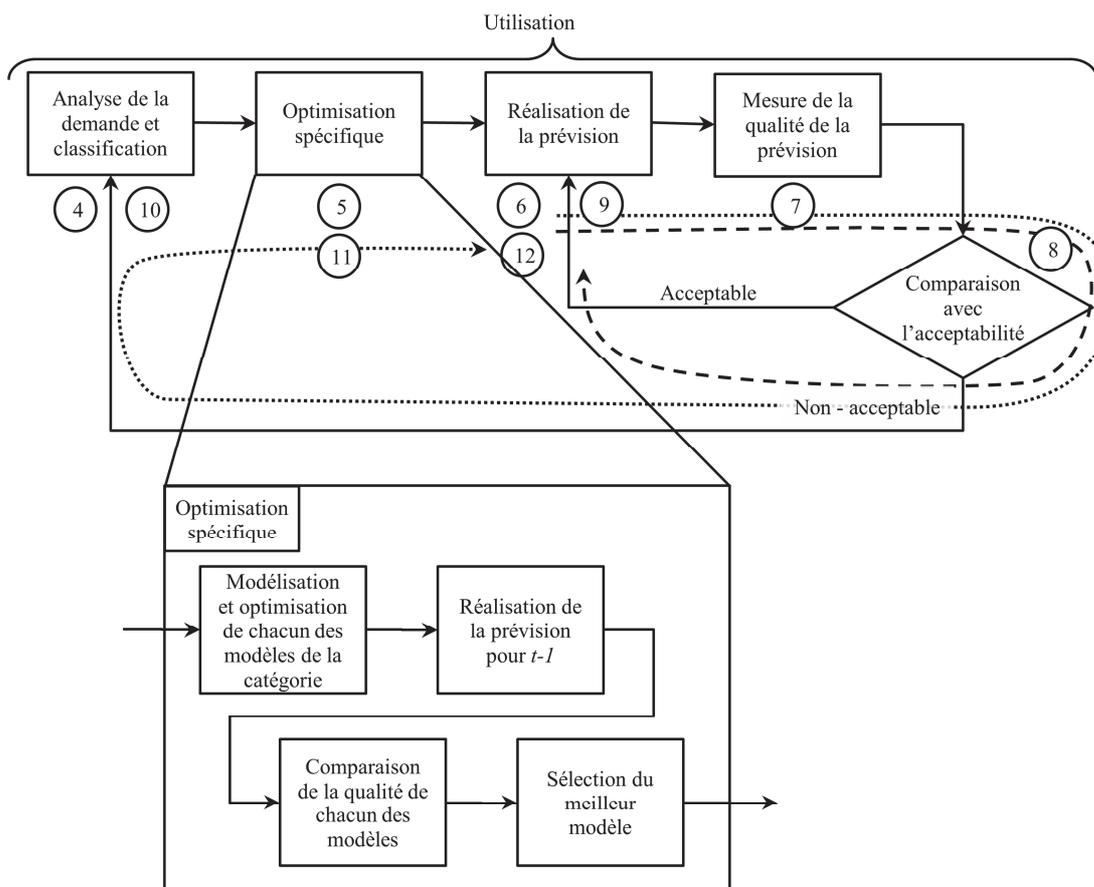


Figure 7: Phase d'utilisation de l'algorithme de choix du modèle de prévision

Suite à cette analyse, le produit est affecté à une famille et les modèles de cette famille vont être appliqués à ce produit. Ces modèles sont optimisés spécifiquement pour le profil de demande du produit à partir de l'historique disponible et de l'analyse rétrospective de l'erreur de prévision sur les dernières périodes. Les paramètres des modèles sont alors déterminés de façon à obtenir la plus faible erreur de prévisions sur les périodes précédentes. Le nombre de périodes à prendre en compte peut varier suivant les spécificités du produit (saisonnalité etc.). Nous avons observé qu'une analyse sur les trois périodes de temps précédentes donnait de bons résultats car cela permet de faire apparaître la tendance. Si une saisonnalité forte existe, alors une analyse sur six périodes au moins est recommandée. Suite à cette optimisation spécifique, nous obtenons alors entre deux et quatre modèles de prévisions spécifiquement optimisés pour la prévision du produit en question. Ces prévisions sont alors comparées sur la dernière période de vente connue (c'est-à-dire sur la période $t - 1$) afin de retenir celle permettant d'avoir *a priori* la meilleure qualité de prévision. Nous

préconisons l'utilisation du MAD ou du MAPE selon que la demande est toujours supérieure à zéro ou non pour suivre la qualité de la prévision.

Une fois le modèle de prévision retenu, la prévision peut être réalisée pour la période t , et pour les périodes suivantes si besoin.

A la période suivante, une mesure de la qualité de la prévision est réalisée grâce à la comparaison entre cette prévision et la demande réelle qui a pu être mesurée. Cette demande doit correspondre à la demande réelle, et non aux ventes. Elle doit donc être dépolluée des ruptures. Des méthodes d'analyse des ruptures ont été développées par des cabinets spécialistes. Ils s'appuient principalement sur la comparaison avec la demande moyenne. Si une demande paraît excessivement basse par rapport à la moyenne, cela est analysé comme une rupture de stock. La qualité de la prévision peut se juger soit sur une seule période donc la dernière, soit sur les trois dernières périodes, afin de limiter la prise en compte de points aberrants, soit sur un nombre plus grand de périodes selon la stabilité dans le modèle de prévision que l'on souhaite.

L'étape suivante est l'étude de l'acceptabilité de la qualité de la prévision. Cette étude peut se faire de différentes façons. Le critère d'acceptabilité peut être par exemple d'accepter une prévision en dehors de l'intervalle de tolérance, mais pas deux périodes de suite, avec une borne maximale de la déviation de la prévision. Plusieurs règles d'acceptabilité peuvent donc être définies en fonction des paramètres : intervalle de tolérance (qualité de la prévision) ; nombre de périodes regardées (latence de l'erreur de prévision).

Suite à ce test d'acceptabilité ou non de la qualité de la prévision, soit elle est acceptée et le modèle utilisé va être réutilisé tel quel pour la prévision de la période suivante, soit la prévision est jugée de qualité insuffisante, et dans ce cas, la demande va être ré-analysée afin de pouvoir choisir le modèle et le paramétrer de façon plus adéquate avec la prise en compte de la dernière demande réelle.

Cet algorithme de la phase cyclique permet donc de diminuer le temps de réalisation des prévisions en supprimant des remises en cause et des re-modélisations inutiles. La mise en place d'une borne d'acceptabilité permet de définir pour chacun des produits ou famille de produits considérés, à partir de quel niveau de qualité le modèle de prévision utilisé doit être revu. La réalisation de prévision dans un contexte industriel est souvent confrontée au temps disponible pour cette réalisation et pour son analyse. Cet algorithme permet alors de fonctionner par alerte et ainsi permettre au prévisionniste de se concentrer sur les cas les plus importants. La démarche à suivre dans un cadre prédéterminé lui est également donnée. Cela permet de diminuer le temps passé à la réalisation et à l'étude en masse des prévisions et donc d'améliorer la qualité globale des prévisions en se concentrant sur les produits à forts enjeux.

III. Conclusions

Cette méthode qui s'apparente à la logique du système expert doit permettre en premier lieu de gagner du temps sur la réalisation de la prévision et améliorer la qualité des prévisions réalisées. En effet, notre étude est partie du constat que la réalisation des prévisions bute sur deux problèmes : le premier est le manque de temps pour travailler sur l'ensemble des références de façon spécifique, le deuxième est la difficulté d'avoir un modèle approprié au contexte lors de la réalisation des prévisions.

Nous avons donc proposé une méthode qui permet de gagner du temps en limitant la remise en cause du modèle de prévision, et donc les références où le prévisionniste va devoir passer du temps sur le modèle aux seuls produits ayant une qualité de prévision insuffisante. Cette méthode permet

également d'améliorer la qualité de la prévision car elle remet en cause le modèle utilisé et offre la possibilité d'avoir un choix plus large de modèles de prévision.

Nous allons maintenant présenter la mise en application de notre méthode sur un cas industriel. Nous allons ainsi pouvoir quantifier les gains apportés par l'application de notre algorithme.

Applications industrielles

Dans cette section, nous allons présenter les deux applications industrielles que nous avons réalisées à partir de notre méthode sur le thème de la prévision. Ces applications ont été réalisées avec deux entreprises partenaires de la chaire : Gefco et PSA.

Nous allons commencer par présenter l'application prospective réalisée avec Gefco concernant la prévision de flux d'une plate-forme de cross-docking puis nous présenterons la seconde application qui nous a permis d'évaluer les performances obtenues par notre méthode dans le cas de PSA.

I. Application à démarche prospective : la mise en place de prévision de flux dans le cadre d'une plate-forme de transport Gefco

A. Contexte et objectifs de l'étude

1. Contexte

L'étude réalisée avec Gefco concerne le transport de marchandises par camion. Celui-ci se fait de trois manières :

- 1) Soit en FTL (Full TruckLoad), l'activité a alors une visibilité de 1 à 2 mois et concerne des volumes importants de 1 à plusieurs dizaines de camions par semaine sur le même trajet,
- 2) Soit en LTL (Less than TruckLoad), la visibilité est ici réduite (1 à 2 semaines) car elle concerne les différents éléments constituant les véhicules (options,...). Les flux propres à chaque élément sont moins prévisibles.
- 3) soit en Messagerie (collecte de pièces, agrégation des flux, puis distribution). La visibilité est ici réduite à 1 jour car elle concerne des flux incertains, avec mutualisation de nombreux clients, gros ou petits.

Pour réaliser ses transports de produits, Gefco ne possède en propre qu'une faible partie des moyens de transport utilisés.

Sur le transport de marchandises, le métier de Gefco consiste donc à faire le lien entre

1. la demande de transport des clients (qui sont les fournisseurs des constituants, les usines d'assemblage ou d'autres clients)
2. le besoin en capacité de transport, après organisation/optimisation du plan de transport (bouclage Aller/Retour, Milkrun...)
3. et les moyens disponibles auprès de transporteurs (semi-remorques, camions, chauffeurs,...).

Pour cela, Gefco distingue trois types de contrats :

1. Les contrats annuels :
Négociés pour des périodes de 1 an renouvelable, le coût de mise à disposition est faible mais les contraintes d'utilisation sont très fortes (flexibilité faible).
2. Les contrats mensuels :
Négociés pour des périodes de 1 ou 2 mois, le coût de mise à disposition est plus élevé, mais les contraintes d'utilisation sont plus faibles (contraintes sur la durée du contrat).

3. Les contrats journaliers (contrats « spot ») :
Négociés au jour le jour, leur coût est élevé, mais ils permettent d’avoir une flexibilité maximale avec une grande réactivité.

	Période	coût	flexibilité
Contrat annuel	2 ans	faible	faible
Contrat mensuel	1-2 mois	moyen	moyen
Contrat journalier (spot)	1 jour	élevé	élevé

Figure 8: Présentation des différents types de contrats de location de moyen de transport et

2. Objectifs

L’objectif global de Gefco est d’identifier le schéma de transport répondant aux exigences des Clients (importance des volumes, fiabilité des prévisions, demande de flexibilité) avec le coût le plus faible pour le Client et la meilleure marge pour Gefco.

Par rapport aux informations du tableau ci-dessus, le but va donc être de minimiser la prise de risque, trouver le bon équilibre entre la fiabilité des prévisions et la durée des contrats transport.

Maximiser les contrats à long terme et minimiser les contrats « spots » et mensuel. Pour cela, il va donc falloir avoir une vision à court (1 semaine), moyen (1 mois) et long terme (1 an) la plus précise possible. De cette façon, les contrats « spot » vont pouvoir être remplacés par des contrats mensuels et/ou annuels, ce qui permettra de diminuer les coûts.

Une fois les contrats définis/conclus, l’objectif va être l’optimisation de l’utilisation des capacités transport achetées par un travail sur les schémas de transport, ce qui sera favorisé par la connaissance de la prévision des demandes.

Un deuxième objectif est la possibilité d’optimiser l’émission des ordres de transports grâce à une démarche proactive en direction des clients (fournisseurs et usines) afin de leur proposer des transports moins chers lorsque la demande est plus faible pour lisser la charge.

La prévision, quel que soit son horizon, va également permettre d’optimiser le « bouclage » des schémas de transport de façon à améliorer le taux de remplissage des camions et surtout le nombre de kilomètres parcourus à vide. La mise en place de flux réguliers va également être favorisée grâce à une vision plus globale des schémas de transport.

Le but de cette étude est donc de mettre en place des prévisions à partir de l’historique des flux réalisés entre les différents clients de Gefco, donc de mettre en place la méthode de prévision que nous avons proposée afin de pouvoir utiliser des prévisions fiables dans la planification des besoins en transport.

3. Utilisation des prévisions : Réalisation de la planification

Voici le processus de planification du plan de transport de Gefco :

1. Le client envoie des prévisions de livraisons exprimées en nombres de pièces de chaque type à M-3. Ces prévisions ne sont pas contractuelles et correspondent rarement aux besoins réels.
2. De cette prévision, est déduite une prévision du besoin en transport.
3. Cette prévision est ensuite utilisée par l’outil de planification pour définir le plan de transport à M-1. La maille de travail des schémas de transport est la semaine. Ceci permet d’avoir un travail relativement fin et adapté au monde de l’entreprise. Les contrats « spot » vont ensuite se greffer sur les schémas hebdomadaires pour faire face aux fluctuations.

Le but pour l'équipe chargée de l'organisation opérationnelle est de mettre en place les flux physiques. Pour cela, elle s'appuie sur les ordres fermes disponibles à un horizon très court terme (quelques jours). Le but est donc de pouvoir fiabiliser les prévisions afin de permettre une prise en compte fiable des données plus en amont et ainsi de pouvoir optimiser plus globalement le plan de transport. En effet, si le besoin réel est supérieur au prévisionnel, il faut faire appel au transport « spot » très coûteux. Dans le cas contraire, il faut néanmoins payer la capacité réservée. Le constat initial était alors une utilisation non-optimale des moyens entre la demande et la disponibilité en fin de planification.

De la même façon, si le plan de transport était réalisé sur prévision, une augmentation des coûts de transport apparaîtrait du fait de changement entre les prévisions et les ordres fermes obligeant à rajouter des moyens supplémentaires.

B. Etude réalisée

1. Echantillon d'étude :

Le but de l'étude réalisée porte sur la faisabilité et la quantification de la qualité des prévisions des besoins en moyens de transport sur un périmètre initial restreint à une plate-forme de cross-docking mono-client. Le but est donc de voir si un bon niveau de prévision peut être obtenu, et quelles sont les perspectives d'utilisation de cette prévision.

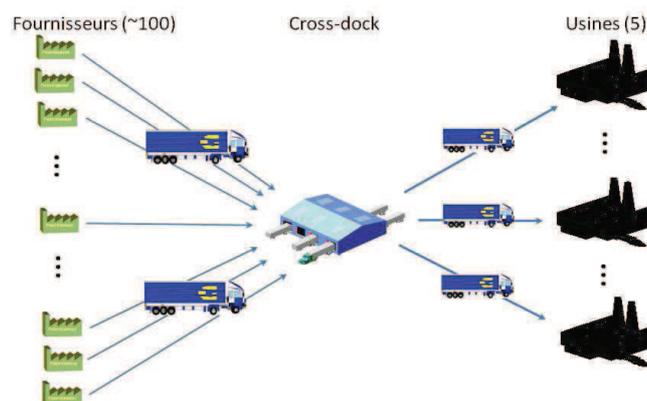


Figure 9: Schéma logistique de la plate forme de cross-docking étudiée

Les données utilisées pour cette étude concernent donc la demande en moyens de transport journalière de près de 100 fournisseurs amont situés dans plus de 100 villes de départ différentes. Les données représentent le poids des marchandises devant être transportées. L'hypothèse sous-jacente est que l'élément limitant dans le transport et le remplissage des moyens de transports (camions) est le poids et non le volume des produits. Ce choix est motivé par les caractéristiques des pièces pour l'automobile. En effet, celles-ci sont lourdes et peu encombrantes. Ces flux de pièces sont donc centralisés sur une plate-forme de cross-docking puis réorientés vers cinq usines aval. L'historique des données disponible représente la demande sur 37 semaines. Il faudra prendre en considération l'environnement économique propre à cette période. En effet, la crise économique de septembre 2008 a considérablement perturbé le marché automobile et donc les besoins et les flux de pièces automobiles concernées par cette étude.

2. Réalisation :

Nous avons, à partir des données disponibles, réalisé la prévision des flux pour les besoins amont comme pour les besoins aval.

a) Flux amont (Fournisseurs => Plate-forme)

Les flux sont directs entre chaque fournisseur et la plate-forme de cross-dock. Les besoins sont très variables aussi bien en terme de quantité qu'en terme de fréquence. La demande est donc, pour certains flux, intermittente et très variable en quantité. Les prévisions réalisées n'ont pas donné de résultat utilisable de fait de leur variabilité. Dans de tel cas, la prévision ne suffit pas. Il faut obligatoirement avoir une flexibilité maximale, ici, au niveau de l'offre en moyen de transport, pour faire face à ces variabilités.

Nous nous sommes donc concentrés sur l'étude et la prévision des flux avals qui sont, comme nous allons le détailler, plus stables.

b) Flux aval (Plate-forme => Usines)

Les flux avals sont constitués de besoin en transport pour cinq usines livrées directement depuis la plate-forme étudiée. Ces flux sont également assez variables. Etant donnée la limitation en historique, il n'y a pas de saisonnalité annuelle qui puisse être étudiée dans ce cas. Nous ferons donc l'hypothèse de l'absence de saisonnalité. Nous avons donc utilisé trois modèles de prévision classiques à savoir la moyenne mobile, le lissage exponentiel simple et le lissage exponentiel double.

Tableau 6: Erreur de prévisions (MAD) selon les méthodes utilisées et caractéristiques de la demande des flux avals de la plate-forme de cross-docking étudiée

	usine 1	usine 2	usine 3	usine 4	usine 5	flux aval total
Moyenne mobile	28%	47%	21%	20%	3060%	20%
Lissage exponentiel simple	31%	53%	23%	18%	158%	18%
Lissage exponentiel double	29%	45%	21%	20%	4296%	20%
Demande moyenne en nbs de camion par mois	8 944	28 705	39 937	12 181	4 349	94 116
Coefficient de variation	0,56	0,56	0,51	0,53	1,23	0,37

Nous avons commencé par réaliser la prévision des flux avec chacune des méthodes de prévision de façon indépendante. Nous avons également caractérisé chacune des demandes. Nous avons alors obtenu les qualités de prévisions du Tableau 6.

Ces modèles de prévisions ont été utilisés pour les cinq usines en suivant la méthode de choix que nous avons présentée précédemment. Nous avons donc regardé sur chaque période la qualité des prévisions pour chaque modèle. A partir de là, nous pouvions soit garder le modèle précédent, soit changer pour le modèle le plus performant si ce n'était plus le même. Nous avons également regardé l'impact de fixer une borne d'acceptation au niveau de la qualité de la prévision sur les changements de modèle et sur la qualité globale des prévisions. Les paramètres de chacun des modèles de prévisions ont été déterminés de façon à avoir la plus faible erreur de prévision sur

l'ensemble des prévisions réalisées. Le fort coefficient de variation et le profil atypique de la demande de l'usine 5 ne permet pas une prévision acceptable pour la demande. Nous avons testé d'autres types de modèles (Croston, ...) sans améliorations significatives. Nous préconiserons donc dans un cas pareil, de privilégier la flexibilité pour pouvoir adapter l'offre à la demande.

Le Tableau 7 indique pour les 35 périodes observées, sur chacune des usines et pour le flux global sortant de la plate-forme, les différents cas possibles concernant le changement de modèle de prévisions, et l'utilité ou non de mettre en place un test remettant en question le modèle utilisé (étape 8 de la méthode proposée).

Le premier test à avoir lieu est celui affairant à la qualité de la prévision obtenue. Pour cela, la qualité de la prévision est déterminée par le calcul de la « Forecast Accuracy » ($(\text{Demande} - \text{Prévision}) / \text{Prévision}$). Si cette qualité est jugée suffisante ($FA < 10\%$ pour notre cas d'étude), alors nous allons considérer qu'il est inutile de tester d'autres modèles. Cependant, ces derniers pourraient apporter une amélioration malgré la bonne performance du modèle utilisé. Dans ce cas, notre méthode offre un gain en rapidité (moins de modélisation) mais une perte au niveau de la qualité de la prévision. Pour différencier ces deux cas, nous allons noter « test_utile » les cas où l'étape 8 prend tout son sens et permet d'avoir la meilleure prévision sans test superflu, et « test_réducteur » les cas où l'étape 8 implique l'utilisation d'un modèle de prévision ne garantissant pas la meilleure qualité possible.

Dans les cas où l'erreur de prévision obtenue est supérieure à 10% (borne utilisée pour notre étude), nous allons tester l'ensemble des modèles afin de sélectionner celui offrant *a posteriori* la meilleure prévision pour le sélectionner pour la suite (étape 11 de notre méthode). Soit on utilisera un autre modèle et alors, le changement est utile et on notera ce cas « changement_utile » soit le modèle précédemment utilisé est le plus performant malgré l'erreur de prévision et on notera le cas « pas_de_changement ».

La Figure 10 illustre cette classification.

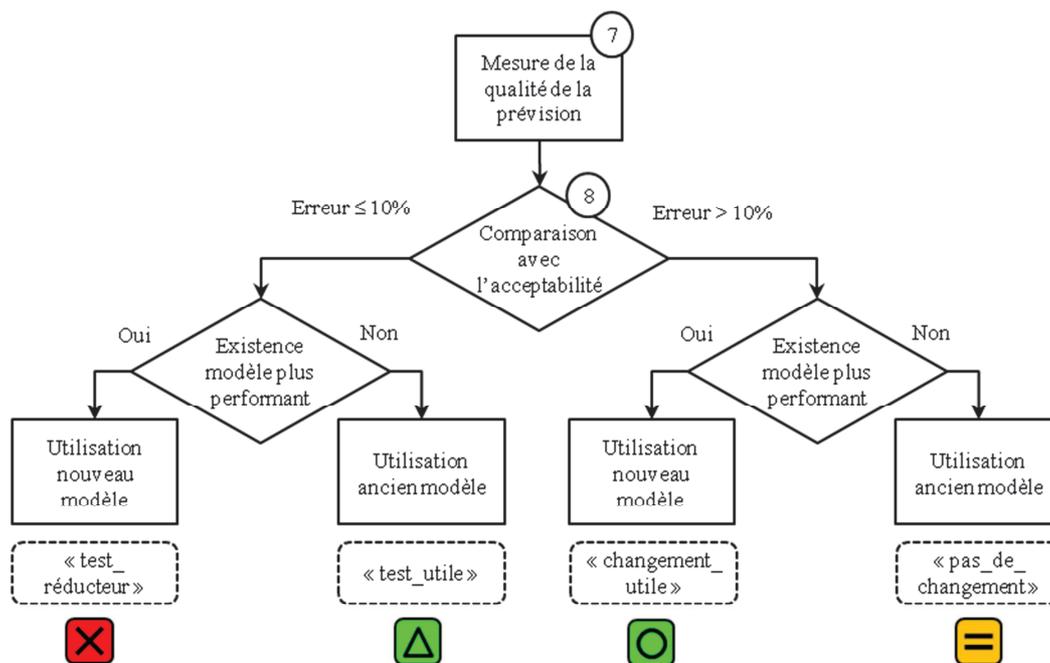


Figure 10: Algorithme de classification des cas de changement de modèle

Tableau 7: Type de changements de modèle pour les flux aval de la plate-forme de cross-docking étudiée sur l'horizon d'étude

Période	Usine 1	Usine 2	Usine 3	Usine 4	Usine 5	Flux aval total
5	O	X	O	X	Δ	Δ
6	O	O	O	O	O	Δ
7	O	Δ	O	O	O	Δ
8	Δ	Δ	O	Δ	O	O
9	=	O	Δ	O	O	X
10	O	O	X	Δ	O	O
11	O	O	O	Δ	O	Δ
12	O	O	O	Δ	O	O
13	=	O	Δ	O	=	X
14	O	Δ	X	O	O	X
15	=	Δ	X	X	O	X
16	O	Δ	=	O	=	X
17	=	O	O	Δ	=	=
18	=	Δ	O	=	O	Δ
19	O	=	Δ	O	O	O
20	=	Δ	O	O	O	O
21	=	Δ	O	O	X	O
22	X	=	X	O	O	Δ
23	Δ	O	X	O	O	X
24	Δ	X	O	O	=	O
25	X	=	O	O	O	=
26	Δ	O	O	O	O	O
27	Δ	O	=	=	O	Δ
28	O	Δ	O	O	O	O
29	O	O	O	Δ	=	O
30	O	Δ	X	Δ	Δ	O
31	O	O	=	=	Δ	X
32	=	=	X	O	O	=
33	O	O	O	O	O	O
34	=	O	O	Δ	=	O
35	Δ	O	O	O	O	O
36	O	Δ	X	O	O	=
37	Δ	O	Δ	=	X	Δ
38	=	O	O	=	O	O
39	=	=	O	O	X	O

A partir de ces résultats, nous pouvons faire les analyses présentées dans le Tableau 8.

Ce tableau permet de mesurer la proportion de changement de modèle sur les 35 périodes et les 6 flux observés. Nous voyions que cette proportion est importante avec un changement dans 64%

des cas en moyenne (de 49 à 80%). Parmi ces changements de modèle, 53% des cas sont jugés « utiles » selon le critère de reconduction du modèle en cas d'erreur de prévision inférieure à 10%.

Nous observons également que la qualité moyenne des prévisions est très faiblement dégradée par le non-changement de modèle lorsque l'erreur de prévision est inférieure à 10% avec une erreur moyenne qui passe de 31.58% à 31.61%, en ne considérant pas l'usine 5 qui a une demande trop variable pour pouvoir être prévue (erreur moyenne de prévision supérieure à 900%). Cette observation montre l'intérêt de fixer une borne au niveau de l'erreur de prévision en dessous de laquelle, une remise en cause du modèle de prévision utilisé n'est pas utile. En effet, la qualité de la prévision n'est pas significativement améliorée alors qu'en contrepartie, le nombre de tests à réaliser diminue.

Tableau 8: Analyse des types de changement et qualité de prévision obtenue pour les flux aval de la plate-forme de cross-docking étudiée

	Usine 1	Usine 2	Usine 3	Usine 4	Usine 5	Flux aval total
proportion de changement total de modèle	49%	54%	80%	63%	74%	66%
proportion de changement de modèle utile (e >10%)	43%	49%	57%	57%	66%	46%
proportion de changement de modèle inutile (e <10%)	6%	6%	23%	6%	9%	20%
qualité moyenne de prévision avec changement de modèle et sans test (test_réducteur & changement_utilite)	29,7%	40,8%	22,2%	46,5%	940,4%	18,7%
qualité moyenne de prévision avec changement de modèle si test négatif (changement_utilite)	29,8%	41,4%	22,2%	45,8%	940,3%	18,8%

Cette analyse est renforcée par le Tableau 9. En effet, la comparaison des erreurs moyennes de prévision entre les différents cas nous montre l'intérêt à pouvoir utiliser le meilleur modèle, mais montre le peu d'intérêt à modifier le modèle lorsque l'erreur de prévision est inférieure à 10% avec une variation de la moyenne des prévisions de 0,1%. Ces différents cas sont : Utilisation de la moyenne mobile uniquement ; utilisation du lissage simple uniquement ; utilisation du lissage double uniquement ; utilisation du meilleur modèle avec changement non restreint ; utilisation du meilleur modèle avec changement restreint (uniquement si erreur de prévision supérieure à 10%). Le gain est calculé de la façon suivante :

$$G(\text{chgt_restreint/lis_simple}) = \left(\frac{Q_{\text{prev}}(\text{lis_simple}) - Q_{\text{prev}}(\text{chg_restreint})}{Q_{\text{prev}}(\text{chg_restreint})} \right)$$

Tableau 9: Analyse de la qualité des prévisions suivant la méthode utilisée

Méthode	moyenne mobile	lissage simple	lissage double	avec changement modèle	changement modèle restreint
Qualité de prévision moyenne	35,1%	36,7%	33,0%	31,6%	31,6%
Gain avec changement	11,1%	16,1%	4,5%	/	0,1%
Gain avec changement restreint	11,1%	16,0%	4,4%	-0,1%	/

Une analyse plus fine nous montre l'importance de prendre en compte la variabilité de la demande sur le choix de la méthode à utiliser.

c) Etude de l'intérêt de la mise en place des prévisions

En plus de l'étude théorique liée à l'amélioration des prévisions grâce à la méthode que nous avons proposée, nous avons également montré l'intérêt qui pouvait exister à mettre en place des prévisions sur les flux avals de la plate-forme de cross-docking étudiée. En effet, l'erreur de prévision malgré son niveau important permet tout de même d'avoir une meilleure vision des flux à venir en particulier au niveau global. En effet, la variabilité de la demande est plus faible et nous pouvons alors, en plus d'avoir une meilleure prévision, avoir un lissage de charge qui va se créer entre les différents flux au départ de la plate-forme. Les moyens de transport engagés sont donc moins variables et le dimensionnement du parc nécessaire plus facile à réaliser. L'allocation de ces moyens sur les différents flux (livraisons usine 1, 2, 3 4 ou 5) peut se faire dans un deuxième temps, l'équilibre charge globale par rapport au parc disponible étant assuré grâce à la qualité acceptable de la prévision obtenue sur le flux aval global.

C. Conclusion

Cette étude réalisée avec notre partenaire Gefco nous a permis de montrer de façon pratique l'intérêt de la méthode que nous avons proposée pour améliorer le processus de réalisation des prévisions. Les gains ont été quantifiés au niveau de la qualité de la prévision. Nous avons montré l'amélioration de la prévision obtenue par rapport au cas d'un modèle statique de 4 à 16% ainsi que l'équivalence en termes de qualité entre la méthode avec changement systématique et la méthode avec changement restreint. L'utilisation de la dernière méthode permet en outre de réduire de 10% le temps passé à la modélisation, étant donné que nous ne changeons plus de modèle lorsque l'erreur de prévision est inférieure à 10%.

II. Application à démarche comparative: Comparaison de la qualité des prévisions obtenues par PSA et celle obtenue en utilisant la méthode proposée dans le cadre de prévision de pièces de rechanges.

A. Contexte et processus de gestion des pièces de rechanges (PR)

Une des principales problématiques que se pose la Direction des Pièces de Rechanges (DPR) est la suivante :

« Quels stocks pour quelles pièces à quels endroits ? »

L'objectif est de maximiser le taux de service et de minimiser les stocks. On retrouve donc une fonction objectif classique à savoir maximisation du taux de service et minimisation du coût.

Une des particularités de cette problématique est qu'elle n'est pas figée. En effet, le « référencié » (terme désignant l'ensemble des références accolées de leur rotation et de leur localisation) est dynamique. De nouvelles références apparaissent à chaque type de véhicule (5 000 références par an) tandis que d'autres disparaissent du fait de la fin du cycle de vie du véhicule. Le référencié varie également suivant les régions, la demande n'étant pas uniforme géographiquement parlant.

Actuellement, la prévision globale de la demande en pièces de rechanges est gérée via le module prévision de SAP et ne satisfait pas aux exigences de qualité de prévisions en particulier pour les produits en début ou en fin de vie. Du fait de la complexité du système, l'apport de modifications à ce système de prévision n'est pas envisageable pour le moment. A partir de là, d'autres

problématiques liant la gestion de la prévision, l'optimisation des approvisionnements et la gestion des stocks apparaissent.

La gestion des pièces de rechange représente pour PSA un enjeu considérable. En effet, la disponibilité et la rapidité de livraison de ces éléments correspondent à une nécessité légale, mais surtout permettent de donner une image du groupe PSA indispensable pour rivaliser avec les concurrents du secteur automobile (constructeurs et revendeurs).

Chez PSA, les pièces de rechanges sont gérées par un service particulier composé de deux pôles :

- Gestion logistique en charge de la production, du stockage et de l'approvisionnement des éléments.
- Gestion commerciale en charge du développement et de la gestion des ventes.

1. Les catégories de pièces

Pour PSA, les pièces de rechange représentent un marché de 250 000 références pouvant être classées en cinq catégories :

1. Les pièces de rechanges de série ;
Elles correspondent aux pièces de première monte équipant des véhicules en cours de production. Leur fabrication va donc correspondre à un rajout par rapport à la production normale.
2. Les pièces de grande vente ou pièces d'usures (plaquettes de frein, courroies, pneus,...). Ces produits dont la demande est relativement connue sont également commercialisés par les réseaux de garage indépendant (type Feu vert) et représente environ 10 000 références.
3. Les pièces de rechanges hors-séries ;
Elles correspondent aux pièces équipant des véhicules n'étant plus produits. La production de ces pièces est donc spécialement réalisée pour les pièces de rechanges. Ce marché, contenant des produits à plus faible rotation n'est pas très utilisé par les garages indépendants.
4. La gamme complémentaire ;
Les pièces de cette gamme sont destinées aux véhicules anciens. Leur cahier des charges est allégé de façon à pouvoir proposer un prix plus faible. La qualité de ces pièces est donc inférieure aux pièces d'origines.
5. Les accessoires ;
Ces pièces correspondent aux éléments non montés de série sur les véhicules mais disponibles dans le réseau PSA. On retrouve par exemple les jantes spécifiques, les attelages, ... Certains de ces produits ne sont pas labélisés par le constructeur mais sont adaptables (feux, etc.). Suivant les produits et leurs spécificités, ils peuvent être disponibles dans des garages indépendants.

2. L'aspect commercial

Le groupe PSA gère en moyenne 350 000 commandes par jour (lots ou pièces unitaires). Ces ventes peuvent être partitionnées en deux catégories :

- Les ventes classiques ;
Elles correspondent au remplacement régulier et prévisible des pièces d'usures. La courbe des ventes est relativement bien connue et prévisible. L'évolution du marché automobile relativise cependant l'utilisation des historiques (diminution de la durée de vie du cycle commercial des véhicules).
- Les ventes spéciales ;
Elles correspondent aux opérations particulières type promotions et aux remplacements liés aux saisons (remplacement voulu (frein, clim, etc.) et non voulu (accident, ...)). La gestion de ces promotions se fait grâce à un partage au niveau du plan de communication 3 mois avant le lancement.

Pour ces deux catégories, on distinguera les produits ayant une forte rotation, ceux ayant une rotation moyenne et enfin les produits ayant de faibles ventes.

La difficulté au niveau des pièces de rechanges est l'absence d'études de marché et donc les difficultés pour prévoir la demande en particulier pour les produits à faible rotation. Des lois de consommation ont cependant déjà été élaborées à partir des historiques et des spécificités de ces pièces (usure, accident, saisonnalité, catastrophe naturelle, ...).

Tableau 10: Catégories de pièces de rechanges en fonction du type de demande et de la famille marketing des pièces

		Pièces de série	Pièces hors série	Gamme complémentaire	Accessoires
demandes élevées	Ventes classiques	A	B	C	D
	Ventes spéciales	E	F	G	H
demandes moyennes	Ventes classiques	I	J	K	L
	Ventes spéciales	M	N	O	P
demandes faibles	Ventes classiques	Q	R	S	T
	Ventes spéciales	U	V	W	X

Globalement, les ventes peuvent être découpées de façon matricielle entre les niveaux de rotation, les types de pièces et les types de ventes.

3. Le schéma logistique

Pour assurer la disponibilité des produits en temps et en heure, un schéma logistique spécifique a été élaboré. Une représentation schématique est proposée dans la Figure 11.

On retrouve donc trois niveaux de distribution avec trois à quatre niveaux de stocks.

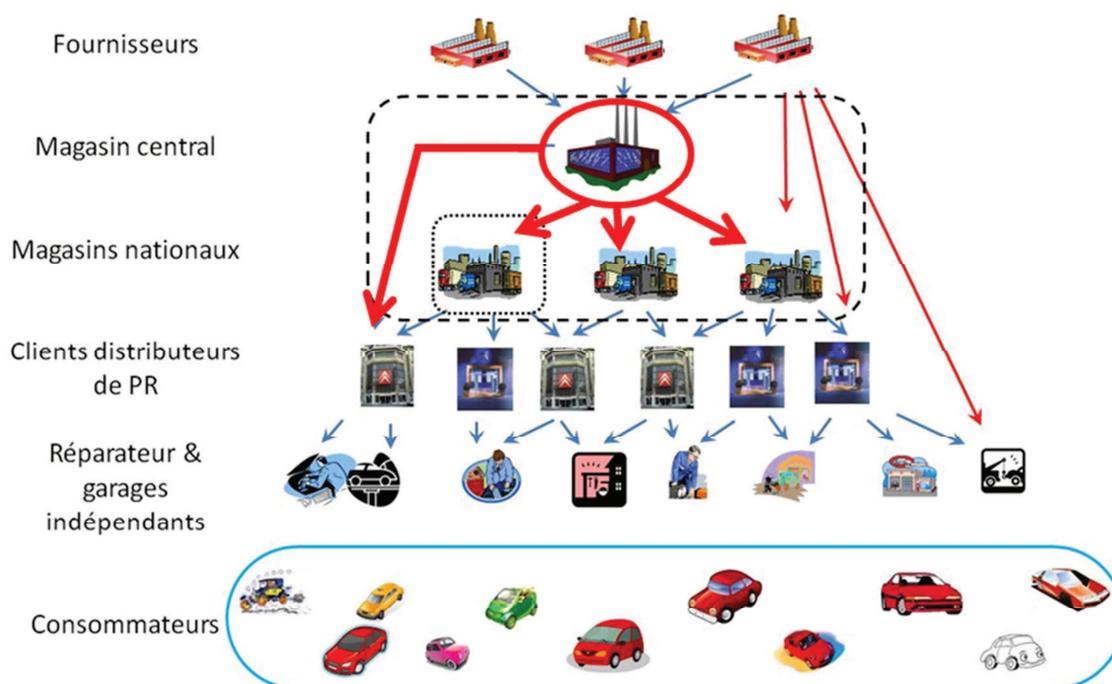


Figure 11: Schéma logistique de distribution des pièces de rechanges

L'objectif dans le marché des pièces de rechanges est d'avoir une réactivité maximale avec la possibilité de livrer n'importe quel endroit de la zone de couverture du réseau en un délai minimal

devant tendre vers 1h30. Le système est donc tourné vers le client. Couplées à cet objectif, de multiples contraintes telles que la limitation des coûts de transports, de stockage, ... vont nous permettre de définir le meilleur choix logistique. L'optimisation de la répartition des magasins fait aussi partie des objectifs de l'optimisation de la chaîne logistique des pièces de rechange.

4. La réalisation des prévisions

a) Fonctionnement du système de prévision

L'ERP utilisé est APO de SAP. Celui-ci réalise la prévision et la planification des flux pour satisfaire un taux de service cible. La prévision est réalisée une fois par mois puis éclatée uniformément sur le mois à la maille journalière. La planification correspondante se fait à la maille hebdomadaire.

Le temps de traitement et la performance du système de prévision sont des contraintes très fortes. En effet, 220 000 références doivent être traitées en 48h en début de mois.

b) Utilisation des modèles :

SAP n'utilise que quatre types de modèles de prévisions qui sont tous basés sur les séries chronologiques. Il n'inclut pas de modèles de prévision causales. Le principal obstacle à l'utilisation de tels modèles est la connaissance et la quantification de paramètres explicatifs de la demande. En effet, l'un des facteurs explicatifs les plus pertinents, à savoir la taille du parc véhicule roulant, permettant de dimensionner au mieux les besoins, n'existe pas à l'heure actuelle. Ces modèles sont donc à écarter pour la suite de notre étude. Les modèles utilisés par SAP sont donc ceux du type lissage exponentiel (simple, double, triple) ainsi que la moyenne mobile.

SAP propose deux types de méthodes de choix de modèle. Soit une classification à partir de l'historique de la demande suivi du choix d'un type de modèle. Soit le test de tous les modèles disponibles, la comparaison des résultats à partir de la MAD (Mean Absolute Deviation) qui est l'indicateur de performance utilisé par SAP, suivi du choix du modèle le plus performant. Pour des contraintes de temps de traitements, c'est la première méthode qui est aujourd'hui utilisée. Cependant, il a été constaté que des incohérences existaient avec une utilisation de modèle inadéquat dans certain cas. La deuxième solution permettrait un meilleur résultat, mais impose un temps de traitement prohibitif dans le cas étudié.

SAP va effectuer le choix du modèle pour chacun des produits à chaque lancement de la prévision c'est à dire tous les mois. L'utilisation de la méthode que nous proposons avec la mise en place d'une borne inférieure ne remettant pas en cause le modèle utilisé permettrait de réduire le temps de traitement et de pouvoir passer plus de temps sur les produits ayant des qualités de prévision trop faibles.

5. Conclusion

En conclusion, la réalisation de l'étude de la prévision de la demande va nous permettre de comparer les résultats obtenus de façon industrielle avec ceux que nous obtenons via une méthode classique ou via la méthode que nous avons proposée. Nous pourrions alors voir l'apport de cette dernière. En effet, la fiabilisation des prévisions et l'amélioration de leur qualité permettraient d'améliorer la sécurisation du stock de pièces de rechange et donc du taux de service tout en minimisant le niveau des stocks. La planification de l'approvisionnement au niveau des magasins nationaux et des clients (distributeurs de pièces de rechanges) pourra alors être améliorée grâce à une plus grande robustesse des données d'entrée.

B. Etude réalisée

1. Echantillon d'étude :

Pour la suite du travail, quatre familles de produits ont été retenues :

- Produits en début de vie ayant une demande moyenne croissante ;
- Produits en fin de vie ayant une demande moyenne décroissante ;
- Produits saisonniers ayant une demande cyclique sur l'année ;
- Produits de fortes consommations ayant une demande variable mais homogène dans le temps.

Ces catégories de familles sont déterminées à partir du profil des ventes et non à partir des caractéristiques commerciales des pièces. Ainsi, nous pouvons retrouver dans la famille produit en début de vie des pièces de carrosserie comme des pièces hydrauliques.

Les données disponibles représentent les demandes sur une durée de cinq ans en moyenne à la maille mensuelle. Nous disposons donc de séries chronologiques de 60 données en moyenne.

2. Réalisation :

Nous avons, à partir des données disponibles, réalisé la prévision de la demande *a priori*, c'est à dire, en ne regardant que les données passées afin de prévoir le futur. Nous avons ensuite comparé les prévisions obtenues par rapport aux données réelles. Les modèles de prévision utilisés sont la moyenne mobile, le lissage exponentiel simple, le lissage exponentiel double et le lissage exponentiel triple. Les paramètres de ces modèles ont été déterminés de façon à minimiser l'erreur de prévisions (FA). Grâce à ces prévisions, nous avons pu quantifier leurs erreurs. Comme pour l'étude précédente réalisée avec Gefco, notre indicateur de qualité de prévision est la « Forecast Accuracy », c'est-à-dire la mesure de l'erreur de prévision divisé par la prévision. Nous avons également caractérisé la demande et en particulier son coefficient de variation (rapport entre l'écart type et la moyenne de la série). Nous obtenons alors les résultats présentés dans le Tableau 11 pour les quatre familles étudiées.

Tableau 11: Analyse de la qualité des prévisions suivant la méthode utilisée pour les différents types de produits

	Produit en début de vie	Produit en fin de vie	Produits saisonniers	Fortes consommations	Moyenne globale
Moyenne mobile	51%	34%	143%	33%	44%
Lissage simple	49%	34%	124%	31%	42%
Lissage double	65%	39%	207%	38%	55%
Lissage triple	14143%	41%	205%	172%	2603%
demande moyenne	265	5 888	14 969	17 269	12 698
Coefficient de variation	0,7	0,5	1,3	0,4	0,5

Nous pouvons à partir de ces premiers résultats voir que le modèle de lissage exponentiel triple est celui offrant la moins bonne qualité de prévision moyenne, même pour les produits saisonniers, domaine où ce modèle a la réputation d'être le plus performant. Cela s'explique par la difficulté d'initialisation du modèle. En effet, celui-ci a besoin d'un historique plus important (minimum 12 mois pour la saisonnalité annuelle). De la même façon, la conjugaison du facteur saisonnier et des caractéristiques de la phase de lancement (demande fortement croissante) amène une initialisation via l'historique qui n'est pas réellement représentative. A l'inverse, le lissage exponentiel simple est celui ayant l'erreur de prévision moyenne la plus faible quel que soit le type de produit.

Nous avons également appliqué, comme pour l'étude précédente, la méthode que nous avons proposée afin d'améliorer la qualité de prévision tout en limitant le temps de calcul des prévisions. Nous avons observé deux choses.

La première est la proportion de changement de modèle induite par notre méthode. Nous pouvons alors distinguer deux cas, le premier où l'on ne considère pas la mise en place d'un seuil d'acceptabilité (étape 8 de notre méthode), et la seconde où l'on tient compte de cette borne d'acceptabilité ce qui va diminuer la proportion de changement de modèle, mais également induire une détérioration de la prévision. Nous avons considéré ici la même borne d'acceptabilité à savoir une erreur de prévision inférieure ou égale à 10% sur une période. Le Tableau 12 présente ces observations.

Tableau 12: Analyse des types de changement et qualité de prévision obtenue pour les différents types de produits étudiés

	Produit en début de vie	Produit en fin de vie	Produits saisonniers	Fortes consommations	Moyenne globale
Proportion de changement total de modèle	51%	77%	59%	74%	69%
Proportion de changement de modèle utile ($\epsilon > 10\%$)	45%	67%	58%	62%	60%
Proportion de changement de modèle inutile ($\epsilon < 10\%$)	6%	10%	1%	12%	10%
Qualité moyenne de prév avec changement de modèle	37%	19,6%	44,6%	18,6%	24,7%
Qualité moyenne de prév avec changement restreint de modèle	37,2%	20,7%	47,6%	19,9%	25,8%

La seconde observation est la qualité de la prévision obtenue grâce à notre méthode en comparaison à l'utilisation d'un modèle de prévision unique. Le Tableau 13 présente ces résultats.

Tableau 13: Analyse de la qualité des prévisions suivant la méthode utilisée

	Moyenne mobile	Lissage simple	Lissage double	Lissage triple	Avec changement de modèle	Changement de modèle restreint
Qualité de prévision moyenne	44%	42%	55%	2603%	24,7%	25,8%
Gain avec changement	44%	41%	55%	99%	/	4%
Gain avec changement restreint	42%	38%	53%	99%	-4%	/

Cette analyse montre que la proportion de changement de modèle est importante. En effet, elle varie entre la moitié et les trois quart des cas selon le type de produit. Notons que près de 15% peuvent être évités si l'on considère le seuil d'acceptabilité que l'on s'est fixé à 10%, ce qui accélérerait théoriquement le temps de modélisation de 15%. De plus, la prise en compte de ce seuil ne dégrade la qualité de la prévision que très faiblement, celle-ci passant en moyenne de 24,7% d'erreur à 25,8%. Enfin, nous pouvons insister sur l'apport de notre méthode en termes de qualité de prévision. En effet, celle-ci passe de 42% d'erreur dans le meilleur des cas d'utilisation d'un modèle statique (lissage exponentiel simple dans notre étude) à près de 25% soit presque une division par deux de l'erreur de prévision.

C. Conclusion

Grâce à cette étude réalisée à la division des pièces de rechanges de PSA, nous avons pu appliquer la méthode que nous avons développée sur un cas industriel réel. Cela nous a permis de montrer deux résultats permettant d'illustrer l'apport de notre méthode.

Le premier résultat est l'amélioration de la qualité obtenue par le fait de permettre un changement dynamique de modèle au cours du temps. En effet, ce changement qui peut être fréquent comme l'a montré notre étude (changement de modèle dans près de 70% des cas) permet d'améliorer la qualité de la prévision de façon importante. Celle-ci passant de plus de 40% d'erreur à moins de 25%.

La deuxième chose est l'impact positif de la mise en place d'une borne d'acceptabilité sur la qualité de la prévision. Dans notre étude, nous avons choisi une borne de 10% d'erreur sur une période, ce qui a permis de réduire les cas de changements de modèle de 10% tout en conservant une qualité de prévision proche avec une erreur moyenne passant de 25 à 26%. Cela permet d'accélérer la réalisation des prévisions et donc répondre aux contraintes industrielles.

En conclusion, notre méthode paraît pertinente aussi bien dans l'apport d'une dynamique de choix de modèle que dans la mise en place d'une borne d'acceptabilité permettant de limiter les changements de modèle et donc de stabiliser la réalisation des prévisions.

III. Conclusion

L'application de notre méthode sur les deux exemples industriels réels nous a permis de valider celle-ci dans des conditions réelles. L'apport au niveau de la qualité de la prévision a été mis en évidence, tout comme l'amélioration proposée par la mise en place d'une étape de vérification de la qualité de la prévision permettant de remettre le modèle de prévision en cause ou non.

Cette étude reste cependant une étude sous forme prospectrice, étant donné qu'elle n'a pas été implémentée globalement. En effet, la méthode a été testée sous Excel, ce qui ne permet pas un fonctionnement tout automatique comme il est nécessaire pour un utilisateur industriel. Cependant, les conclusions restent valables et permettent de proposer des pistes d'améliorations pour l'outil utilisé.

Une deuxième remarque que l'on peut faire de ce travail est la limite de l'étude menée sur le choix du critère d'acceptabilité. En effet, nous nous sommes limités à un critère. Une étude plus approfondie permettrait de voir la sensibilité entre le critère de remise en cause du modèle de prévision et la qualité de la prévision. Cela permettrait de choisir au mieux ce critère pour faire un compromis entre qualité de la prévision et rapidité de sa réalisation. Enfin, la définition de ce critère peut également être discutée. En effet, ce critère peut être modifié de deux façons différentes. La première façon est de relever ou de baisser la limite d'acceptabilité de la qualité de la prévision. La deuxième est l'aspect temporel de l'indicateur. En effet, nous avons choisi dans notre étude d'avoir une grande réactivité par rapport à l'erreur de prévision et donc d'autoriser un changement à chaque période. Une manière différente de faire serait de n'autoriser une modification du modèle que pour les n ($n > 1$) périodes. Cela rend le système plus stable, mais également moins réactif aux changements de la demande. Enfin, le choix de l'indicateur de qualité du modèle de prévision peut intégrer cette composante, en mesurant la qualité de la prévision non pas sur une mais sur plusieurs périodes.

Nous nous sommes intéressés ici uniquement à la réalisation de la prévision. Or, le lien entre la réalisation de la prévision et son utilisation ne peut être ignoré. La manière de réaliser la prévision, et de mesurer sa qualité influence toute la chaîne logistique et en particulier le système de planification et de gestion des stocks. C'est suivant cette logique que (Tiacci et Saetta, 2009) ont mis en évidence la limite des méthodes traditionnelles de prévision utilisées jusqu'à aujourd'hui. Dans leur article de 2009 ils étudient les effets possibles de l'utilisation de différentes méthodes de modélisation de la

prévision sur les résultats finaux que procurent les modèles de gestion des stocks. En particulier ils ont montré que les méthodes utilisées pour évaluer la prévision (MAD, MSE, MAPE..) n'étaient pas toujours appropriées. Ils ont en particulier analysé l'impact du choix des méthodes de prévision ou des méthodes de mesure de la qualité de la prévision utilisées sur le niveau de stock et le niveau de service de la chaîne logistique. Ils en ont conclu que dans certains cas, cette évaluation était pertinente. Dans le même sens (Tratar, 2010) insiste sur le fait que l'optimisation des méthodes de prévision ne peut pas se faire sans considérer les paramètres du problème dans lequel on va les utiliser (planification de la production/ réapprovisionnement).

L'étude du lien entre prévision et planification est donc une des pistes de recherche à mener pour améliorer la qualité globale de la chaîne logistique.

Conclusion

Dans cette première partie, nous avons commencé par faire une analyse de l'existant en termes de modèle de prévision, et surtout en termes de méthodes de choix de modèles de prévision. A partir de cette analyse, nous avons constaté que les méthodes existantes ne permettaient pas un choix suffisamment pertinent et rapide du modèle de prévision pour pouvoir l'adapter dynamiquement à l'évolution de la demande.

Nous avons alors développé une méthode permettant, à partir d'une analyse de la demande, de choisir le modèle le plus adapté à son profil et ainsi permettre l'obtention de la meilleure prévision qui soit.

Enfin, cette méthode a été mise en applications sur deux cas industriels réels : Sous la forme d'une étude prospectrice avec Gefco pour l'évaluation de l'apport de la mise en place de prévision sur les flux aval d'une plate-forme de cross-docking et sous la forme d'une étude comparative pour la prévision de la demande en pièces de rechange pour l'entrepôt central de PSA. Dans les deux cas, l'utilisation de notre méthode comparée à l'utilisation d'un modèle statique montre l'intérêt de celle-ci avec de nettes améliorations de la prévision.

Nous pouvons donc conclure sur la pertinence de la méthode que nous avons développée. Malgré ses limites et les limites des études menées, les améliorations sur la qualité de la prévision ont été démontrées.

Chapitre 2 : Modélisation de l'incertitude prévisionnelle

Comme nous avons pu le voir dans le chapitre précédent, la réalisation de la prévision dans le but de contrôler les flux dans la chaîne logistique se heurte à des difficultés importantes. En effet, il n'est pas toujours possible d'avoir des prévisions de bonne qualité et fiables. Notre objectif étant de piloter au mieux les flux et les stocks pour répondre à la demande future. Nous devons donc quantifier et modéliser les erreurs afin de les prendre en compte de la façon la plus fine qui soit. Nous allons donc introduire et définir la notion d'incertitude prévisionnelle. Cette notion fait l'objet de ce deuxième chapitre.

Nous allons commencer par présenter les modèles d'incertitudes existants ainsi que leur fonction dans la Supply Chain. Dans une deuxième section, nous présenterons un modèle d'incertitude prévisionnelle permettant de se rapprocher de la réalité : le modèle mixte. La troisième section permettra de prolonger ce modèle selon une dimension temporelle. Pour chacune de ces sections, nous présenterons la méthode permettant de déterminer les paramètres des modèles ainsi qu'une application réelle permettant de montrer la pertinence de notre recherche.

Présentation de l'existant

Nous allons commencer par présenter l'existant au niveau de la modélisation des incertitudes. En effet, comme nous allons le voir, de nombreuses méthodes différentes existent, chacune étant adaptée à une application donnée. Nous verrons ainsi que pour notre application, les modèles existants ne sont pas suffisants, ce qui justifie notre recherche et notre apport. Nous avons cherché des travaux caractérisant, de façon quantitative, l'évolution de la qualité des prévisions en fonction de l'horizon de prévision. Mais cette recherche a été infructueuse, ce qui nous laisse penser que de tels travaux sont totalement absents.

Afin de pouvoir répondre à notre problématique générale d'optimisation de la chaîne d'approvisionnement sous incertitude sur la demande, la définition des hypothèses de travail concernant les incertitudes considérées et les modèles utilisés est primordiale.

Nous clarifions, dans la section suivante, la notion d'incertitude prévisionnelle et nous proposons des approches pragmatiques pour sa détermination. Nous illustrons toutes ces notions à travers un exemple numérique dans la dernière section de ce chapitre.

I. Les incertitudes

(Galbraith 1974) définit l'incertitude comme étant la différence entre la quantité d'information nécessaire pour accomplir une tâche et la quantité d'information disponible. Dans le domaine industriel Ho (1989) distingue deux catégories d'incertitudes :

- Les incertitudes environnementales : Toute incertitude indépendante de l'outil de production → Incertitude sur la demande/variation des prix de matières premières/ Retard de livraison des fournisseurs/ Variation des taux de changes.
- Les incertitudes dans le process : Toute incertitude en lien direct avec l'outil de production → Problème de qualité/ panne machine/ retard sur la production.

Les incertitudes sur le process ont été abondamment traitées dans la littérature par le biais de propositions de solutions de type Kaizen, 5S, Six Sigma...

Les incertitudes environnementales étant diverses, plus complexes et généralement indépendantes de l'entreprise, c'est à leur traitement que nous nous intéresserons dans ce travail.

Dans la littérature, nous pouvons distinguer trois principaux types d'incertitudes environnementales impactant directement l'approvisionnement :

- L'incertitude sur la demande ;
- L'incertitude sur le délai d'approvisionnement ;
- L'incertitude sur la quantité reçue (provenant des erreurs de quantités livrées, ou de problème de qualité impactant la quantité utile).

Pour faire face à ces incertitudes, plusieurs solutions peuvent être mises en place telles que les quantités de sécurité, les délais de sécurité etc. Les quantités de sécurité sont utilisées pour couvrir les incertitudes sur la demande et les incertitudes sur la qualité des produits. Quant aux délais de sécurité, ils peuvent être utilisés pour couvrir l'incertitude sur les délais de livraison. Nous détaillerons ici en particulier le cas de l'incertitude sur la demande et ses conséquences en étudiant quelques modèles de planification qui la prennent en compte.

(Mula *et al.* 2006) donne une classification des références dans le domaine de la planification en termes d'incertitudes prises en compte, de types de plannings et de méthodes appliquées. A travers la recherche effectuée nous nous sommes aperçus que les incertitudes les plus traitées sont celles portant sur la demande et les délais de livraison. Il est par ailleurs important de préciser que ces deux sujets ont beaucoup été étudiés indépendamment, en particulier l'incertitude de la demande (Gupta & Maranas 2003) mais rares sont les articles les prenant en considération simultanément. Ainsi nous pouvons trouver dans (Dolgui & Prodhon 2007) la classification d'un certain nombre de références où l'auteur discerne les travaux portant sur l'incertitude de la demande, ceux portant sur l'incertitude sur le délai d'approvisionnement, et ceux portant sur ces deux types d'incertitudes.

Tableau 14: classification des références en termes d'incertitudes

Les références	Incertainude de la demande	Incertainude des délais	Incertainude de la demande et des délais
(Babai, 2009)	X		
(Hnaien, 2009)		X	
(ManMohan, 2009)	X		
(Satyaveer, 2009)		X	
(Li, 2008)	X		
(Liang, 2008)	X		
(Torabi, 2008)	X		
(Roghanian, 2007)	X		
(Chen, 2004)	X		
(Ould-Louly, 2004)		X	
(Ryu, 2004)	X		
(Gupta, 2003)	X		
(Dolgui, 2002)		X	
(Enns, 2002)	X		
(Lee, 1999)	X		
(Grasso, 1984)		X	
(Billington, 1983)			X

Avant de s'intéresser spécifiquement à l'incertitude sur la demande, il est important d'identifier les différents moyens de la modéliser. Plusieurs méthodes sont proposées dans la littérature pour la détermination de l'incertitude prévisionnelle. Elles sont regroupées, comme les prévisions de la demande, en deux familles : les méthodes qualitatives et les méthodes quantitatives.

- **Les méthodes qualitatives** : Ces méthodes sont basées sur des jugements d'experts et utilisent des historiques et des scénarios de prévision. Elles sont très subjectives, ce qui fait qu'elles sont rarement utilisées en pilotage des flux mais plutôt dans des décisions à moyen et long terme. Notons aussi que, d'après (Ericsson 2001) et (Wallis 2008), ces méthodes sont également utilisées pour l'estimation de résultats économiques et financiers.
- **Les méthodes quantitatives** : Ces méthodes sont basées sur des modèles mathématiques ayant pour objectif la détermination de l'incertitude prévisionnelle à partir d'un historique de prévisions. En pratique, elles permettent de donner des distributions de probabilité de l'incertitude prévisionnelle. Dans le cas de modèles complexes non linéaires, certaines méthodes se basent sur des modèles de simulation stochastiques.

Trois principales méthodes sont fréquemment utilisées (Liu & Sahinidis 1997) et (Gupta & Maranas 2003) :

- Distribution-based approach : Cette approche a pour objectif d'utiliser des distributions de probabilités (avec une moyenne et une variance connues) afin de modéliser des paramètres incertains.
- Fuzzy-based approach : Pour modéliser les paramètres du problème traité les chercheurs s'appuient sur la logique floue. Les variables incertaines sont beaucoup plus faciles à modéliser en se basant sur la logique floue que sur la logique probabiliste.
- Scenario-based approach : Un certain nombre de scénarii sont imaginés, à ces scénarii sont associées des probabilités d'occurrence. Ainsi différentes évolutions possibles du paramètre sont imaginées, ce qui permet d'identifier un certain nombre de scénarii auxquels sont associées des probabilités d'occurrence.

Chacune de ces méthodes a son domaine d'utilisation. Néanmoins la méthode probabiliste est la plus utilisée pour les modèles de planification. La «scenario based approach» paraît plus adaptée à des questions d'ordre stratégique. La «fuzzy based approach» est une méthode récente dans le domaine de la planification mais intéresse de plus en plus les chercheurs en raison de sa capacité à modéliser les paramètres incertains.

Dans la suite de ce chapitre, nous utilisons une méthode de type « Distribution-based approach » basée principalement sur les historiques des données.

II. Incertitude sur la demande

Selon (Davis 1993) l'incertitude sur la demande se réfère aux variations inconnues et imprévisibles de la quantité nécessaire pour combler les besoins du marché (des consommateurs) ainsi que la période à laquelle cette demande va s'exprimer. Cette incertitude est d'une grande importance dans toute décision basée sur des estimations de demandes futures, comme les décisions de planification de la production ou de pilotage de flux. En gestion des stocks, (Brown 1959) a montré l'importance de l'utilisation de l'incertitude prévisionnelle, notamment pour le calcul des stocks de sécurité.

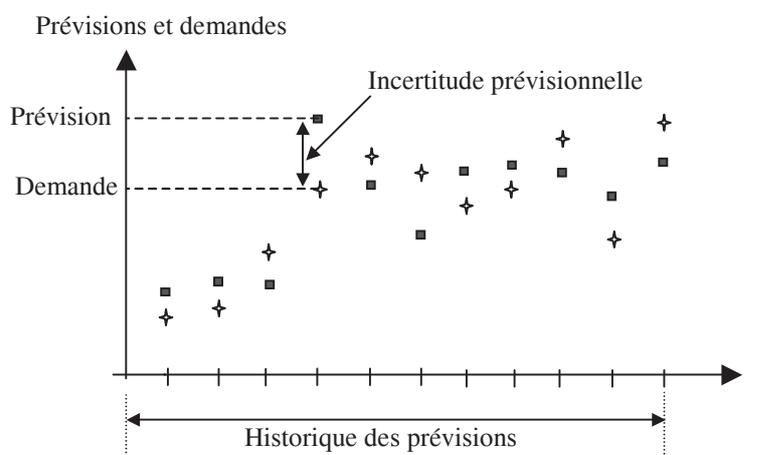


Figure 12: Prévisions et incertitudes prévisionnelles

Les caractéristiques de cette incertitude sur la demande que l'on notera dans la suite de notre travail « incertitude prévisionnelle » et que l'on trouve également notée « erreur prévisionnelle »

dans certains travaux sur la gestion des stocks sont définies par l'erreur sur la prévision de la demande. Elle correspond donc à l'écart entre les prévisions réalisées et les demandes réelles. Le terme « incertitude prévisionnelle » nous semble mieux convenir à cette grandeur car elle reflète la part de l'incertain inhérente au système de prévision et ne peut donc pas être considérée comme une erreur *sensu stricto*.

En pratique, les incertitudes prévisionnelles sont importantes parce qu'elles permettent d'analyser la précision des prévisions passées. Ceci peut permettre, grâce à une analyse rétrospective, de comprendre les erreurs des prévisions passées. Pour avoir une bonne estimation de l'incertitude prévisionnelle, il est donc indispensable de commencer par étudier et analyser l'historique des prévisions couplé à celui des demandes réelles et ensuite, d'utiliser une méthode fiable pour la détermination de l'incertitude prévisionnelle future.

Dans le cas de prévision de la demande, nous pouvons présenter l'incertitude prévisionnelle comme l'intervalle dans lequel sera contenue la demande réelle. En effet, comme nous l'avons vu dans le chapitre précédent, la prévision ne sera que très rarement exacte. En revanche, elle donne une bonne idée de la demande réelle. Ainsi, en rajoutant cet intervalle de confiance à la prévision, nous obtenons une information plus précise sur la valeur probable de la demande. Cet intervalle de confiance va ensuite être modélisé à partir de l'historique du produit afin de correspondre au mieux à la réalité. Nous pouvons représenter cette démarche par la Figure 13.

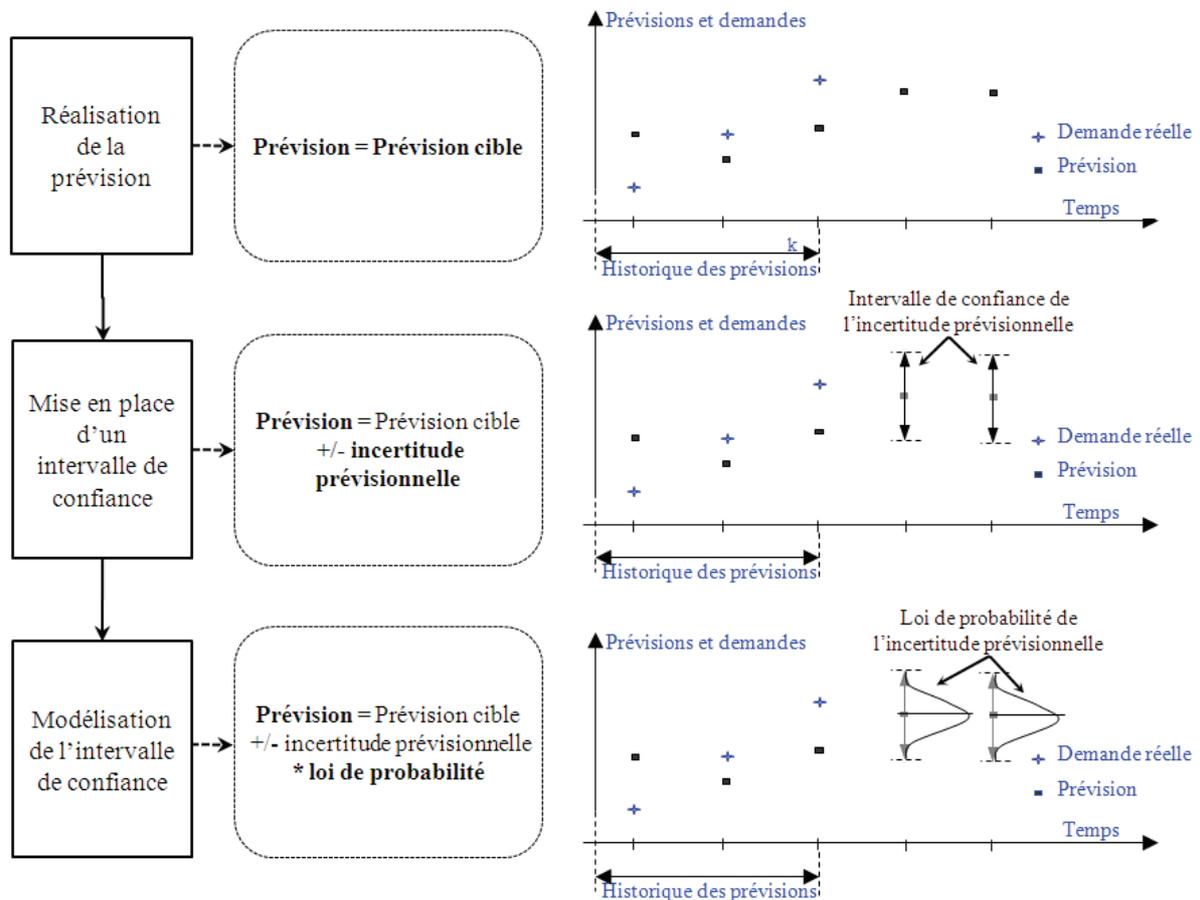


Figure 13: Fiabilisation de la prévision par la mise en place de l'incertitude prévisionnelle

Il est important de préciser que cette erreur peut être à l'origine de deux effets : l'erreur sur la quantité ou l'erreur sur le délai. Néanmoins ces deux cas provoquent une même conséquence : l'excès de stock ou la rupture. En outre ces conséquences peuvent devenir d'autant plus graves lorsqu'elles sont amplifiées par l'effet bullwhip (effet coup de fouet). Cet effet décrit le phénomène selon lequel une petite variation de la demande au niveau du client final va avoir tendance à s'amplifier tout au long de la Supply Chain (Lee *et al.* 1997).

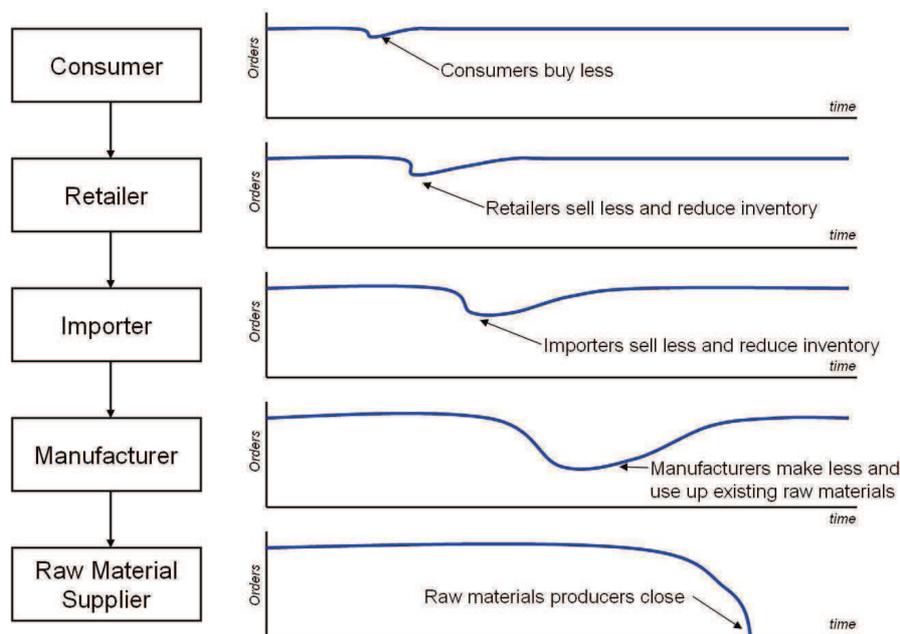


Figure 14: Bullwhipeffect ou effet coup de fouet

D'après (Dolgui & Prodhon 2007) l'incertitude sur la demande a un très mauvais effet sur les systèmes de planification type MRP. En effet, une demande incertaine va engendrer une actualisation régulière des paramètres du système et un changement régulier des objectifs, ce qui entraîne une augmentation du niveau de stock et une détérioration du niveau de service.

D'autre part nous remarquons que certains auteurs ne considèrent pas l'incertitude comme néfaste (Lee & Adam Jr 1986) et (Biggs & Campion 1982). Leur principal argument est de dire que si au niveau de la prévision le biais est positif alors se crée un surplus de stock qui peut être utilisé comme un stock de sécurité pour répondre à d'éventuelles demandes non prévues.

Voici un récapitulatif des travaux de planification prenant en compte l'incertitude sur la demande inspiré de (Dolgui & Prodhon 2007) :

Tableau 15: Travaux prenant en compte l'incertitude de la demande dans la planification

Article	Critère	Paramètre	Type de réseau	Commentaire
De Bodt and Van Wassenhove (1983)	Coûts de stock et de commande	Lot-sizing, Safety stocks	Un niveau	Recommandé avec des coûts de lancement faible et une demande lissée.
Sridharan and Berry (1990)	Coûts de stock et coûts de changement, taux de service	Freezing, replanification	Un niveau	Pas de retour, le gel de l'horizon fait augmenter les coûts du fait d'erreurs de prévisions
Zhao and Lee (1993)	Possession, coût de rupture, taux de service	Freezing, replanification, planning horizon	Multi-niveau	
Sridharan and Laforge (1994)	Taux de service	Freezing	Produit unique	L'extension de l'horizon gelé induit une augmentation du stock
Grubbström and Molinder (1996)	Coût de lancement, de stock et de retard	Safety MPS	Un et deux niveaux	Demande modélisée par une distribution de Poisson
Grubbström and Tang (1999)	Valeur nette actuelle	Safety Stocks	Multi niveau	Demande modélisée par une distribution Gamma
Gomaa <i>et al.</i> (1999)	Nervosité, coûts de lancement, de possession et de rupture	Nine lot-sizing rules among 10 factors	Multi-niveaux	Programmation mathématique
Kazan <i>et al.</i> (2000)	Coûts de lancement, de changement et de possession	Lot sizing	Un niveau	Silver Meal recommandé avec un haut ratio cout de lancement / cout de possession
Jeunet and Jonard (2000)	Coûts de lancement et de gestion des stocks	Lot sizing	Un niveau	Règle de lot sizing dépendant du système (de sa flexibilité)
Tang and Grubbström (2002)	Coûts de possession, de rupture et de replanification	Freezing, replanification	Un niveau	Optimisation
Bai <i>et al.</i> (2002)	Coûts de lancement, de changement, de possession, taux de service	Freezing, lot-sizing, safety stock, replanification	Multi-niveaux	Le stock de sécurité permet d'avoir un bon taux de service
Grubbström and Wang (2003)	Valeur nette présente	Stock de sécurité	Multi-niveaux, multi-étage, capacité	Demande modélisée par une distribution de Poisson

III. Conclusion

Dans cette première section, nous avons présenté le rôle de l'analyse des incertitudes dans l'amélioration des modèles de pilotage de flux.

Après avoir défini plus précisément l'incertitude sur la demande, nous avons également présenté les travaux existants dans la littérature sur cette incertitude et sur l'incertitude sur le délai d'approvisionnement. Cette étude nous a permis de montrer l'intérêt d'étudier la modélisation de

l'incertitude et en particulier celle portant sur la demande. En effet, comme on a pu le voir à travers l'analyse de la littérature, celle-ci est nécessaire pour étudier l'optimisation des approvisionnements sous incertitude sur la demande. Cette analyse nous a également montré qu'il y avait très peu de modèle prenant en compte l'incertitude sur la demande via une modélisation mixte (absolue et relative). Nous allons donc maintenant présenter les deux modèles que nous avons développés afin de modéliser l'incertitude sur la demande. Cette incertitude pourra également être appelée variabilité commerciale, appellation plus courante dans le domaine industriel.

Le modèle mixte : modèle théorique et validation sur cas réels

Après avoir présenté l'intérêt de modéliser l'incertitude prévisionnelle, nous allons maintenant présenter notre premier modèle d'incertitude prévisionnelle : le modèle d'incertitude prévisionnelle mixte. Pour cela, nous allons présenter sa modélisation, puis nous présenterons la méthode de détermination des coefficients permettant de caractériser les paramètres du modèle à partir des données réelles. Enfin, nous montrerons la cohérence du modèle par rapport à la réalité grâce à la modélisation de l'incertitude prévisionnelle mixte sur un exemple réel.

I. Modèle théorique

Comme nous l'avons vu dans la section précédente, plusieurs méthodes sont possibles pour modéliser l'incertitude prévisionnelle. Dans notre travail, nous utilisons une méthode quantitative qui consiste à déterminer la distribution de probabilité de l'incertitude prévisionnelle à partir de l'historique de la demande. Cette méthode empirique présente l'avantage par rapport à une approche d'avoir la loi de consommation exacte du produit étudié. En effet, le calcul des écarts entre les prévisions et les demandes réelles sur toutes les périodes de l'historique passé permet d'obtenir la distribution de probabilité de l'incertitude prévisionnelle correspondant au produit étudié. Ainsi, chaque produit est traité de façon unique et personnalisée. Cela permet d'adapter le modèle spécifiquement à chaque produit et donc d'avoir une incertitude prévisionnelle correspondant spécifiquement au produit considéré.

En fonction du type d'erreur de prévision, nous pouvons distinguer trois modèles d'incertitude prévisionnelle : Deux basiques, qui sont le modèle absolu et le modèle relatif, et un troisième qui est l'intégration des deux premiers, le modèle mixte. Dans la littérature, nous retrouvons ces mêmes modèles avec la terminologie "erreur prévisionnelle" sous les appellations de modèle additif, modèle multiplicatif et modèle mixte.

A. Modèle absolu:

Dans ce modèle, l'incertitude prévisionnelle représente l'écart entre demande et prévision en valeur absolue. A une période k , l'incertitude prévisionnelle FU_k^A est fonction de la prévision F_k et de la demande D_k comme suit :

$$FU_k^A = D_k - F_k.$$

Une fois initialisée, l'incertitude prévisionnelle absolue ne change donc plus en fonction de la valeur de la prévision. Ce modèle permet d'avoir un intervalle de confiance fixe quelle que soit la valeur de la prévision.

Ce modèle peut, également, être vu comme un modèle additif puisque la demande peut s'écrire sous la forme : $D_k = F_k + FU_k^A$.

B. Modèle relatif:

Dans ce deuxième modèle, l'incertitude prévisionnelle représente l'écart entre demande et prévision, rapporté à la valeur de la prévision. C'est donc une valeur relative. A une période k , l'incertitude prévisionnelle FU_k^R est fonction de la prévision F_k et la demande D_k comme suit :

$$FU_k^R = \frac{D_k - F_k}{F_k} = \left(\frac{D_k}{F_k} - 1 \right)$$

A l'inverse du modèle précédent, l'incertitude prévisionnelle relative va évoluer en fonction de la valeur de la prévision. Ce modèle d'incertitude permet d'avoir un intervalle de confiance variable en fonction de la valeur de la prévision.

Ce modèle peut être vu comme un modèle multiplicatif puisque la demande peut s'écrire sous la forme : $D_k = F_k (1 + FU_k^R)$

C. Modèle mixte :

Dans ce troisième modèle, l'incertitude prévisionnelle comporte une composante relative et une composante absolue. A une période k , l'incertitude prévisionnelle peut s'écrire sous la forme suivante :

$$FU_k^M = \alpha \cdot (D_k - F_k) + \beta \cdot \left(\frac{D_k - F_k}{F_k} \right) = \alpha \cdot (D_k - F_k) + \beta \cdot \left(\frac{D_k}{F_k} - 1 \right).$$

Ce modèle est donc un mixte entre un modèle additif et un modèle multiplicatif. La demande peut alors s'écrire sous la forme

$$D_k = F_k + FU_k^M \left(\frac{F_k}{\beta + \alpha \cdot F_k} \right) \text{ ou encore } D_k = (F_k + FU_k^A) + (F_k \cdot FU_k^R)$$

La difficulté du modèle mixte repose dans la détermination des coefficients α et β . Nous allons alors exprimer l'incertitude prévisionnelle d'une autre façon permettant de la caractériser et de faire apparaître la composante absolue d'un côté et la composante relative de l'autre :

$$FU_k^M = A + B \cdot F_k$$

où « A » représente la composante absolue de l'incertitude prévisionnelle, c'est-à-dire ne dépendant pas de la valeur de la prévision, et « $B \cdot F_k$ » la part relative, car dépendant de la prévision. Nous allons voir dans la section suivante la méthode permettant de définir ces paramètres à partir de l'historique des erreurs de prévisions. Ces paramètres peuvent donc être fixes en étant déterminés avec les premières valeurs d'historique disponible, ou être dynamiques et s'adapter à l'évolution du produit. De plus, les modèles existants, à savoir le modèle absolu et le modèle relatif, peuvent être considérés comme des cas particuliers du modèle mixte que nous proposons.

D. Exemple numérique

Nous allons maintenant présenter ces trois modèles d'incertitudes sur un exemple numérique.

Pour une incertitude prévisionnelle donnée, nous allons voir l'évolution de l'intervalle dans lequel se trouvera la demande réelle en fonction de la prévision. Nous retiendrons les valeurs suivantes qui seraient dans un cas réel à déterminer à partir des historiques d'erreurs de prévision :

Tableau 16: Exemple numérique d'incertitude prévisionnelle

Prévision	Intervalle de la demande pour I.P. Absolue	Intervalle de la demande pour I.P. Relative	Intervalle de la demande pour I.P. Mixte
paramètres	15	30%	8 _ 15%
0	[0; 15]	[0; 0]	[0; 8]
5	[0; 20]	[4; 7]	[0; 14]
10	[0; 25]	[7; 13]	[1; 20]
15	[0; 30]	[11; 20]	[5; 25]
20	[5; 35]	[14; 26]	[9; 31]
25	[10; 40]	[18; 33]	[13; 37]
30	[15; 45]	[21; 39]	[18; 43]
35	[20; 50]	[25; 46]	[22; 48]
40	[25; 55]	[28; 52]	[26; 54]
45	[30; 60]	[32; 59]	[30; 60]
50	[35; 65]	[35; 65]	[35; 66]
55	[40; 70]	[39; 72]	[39; 71]
60	[45; 75]	[42; 78]	[43; 77]
65	[50; 80]	[46; 85]	[47; 83]
70	[55; 85]	[49; 91]	[52; 89]
75	[60; 90]	[53; 98]	[56; 94]
80	[65; 95]	[56; 104]	[60; 100]
85	[70; 100]	[60; 111]	[64; 106]
90	[75; 105]	[63; 117]	[69; 112]
95	[80; 110]	[67; 124]	[73; 117]
100	[85; 115]	[70; 130]	[77; 123]

Le Tableau 16 illustré par la Figure 15 nous permet de voir l'évolution des trois intervalles de confiances centrés autour de la prévision en fonction de la valeur de la prévision.

Cet intervalle garde donc la même largeur pour une incertitude absolue, tandis qu'elle augmente avec la prévision pour les incertitudes relatives et mixtes.

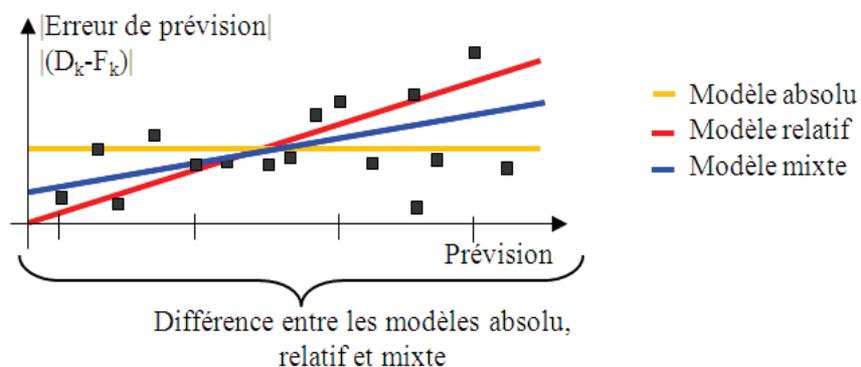


Figure 15: Valeur absolue de l'erreur de prévision en fonction de la prévision pour trois types d'incertitudes prévisionnelles

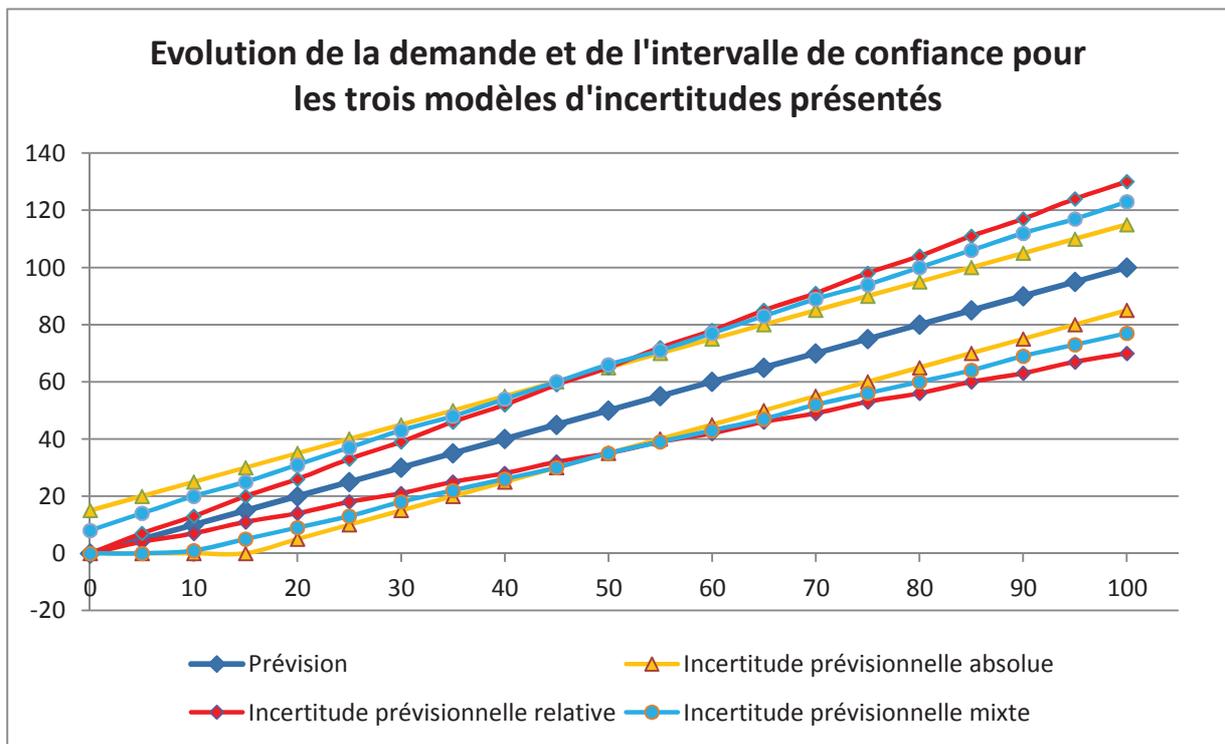


Figure 16: Evolution des trois types d'incertitudes prévisionnelles en fonction des prévisions

Nous avons fait plusieurs hypothèses dans notre travail. La première hypothèse que l'on a retenue et qui est utilisée dans le Tableau 16 est que l'intervalle de confiance est centré autour de la prévision ce qui correspond à une prévision non biaisée. Dans ce cas, l'erreur moyenne de prévision est alors nulle. Cette hypothèse nous permet de pouvoir définir une incertitude prévisionnelle centrée autour de la valeur de la prévision. Si l'hypothèse n'est pas vérifiée, la méthode reste valable, l'incertitude prévisionnelle sera simplement décalée autour de la valeur de la prévision. Cette hypothèse se vérifie à partir de l'historique des erreurs de prévision, en regardant si la moyenne des erreurs est nulle ou pas. Ainsi, selon cette analyse, l'intervalle de confiance pourra être déplacé autour de la prévision en fonction des résultats trouvés. Cette hypothèse est illustrée dans la Figure 17. L'intervalle de confiance est alors décentré, comme nous pouvons le voir sur la Figure 18.

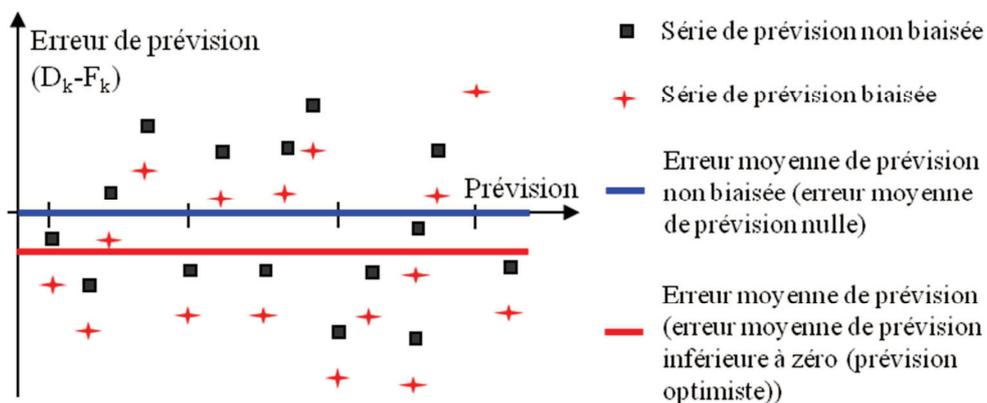


Figure 17: Illustration de l'hypothèse de prévision non biaisée (1)

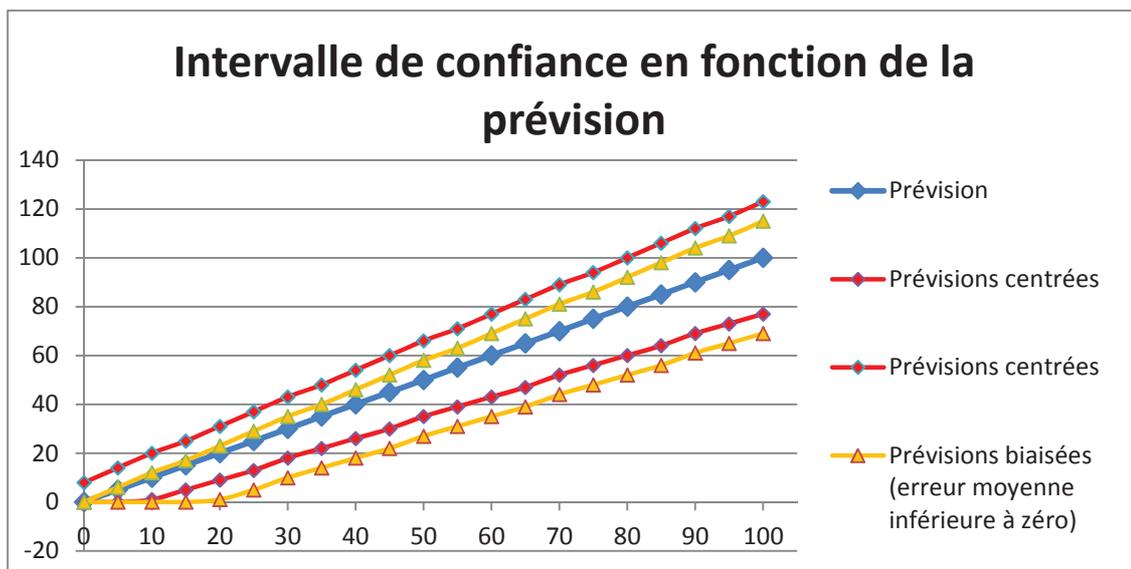


Figure 18: Illustration de l'hypothèse de prévision non biaisée (2)

Nous allons maintenant présenter comment obtenir les paramètres de l'incertitude prévisionnelle mixte. Ces paramètres dans l'exemple précédent étaient $A = 8$ (incertitude absolue) et $B = 15\%$ (incertitude relative).

II. Obtention des paramètres à partir d'un historique des données

Maintenant que nous avons défini le modèle d'incertitude mixte, nous allons voir comment définir ses paramètres afin d'identifier les parties absolue et relative.

Ces hypothèses étant faites, nous allons pouvoir tracer le graphe représentant la valeur absolue de l'erreur de prévision en fonction de la prévision avec les données de l'historique. Nous pouvons alors tracer une droite de tendance de la forme droite affine ($y(x) = a + b \cdot x$) à partir du nuage de points obtenu précédemment. Cette fonction affine représente ainsi notre incertitude prévisionnelle mixte de la forme $FU_k^M = A + B \cdot F_k$. La Figure 19 illustre ceci.

Cette démarche permet de caractériser l'incertitude prévisionnelle pour une prévision donnée. En effet, les caractéristiques d'une prévision à J+1 ne sont pas forcément les mêmes que pour une prévision à J+15. Il faudra donc veiller à déterminer les paramètres adéquats en fonction de la prévision que l'on souhaite utiliser. La qualité de la modélisation dépend de l'historique disponible car un historique suffisant est nécessaire pour obtenir une modélisation ayant des paramètres significatifs.

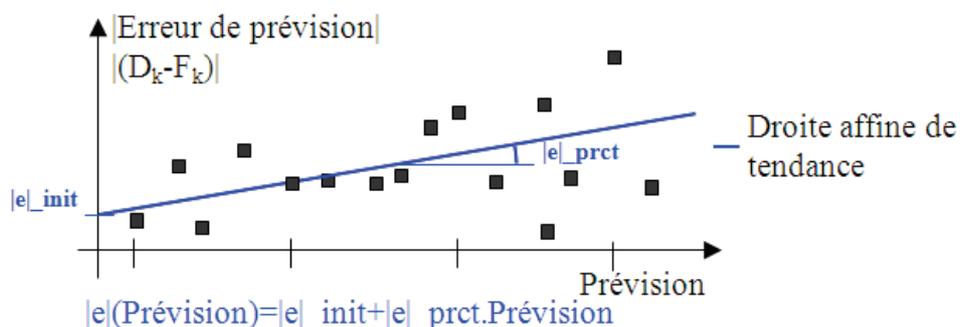


Figure 19: Tracer de la droite de tendance modélisant l'incertitude prévisionnelle mixte

Il est important pour la suite de notre travail de pouvoir modéliser les erreurs de prévisions et donc l'incertitude prévisionnelles pour plusieurs horizons car cela va nous permettre de définir précisément la sécurisation à mettre en place, donc le niveau du stock de sécurité, en fonction de l'horizon de prévisions et de la réactualisation de ces dernières.

Dans le cas où il n'y aurait pas d'historique disponible, les mêmes méthodes que précédemment peuvent encore être utilisées, soit en prenant des données standard, soit en prenant les paramètres d'un produit similaire. Dans tous les cas, dès qu'un historique suffisant est disponible, l'utilisation de celui-ci permet de caractériser au mieux les paramètres en question.

Nous allons maintenant présenter les résultats obtenus sur des données réelles.

III. Validation du modèle obtenu sur un jeu de données

Afin de valider notre modèle, nous l'avons appliqué sur un échantillon donné par PSA contenant 30 produits ayant des profils de demande différents. Ces produits sont approvisionnés pour une usine de montage. Nous avons déterminé l'erreur de prévision à partir de l'historique des prévisions et des demandes sur un grand horizon (prévision et demande quotidiennes sur un horizon de 3 ans).

A partir de ces résultats, nous avons défini l'incertitude prévisionnelle de chacun des produits. Ayant plusieurs horizons de prévision, nous avons caractérisé pour chaque produit plusieurs incertitudes prévisionnelles. La Figure 20 présente les nuages de points et les courbes obtenus pour le produit R_21 pour les horizons de prévisions J+3 et J+18. Nous voyons ici avec l'équation des deux droites de tendance que pour J+3, A=9,5 et B=2,3% tandis que pour J+18, A=70 et B=7,7%.

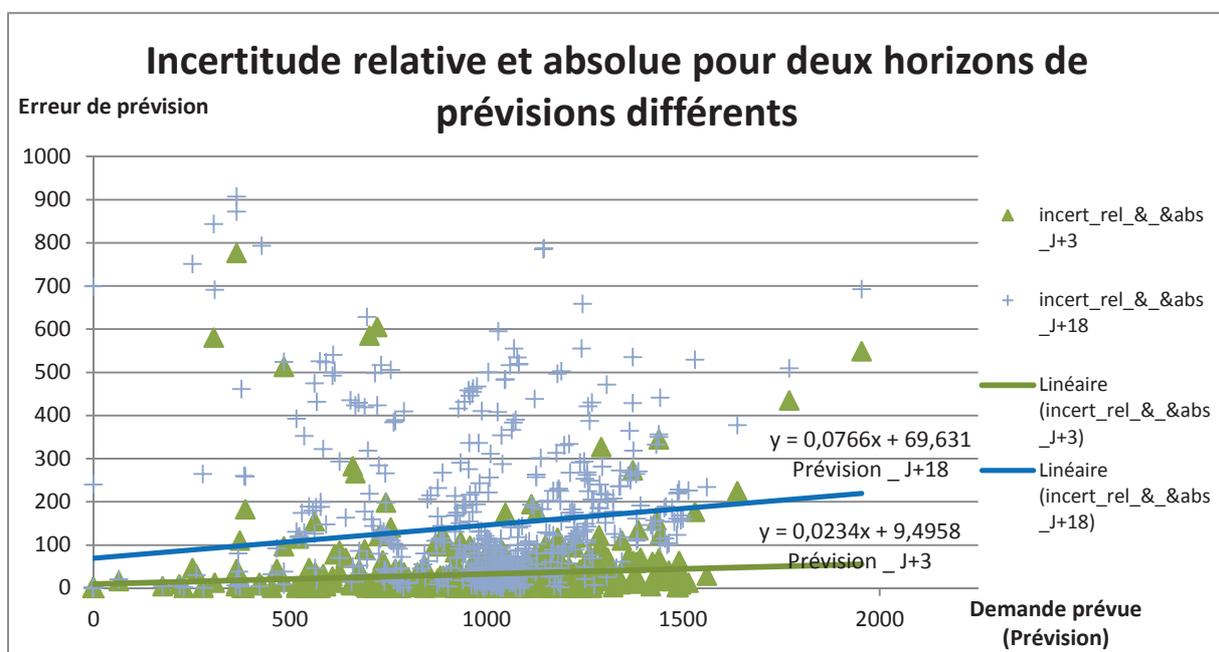


Figure 20: Détermination des paramètres de l'incertitude prévisionnelle mixte sur deux horizons différents

Tableau 17: Incertitudes prévisionnelles pour chacun des produits de l'échantillon et pour les différents horizons de prévisions

Produit	J+1		J+2		J+3		J+6		J+9		J+12		J+18		J+24		J+30		J+36		J+42		J+48		J+49		Moyenne		Demande moyenne	I.P.Abs/Dem Moy.
	Rel.	Abs.	Rel.	Abs.	Rel.	Abs.	Rel.	Abs.	Rel.	Abs.	Rel.	Abs.	Rel.	Abs.	Rel.	Abs.	Rel.	Abs.	Rel.	Abs.										
R_01	2%	-1	3%	0	4%	-2	4%	0	10%	-1	12%	4	12%	9	12%	11	12%	12	12%	13	11%	16	11%	19	11%	19	9%	8	214	4%
R_02	0%	3	0%	6	0%	7	0%	10	2%	26	6%	27	11%	25	13%	24	13%	24	13%	24	13%	26	13%	27	14%	27	8%	20	265	7%
R_03	5%	-1	6%	-1	8%	-1	10%	-1	18%	-2	19%	-1	19%	0	23%	-1	24%	-1	27%	-1	30%	-2	31%	-2	31%	-2	19%	-1	57	-2%
R_04	1%	1	0%	2	1%	2	1%	3	0%	10	5%	11	9%	9	9%	10	9%	10	10%	10	9%	11	10%	11	10%	11	6%	8	135	6%
R_05	6%	-1	5%	0	6%	0	10%	0	12%	2	14%	3	14%	4	14%	6	14%	6	14%	6	13%	7	13%	8	13%	8	11%	4	82	5%
R_06	1%	1	1%	2	2%	2	2%	5	2%	17	4%	20	5%	26	4%	30	4%	30	4%	31	4%	31	4%	32	5%	32	3%	20	284	7%
R_07	4%	2	4%	2	5%	2	7%	3	7%	7	10%	8	14%	8	14%	9	13%	9	12%	10	13%	11	13%	12	13%	12	10%	7	69	11%
R_08	1%	2	1%	3	2%	3	2%	6	2%	18	4%	22	5%	27	3%	31	4%	31	4%	33	4%	34	4%	34	4%	34	3%	21	290	7%
R_09	5%	1	4%	2	6%	2	7%	3	11%	3	14%	4	16%	4	17%	4	18%	3	19%	3	18%	4	19%	4	19%	4	13%	3	64	5%
R_10	1%	1	0%	2	1%	2	0%	6	0%	10	5%	11	9%	9	9%	10	10%	10	10%	10	10%	10	11%	9	12%	9	6%	8	130	6%
R_11	1%	1	1%	1	2%	2	2%	3	2%	9	4%	11	4%	16	2%	18	3%	18	3%	19	3%	21	4%	17	4%	17	3%	12	145	8%
R_12	3%	0	3%	0	5%	0	7%	0	17%	-1	18%	0	18%	0	22%	0	22%	0	25%	0	28%	0	29%	0	29%	0	17%	0	28	-1%
R_13	2%	7	2%	9	2%	11	3%	14	3%	26	6%	28	6%	38	5%	42	6%	41	6%	43	6%	46	7%	39	7%	38	5%	29	364	8%
R_14	1%	3	1%	4	1%	4	2%	7	2%	19	4%	22	4%	29	3%	33	3%	32	3%	34	3%	35	3%	34	4%	35	3%	22	283	8%
R_15	5%	-2	5%	-1	5%	0	5%	0	9%	1	10%	3	11%	4	11%	5	11%	5	11%	6	10%	7	9%	8	9%	9	9%	4	83	4%
R_16	1%	4	1%	20	1%	19	2%	39	4%	96	6%	137	8%	150	8%	163	8%	164	8%	168	8%	188	7%	200	8%	200	5%	119	1932	6%
R_17	4%	1	4%	1	5%	1	7%	2	8%	6	10%	8	11%	10	12%	10	12%	11	12%	11	12%	11	12%	11	12%	11	9%	7	139	5%
R_18	2%	3	2%	4	2%	4	3%	8	3%	17	5%	20	5%	24	4%	28	4%	29	4%	30	4%	30	5%	31	5%	30	4%	20	257	8%
R_19	1%	1	1%	2	1%	2	1%	3	0%	11	5%	11	8%	11	9%	11	9%	12	10%	12	9%	14	10%	14	10%	14	6%	9	136	7%
R_20	1%	1	1%	5	2%	5	2%	10	3%	30	5%	39	6%	46	8%	44	8%	41	10%	40	10%	38	11%	36	11%	36	6%	28	553	5%
R_21	2%	2	2%	9	2%	9	3%	16	4%	45	6%	63	8%	70	8%	77	8%	79	8%	82	7%	93	7%	99	7%	100	6%	57	856	7%
R_22	0%	1	0%	1	0%	2	1%	2	5%	4	6%	6	4%	9	3%	10	3%	10	3%	10	4%	10	4%	10	4%	10	3%	7	65	10%
R_23	1%	6	1%	9	1%	11	2%	14	4%	28	5%	40	3%	58	2%	64	2%	63	2%	66	1%	67	1%	69	1%	69	2%	43	400	11%
R_24	1%	10	1%	28	1%	30	1%	51	0%	153	2%	191	4%	204	4%	218	5%	218	5%	222	5%	231	5%	228	6%	226	3%	154	1973	8%
R_25	4%	7	4%	7	5%	9	7%	8	10%	12	12%	13	13%	18	13%	19	13%	19	12%	21	11%	22	11%	22	11%	22	10%	15	163	9%
R_26	3%	1	4%	2	5%	2	7%	3	8%	5	11%	4	13%	5	13%	5	12%	6	12%	7	11%	7	12%	8	12%	8	9%	5	56	9%
R_27	3%	1	4%	2	5%	2	7%	3	8%	5	11%	4	13%	5	13%	5	12%	6	12%	7	11%	7	12%	8	12%	8	9%	5	56	9%
R_28	1%	1	1%	5	1%	5	2%	10	3%	25	6%	35	7%	39	7%	43	7%	44	8%	45	7%	50	7%	54	7%	54	5%	32	486	7%
R_29	0%	1	0%	1	0%	2	1%	2	5%	4	6%	6	4%	9	3%	10	3%	10	3%	10	4%	10	4%	10	4%	10	3%	7	65	10%
R_30	0%	1	0%	1	0%	2	1%	2	5%	4	6%	6	4%	9	3%	10	3%	10	3%	10	4%	10	4%	10	4%	10	3%	7	65	10%
Moyenne	2%	2	2%	4	3%	5	4%	8	6%	20	8%	25	9%	29	9%	32	9%	32	10%	33	10%	35	10%	35	10%	35	7%	23	323	7%

Nous pouvons donc caractériser les produits de façon personnalisée. Les résultats que nous obtenons nous montrent que l'incertitude prévisionnelle est dans la plupart des cas modélisable sous la forme d'une incertitude mixte avec une part relative et une part absolue. Comme on peut le voir dans les dernières colonnes du Tableau 17, dans certains cas, la part de l'incertitude absolue ou de l'incertitude relative devient négligeable devant l'autre. Cependant, la mise en place d'une modélisation mixte permet d'avoir un résultat bien plus précis que si l'on se limitait à l'utilisation d'un seul modèle absolu ou relatif. En effet, Pour mettre en évidence ceci, nous avons comparé la corrélation des différents modèles étudiés par rapport aux séries de données. Ces résultats sont présentés dans le Tableau 18. Les gains en corrélation apporté par l'utilisation du modèle mixte par rapport aux modèles relatif pur et absolu pur sont en moyenne pour les 30 produits étudiés respectivement de 47% et 59%.

Tableau 18: Comparaison corrélation modèles relatif, absolu et mixte et gains associés

Produit	modèle relatif pur		modèle absolu pur		modèle absolu-relatif			Gain en corrélation mixte vs relatif pur	Gain en corrélation mixte vs absolu pur
	relative	Coef. de corrélation	absolue	Coef. de corrélation	relative	absolue	Coef. de corrélation		
R_01	11,5%	0,74	26,74	0,53	8,9%	7,62	0,98	25%	46%
R_02	13,5%	0,04	52,73	0,58	7,5%	19,68	0,70	94%	17%
R_03	18,7%	0,98	9,99	0,98	19,3%	0,98	0,99	1%	1%
R_04	10,4%	0,05	15,49	0,11	5,8%	7,72	0,75	94%	86%
R_05	14,6%	0,90	13,07	0,75	11,3%	3,81	0,99	9%	24%
R_06	8,4%	0,33	29,34	0,11	3,3%	19,85	0,88	62%	88%
R_07	17,7%	0,12	13,93	0,34	9,8%	7,24	0,84	85%	60%
R_08	8,6%	0,34	30,30	0,07	3,1%	21,42	0,68	50%	89%
R_09	16,9%	0,92	11,59	0,74	13,3%	3,11	0,99	7%	25%
R_10	10,5%	0,08	15,28	0,15	6,0%	7,52	0,89	91%	83%
R_11	8,8%	0,33	15,73	0,05	2,7%	11,83	0,49	32%	89%
R_12	17,2%	0,98	4,68	0,98	17,5%	0,18	0,99	1%	1%
R_13	10,1%	0,32	46,59	0,19	4,7%	29,36	0,75	57%	75%
R_14	8,4%	0,35	29,73	0,05	2,6%	22,43	0,48	27%	89%
R_15	11,8%	0,52	10,72	0,38	8,6%	3,54	0,92	44%	59%
R_16	10,3%	0,30	221,64	0,11	5,3%	119,16	0,71	57%	85%
R_17	13,5%	0,59	20,25	0,34	9,4%	7,21	0,99	40%	65%
R_18	9,3%	0,34	29,18	0,11	3,6%	19,90	0,96	65%	89%
R_19	11,1%	0,30	16,85	0,10	5,7%	9,06	0,70	56%	86%
R_20	9,9%	0,19	61,72	0,22	6,0%	28,50	0,98	80%	77%
R_21	10,9%	0,30	104,71	0,12	5,5%	57,46	0,78	61%	85%
R_22	10,4%	0,37	8,58	0,06	2,9%	6,69	0,48	23%	88%
R_23	8,7%	0,41	50,70	0,07	1,8%	43,34	0,45	8%	84%
R_24	9,6%	0,33	216,13	0,03	3,1%	154,44	0,42	20%	92%
R_25	15,1%	0,46	31,20	0,89	9,7%	15,36	0,99	54%	10%
R_26	14,8%	0,37	10,05	0,62	9,4%	4,79	0,98	62%	37%
R_27	14,8%	0,37	10,05	0,62	9,4%	4,79	0,98	62%	37%
R_28	10,2%	0,31	55,81	0,09	5,0%	31,68	0,61	50%	85%
R_29	10,4%	0,37	8,58	0,06	2,9%	6,69	0,48	23%	88%
R_30	10,4%	0,37	8,58	0,06	2,9%	6,69	0,48	23%	88%
Moyenne	11,9%	0,41	39,33	0,32	6,9%	22,66	0,78	47%	59%

Il y a donc un grand intérêt à préférer l'utilisation du modèle mixte par rapport aux modèles soit relatif, soit absolu en moyenne. Nous noterons toutefois que le bénéfice est plus disparates par rapport au modèle relatif, celui-ci allant de 0 à 1300%.

IV. Conclusion

Comme nous l'avons vu, la détermination des paramètres du modèle mixte tel que nous l'avons présenté nécessite la présence d'un historique de données. Dans le cas d'un produit sans historique, la détermination de ces paramètres pose donc problème. Une analogie peut alors être faite avec les méthodes de prévision sans historique. Les deux principales méthodes possibles sont, comme pour la prévision, l'utilisation de valeur standard ou l'utilisation des valeurs d'un produit jugé « similaire ». Les paramètres standard que nous pourrions conseiller suite à nos simulations sont les valeurs de 7% de la demande moyenne pour le paramètre A et 7% pour le paramètre B dans le cadre de notre étude, c'est-à-dire pour les produits représenté par notre échantillon.

Les hypothèses que nous avons faites concernant le biais de la prévision et le fait de considérer des erreurs de prévision symétriques autour de la moyenne ne constituent pas un frein à l'utilisation de notre méthode de détermination de l'incertitude prévisionnelle mixte. En effet, en cas de biais dans la prévision, nous avons montré qu'il suffit de décentrer ensuite l'incertitude prévisionnelle trouvée par rapport à la prévision réalisée.

Cette modélisation va nous permettre par la suite de pouvoir modéliser plus précisément la loi théorique de l'incertitude prévisionnelle. En effet, cette modélisation permettrait d'avoir une sécurisation qui ne se ferait non plus uniquement par rapport à une fraction de l'historique échantillonné, mais sur un modèle statistique bâti sur un historique définit. Ce modèle statistique pourra alors être utilisé avec des données prédéfinies, ou avec des données définies à partir de l'historique propre aux produits à sécuriser. Nous pourrions alors reprendre les travaux de (Babai 2005) en prenant en compte l'évolution de notre incertitude en fonction de la prévision. Cela se retrouverait principalement dans le coefficient de l'écart type de la loi statistique utilisée. En effet, cet écart type jouerait le rôle de notre incertitude prévisionnelle, c'est-à-dire mixte et évoluant en fonction de la prévision.

Le modèle évolutif : modèle théorique et validation sur cas réels

La première évolution que nous avons proposée pour la modélisation de l'incertitude prévisionnelle était donc la prise en compte simultanée des caractères absolu et relatif de l'incertitude en fonction de la prévision.

Nous allons maintenant présenter une deuxième évolution. Celle-ci prend en compte la dimension temporelle. En effet, il paraît évident que selon l'horizon auquel on prévoit, étant données les informations actuelles dont on dispose et la variabilité de nombreux paramètres comme la demande, la prévision sera moins fiable à un horizon lointain qu'à un horizon proche. Nous avons donc souhaité étudier et modéliser l'évolution de l'incertitude prévisionnelle en fonction de l'horizon de prévision.

Nous allons donc présenter le modèle d'évolution que l'on a construit. Suite à cela, nous présenterons la démarche permettant de déterminer les paramètres de ce modèle pour l'incertitude prévisionnelle à modéliser. Pour finir, comme pour la section précédente, nous validerons notre modèle sur un exemple réel.

I. Un modèle théorique

Suite à la modélisation de l'évolution de l'incertitude prévisionnelle sur l'échantillon de données fourni par notre partenaire industriel, nous avons défini la forme de notre modèle d'évolution. En effet, la courbe d'évolution présente une forme logarithmique que l'on va pouvoir modéliser.

Nous avons alors opté pour un modèle d'évolution de l'incertitude prévisionnelle de la forme suivante :

$$EFU_{\mu,\rho}(t,k) = \mu \cdot FU_{\max}(t) \cdot (1 - e^{\rho \cdot k}) \quad (\text{Modèle « exponentiel max »})$$

avec : FU_{\max} : l'incertitude prévisionnelle maximale, c'est-à-dire l'incertitude prévisionnelle pour la période k_{\max} .

t : la période actuelle

k : la période extrapolée

μ : le paramètre d'échelle de l'incertitude

ρ : le paramètre d'évolution ($\rho \in]0 ; \infty[$)

Nous obtenons alors des courbes d'évolutions de la forme de celle de la Figure 21. Le modèle nécessite cependant d'avoir la valeur de l'incertitude prévisionnelle maximale, ce qui n'est pas forcément facile. Nous pouvons donc à l'inverse, définir l'évolution de l'incertitude prévisionnelle à partir de celle de la 1^{ère} période extrapolée. Nous obtenons alors le modèle suivant :

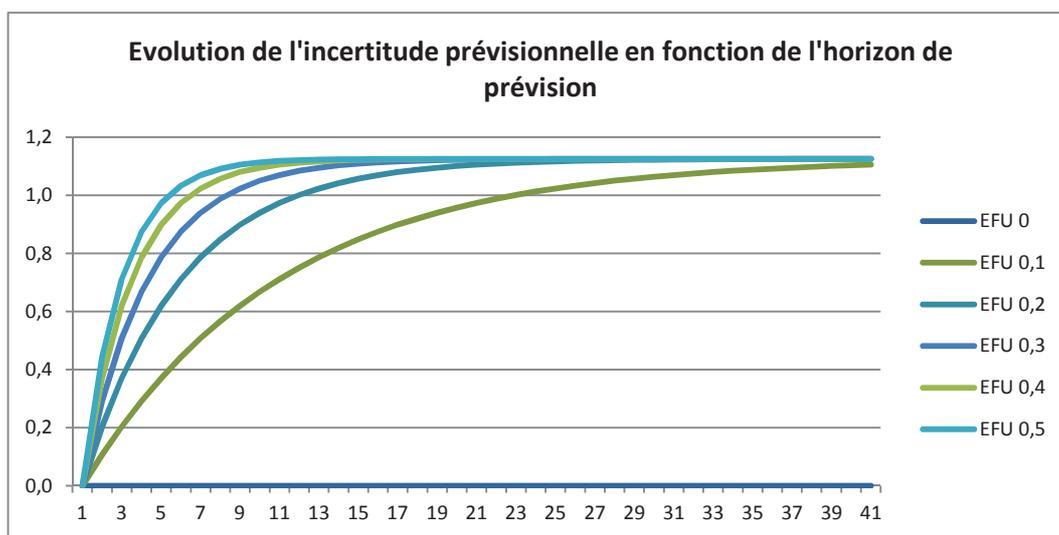


Figure 21: Evolution de l'incertitude modèle « Exponentiel max »

$$EFU_{\mu,\rho}(t,k) = \mu \cdot FU_1(t) \cdot (1 - e^{-\rho \cdot k}) \quad (\text{Modèle « exponentiel 1 »})$$

avec : FU_1 : l'incertitude prévisionnelle de la première période extrapolée (FU pour $k=t+1$).

t : la période actuelle

k : la période extrapolée

μ : le paramètre d'échelle de l'incertitude

ρ : le paramètre d'évolution ($\rho \in]0 ; \infty[$)

Ce modèle permet donc de déterminer l'évolution de l'incertitude prévisionnelle en fonction de l'historique des erreurs de prévisions et de leur évolution. La connaissance de l'incertitude pour la prévision à $J+1$ permet d'extrapoler et de connaître l'incertitude jusqu'à $J+k$ où $k \in]2 ; k_{max} [$. k_{max} dépend du nombre de périodes d'extrapolation prises en compte lors de la détermination des paramètres μ et ρ du modèle.

Nous allons maintenant présenter la méthode permettant de déterminer ces paramètres à partir d'un historique.

II. Obtention des paramètres à partir d'un historique

Maintenant que nous avons défini le modèle d'évolution de l'incertitude prévisionnelle, nous allons voir comment définir ses paramètres afin d'identifier la vitesse d'évolution et la taille de l'incertitude à l'horizon maxi.

Contrairement à la détermination de l'incertitude prévisionnelle mixte, nous ne ferons pas ici d'hypothèses concernant la prévision. En effet, la détermination des paramètres permettra de faire ressortir si elle est biaisée ou non et si les erreurs sont symétriques ou non.

Afin de déterminer les paramètres du modèle, un échantillon de l'historique des prévisions de $J+1$ à $J+k_{max}$ ainsi que la demande réelle est nécessaire. En effet, les paramètres permettant d'extrapoler les valeurs de l'incertitude prévisionnelle future vont dépendre de l'évolution de l'incertitude prévisionnelle passée. Ici comme pour les modèles précédents, nous considérons que la connaissance du passé nous permet de déterminer le futur. Cette hypothèse étant importante, il est nécessaire de considérer les résultats avec précaution. Cela nous permet cependant d'avoir une information qui est pertinente dans la majorité des cas.

Il convient ensuite de déterminer l'erreur moyenne sur les différents horizons d'extrapolations ($J+1, \dots, J+k_{\max}$) à partir de l'historique des erreurs de prévisions. Le modèle « Extrapolation 1 » peut alors être défini à partir de ces erreurs moyennes. La Figure 22 illustre cette détermination.

Une fois les paramètres déterminés, la détermination de l'évolution de l'incertitude prévisionnelle future peut être réalisée. Les paramètres du modèle peuvent être mis à jour en fonction des nouvelles données disponibles au fur et à mesure des périodes.

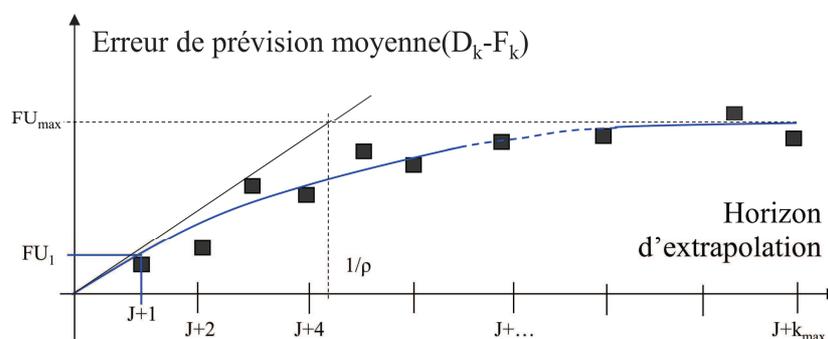


Figure 22: Evolution de l'incertitude prévisionnelle en fonction de l'horizon d'extrapolation

Dans le cas où il n'y aurait pas d'historique disponible, les mêmes méthodes que pour la détermination de l'incertitude prévisionnelle mixte peuvent encore être utilisées, c'est-à-dire soit en prenant des données standard, soit en prenant les paramètres d'un produit similaire. Dans tous les cas, dès qu'un historique suffisant est disponible, l'utilisation de celui-ci permet de caractériser au mieux les paramètres dont on a besoin.

Nous allons maintenant présenter les résultats obtenus sur des données réelles.

III. Validation du modèle obtenu sur un jeu de données réelles

Comme pour la validation de notre modèle d'incertitude prévisionnelle mixte, nous avons appliqué notre modèle d'évolution de l'incertitude prévisionnelle en fonction de l'horizon de prévision sur un échantillon de données de 30 produits de différents types. A partir de l'analyse des erreurs de prévision sur un historique important (3 ans de prévision quotidienne avec un horizon de prévision limité à 48 jours), nous avons pu déterminer les paramètres du modèle évolutif pour les différents produits.

Nous avons ainsi pu définir l'évolution de la moyenne des erreurs de prévisions, ainsi que l'écart type de l'erreur de prévisions à chaque horizon. Nous remarquons que la moyenne comme l'écart type des erreurs suivent la même loi d'évolution qui est celle que nous avons proposée. La Figure 23 représente pour un produit, les évolutions de l'erreur absolue moyenne et de son écart type. Nous remarquons que la moyenne des erreurs n'est pas forcément nulle. La prévision, si biaisée, présente une erreur moyenne différente de zéro qui est soit positive (prévision pessimiste), soit négative comme c'est le cas pour l'exemple de la Figure 23 (prévision optimiste). La Figure 24 représente les mêmes éléments pour une erreur relative.

Le Tableau 19 permet de récapituler ces résultats pour l'échantillon de données sur lequel nous avons travaillé. Nous y retrouvons pour chacun des produits de l'échantillon étudié, pour l'erreur moyenne en valeur absolue « e_ » et en valeur relative « eprct », les paramètres du modèle d'évolution $EFU_{\mu,\rho}(t,k) = \mu \cdot FU_{\max}(t) \cdot (1 - e^{\rho \cdot k})$ pour :

- l'erreur moyenne « e_moy » ou « eprct_moy »

- l'écart type moyen « e_écart » ou « eprct_écart ».

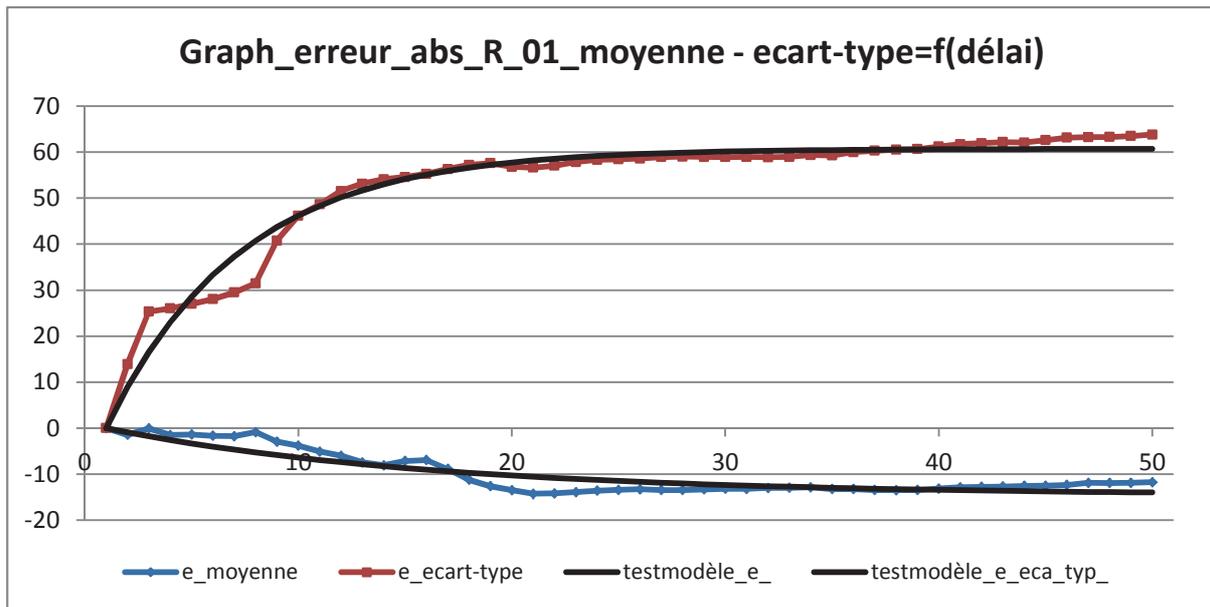


Figure 23: Modélisation de l'évolution de l'erreur absolue moyenne et de l'écart type de l'erreur absolue moyenne en fonction de l'horizon de prévision

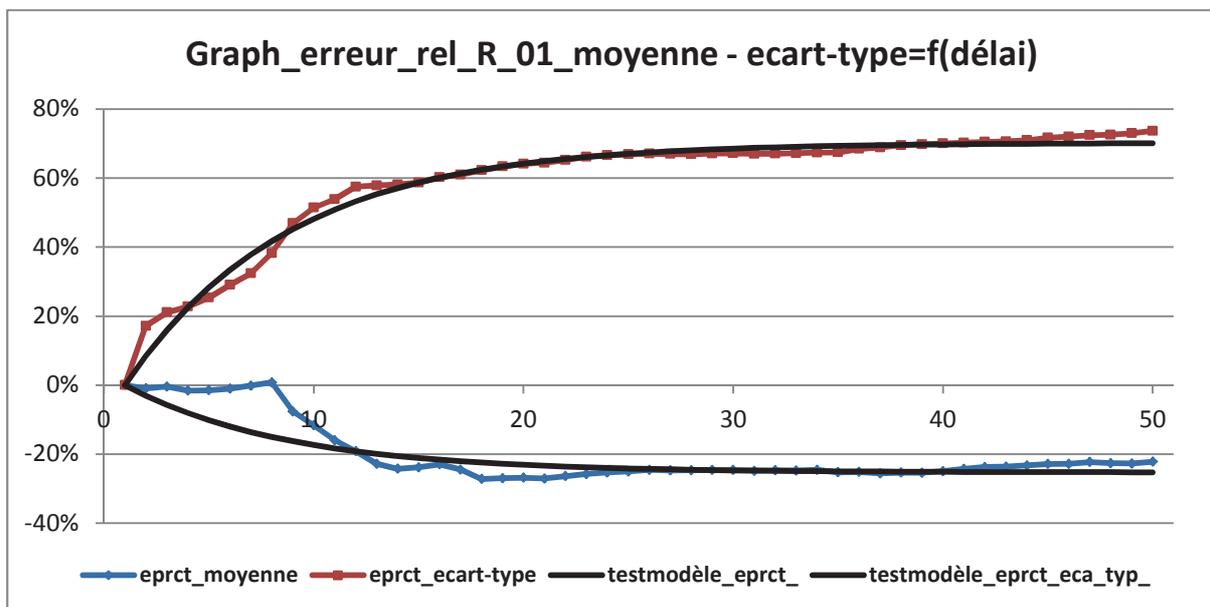


Figure 24: Modélisation de l'évolution de l'erreur relative moyenne et de l'écart type de l'erreur relative moyenne en fonction de l'horizon de prévision

Tableau 19: Synthèse des résultats des paramètres des modèles d'évolutions

Produit	Type d'erreur	Mu	rho	Différence "réel vs modèle"	Incertitude prévisionnelle maximale	Demande moyenne
moyenne	e_ecart	1,02	0,13	3,3	92,3	323
écart-type	e_ecart	0,16	0,03	4,2	126,4	479
moyenne	e_moy	1,17	0,08	2,1	-15,7	323
écart-type	e_moy	0,34	0,03	3,5	26,0	479
moyenne	eprct_ecart	0,96	0,15	2%	73%	323
écart-type	eprct_ecart	0,02	0,02	0%	3%	479
moyenne	eprct_moy	5,41	0,16	3%	-13%	323
écart-type	eprct_moy	22,36	0,16	1%	8%	479

Ainsi, nous pouvons caractériser l'évolution de l'erreur de prévision ainsi que sa dispersion en fonction de l'horizon de prévision. La loi d'évolution de l'erreur de prévision est assez semblable pour l'ensemble des produits étudiés. De la même façon, la dispersion de l'erreur est également assez similaire pour tous les produits. Cela se démontre par les faibles valeurs d'écart type sur les moyennes des paramètres « Mu » et « rho », que ce soit pour les moyennes ou les écarts-types des erreurs absolues ou relatives. Ces résultats nous montrent la parfaite adéquation entre le modèle et le système réel, avec une erreur moyenne inférieure à 3%.

Nous avons aussi appliqué les résultats obtenus dans cette section dans les cas des pièces de rechange automobile. Cette prévision se fait mensuellement sur un horizon de trois mois. Nous avons donc réalisé la modélisation de l'incertitude prévisionnelle en fonction de l'horizon de prévision. Nous avons ici aussi obtenu des résultats proches de ceux observés précédemment. La Figure 25 présente une partie seulement de ces résultats dans un souci de lisibilité. L'erreur étudiée

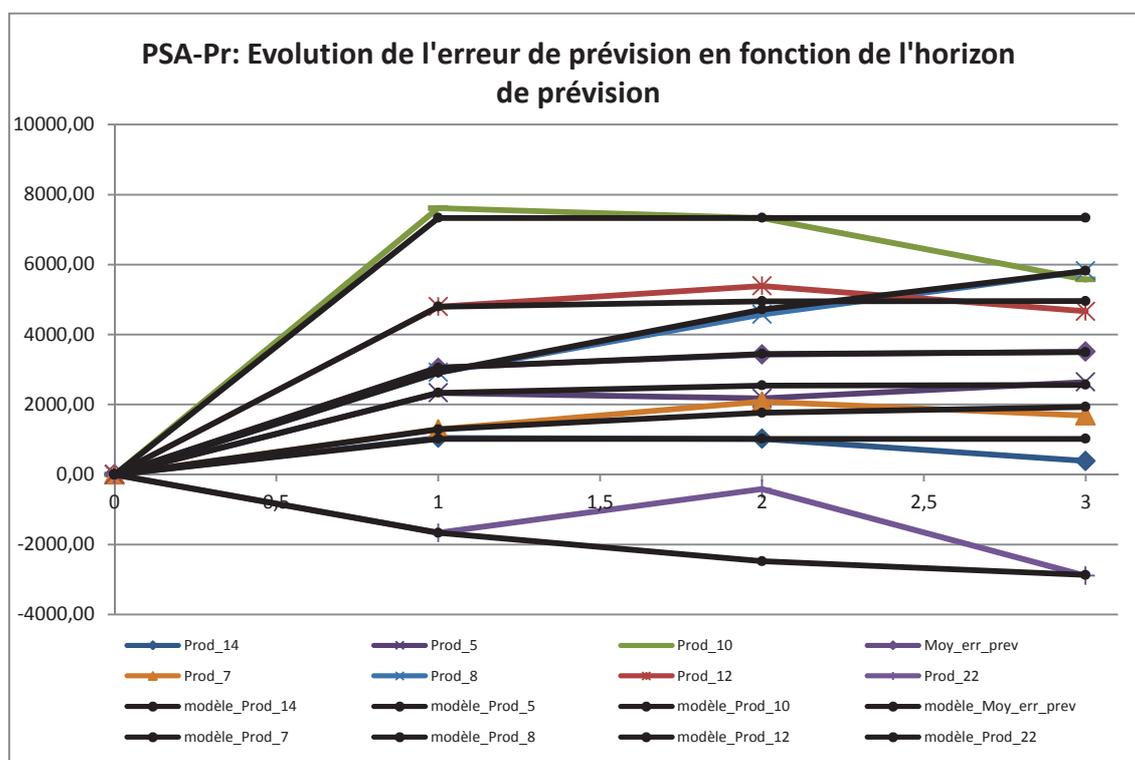


Figure 25: Evolution de l'erreur de prévision en fonction de l'horizon de prévision (cas des pièces de rechanges)

est ici l'erreur absolue de prévision. Le Tableau 20 présente la moyenne des résultats pour les 42 produits de l'échantillon. Là encore, nous pouvons voir que le modèle correspond très bien à la réalité avec une erreur relative moyenne de 5%.

Tableau 20: Synthèse des résultats des paramètres des modèles d'évolutions (cas des pièces de rechanges)

	mu	rho	Erreur relative moyenne du modèle par rapport au réel	Incertitude maximale	Demande moyenne
Moyenne	1,23	4,43	5%	3513	10812
Ecart type	0,54	6,72	7%	8480	20222

Une autre façon de voir l'évolution de la répartition des erreurs en fonction de l'horizon de prévision est de représenter la répartition des erreurs relatives de prévision pour différents horizon de prévision.

L'exemple du produit exposé dans la Figure 23 et la Figure 24 est présenté sur la Figure 26. L'axe des ordonnées présente le nombre relatif d'occurrences de l'erreur relative (de -100% de l'erreur maximale à 100% de l'erreur maximale) tandis que l'axe des abscisses présente la plage des erreurs (de -100% à +100% de l'erreur maximale observée sur l'horizon de prévision).

Nous remarquons sur la Figure 26 que plus l'horizon de prévision augmente, plus les erreurs de prévision se répartissent aux extrémités, et ce, de façon symétrique. Nous constatons également que trois groupes de taille similaire se forment : les erreurs négatives, les erreurs positives, et les prévisions exactes. Nous constatons donc que près du tiers des prévisions sont exactes dès l'horizon maximal de prévision.

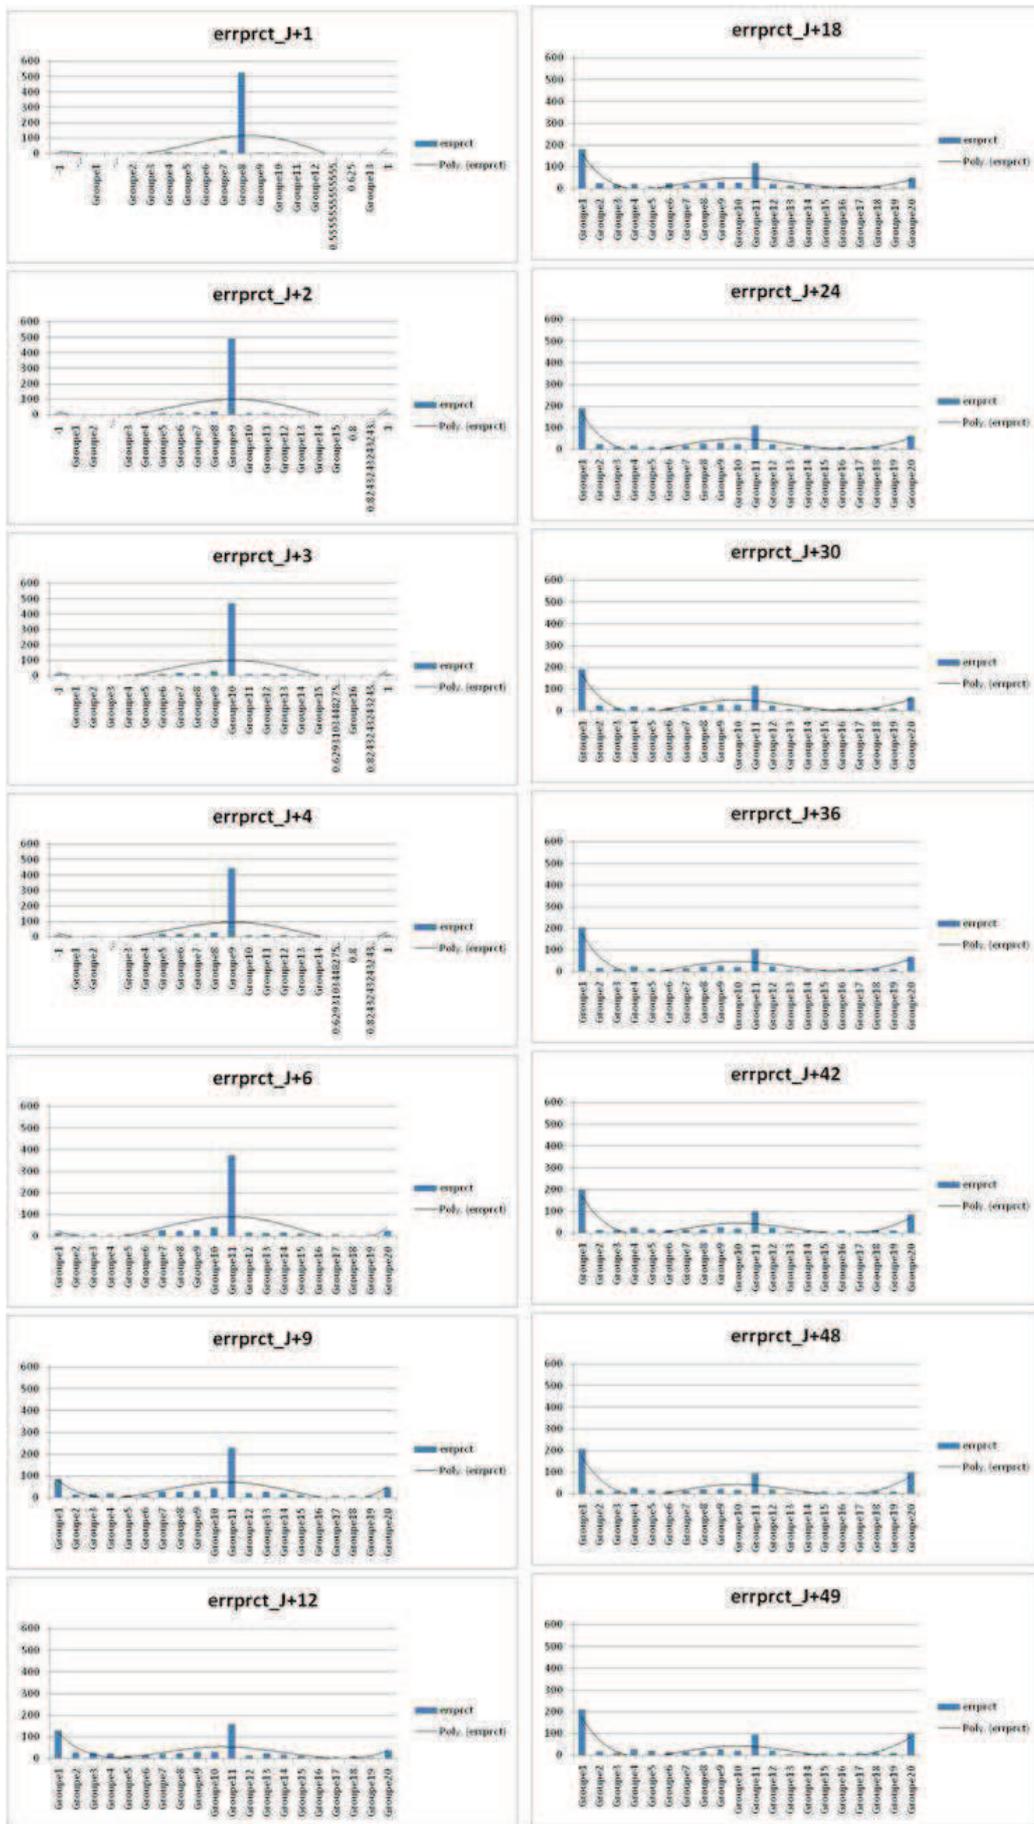


Figure 26: Evolution et répartition relative de l'erreur de prévision en fonction de l'horizon de prévision

IV. Conclusion

La modélisation de l'évolution de l'erreur de prévision en fonction de l'horizon de prévision est un apport important de notre travail. En effet, nous avons proposé ici une méthode permettant de modéliser l'évolution de l'incertitude prévisionnelle, qu'elle soit absolue, relative ou mixte en fonction de l'horizon de prévision. Nous avons également proposé un modèle d'évolution qui correspond parfaitement à l'évolution réelle de l'erreur de prévision et qui peut être adapté à chaque produit spécifiquement en fonction de ses caractéristiques propres. Cette modélisation nous a permis de montrer que l'erreur de prévision apparaît rapidement en fonction de l'horizon de prévision pour devenir constante malgré l'augmentation de l'horizon de prévision.

Cette analyse permet de montrer la corrélation entre les erreurs de prévision à très court terme et les erreurs de prévision à long terme. Ainsi, en corrigeant rapidement les prévisions en fonction des premières erreurs relevées, la prévision à horizon plus lointain peut s'améliorer de façon importante.

Nous pouvons également utiliser notre modèle d'incertitude prévisionnelle pour utiliser une approche modèle et non une approche empirique dans la détermination de l'incertitude prévisionnelle. En effet, nous avons montré l'évolution de l'erreur moyenne ainsi que l'évolution de l'écart type de l'erreur en fonction de l'horizon de la prévision. En considérant que l'erreur de prévision suit une loi normale, nous pouvons alors en déduire ses caractéristiques (moyenne et écart type) et ainsi pouvoir modéliser précisément la répartition des erreurs. Ceci va pouvoir servir à la sécurisation des flux en fonction des prévisions et des horizons de prévision en limitant la sécurisation au juste nécessaire.

Cependant, la modélisation de l'évolution de la prévision reste très liée à la réalisation des prévisions. En effet, selon la mise à jour des prévisions, l'évolution de l'erreur de prévision peut être modifiée. C'est pour cela qu'il est important de se baser sur l'historique du produit considéré. En effet, il y a peu de chances pour que la méthode de rafraîchissement des prévisions évolue. C'est généralement un paramètre fixe du processus de prévision.

Enfin, ici aussi, la présence d'un historique est nécessaire. Nous pouvons donc encore proposer, dans les cas où il n'y aurait pas d'historique, d'utiliser des méthodes similaires à la prévision, en utilisant soit des données standards, soit les paramètres de produits similaires à ceux étudiés.

Ce travail va nous permettre par la suite de pouvoir modéliser plus précisément la loi théorique de l'incertitude prévisionnelle. En effet, elle permettrait d'avoir une sécurisation qui ne se ferait non plus par rapport à l'historique, mais uniquement en fonction d'un modèle statistique prédéfini qui dépendrait du type d'incertitude prévisionnelle, et aussi de l'horizon de prévision. Nous pourrions alors reprendre les travaux de (Babai 2005) en prenant en compte l'évolution de notre incertitude en fonction de la prévision et de son horizon. Cela se retrouverait alors non plus uniquement dans le coefficient de l'écart type de la loi statistique utilisée, mais aussi dans la valeur de la moyenne.

Conclusion

Dans ce deuxième chapitre, nous avons présenté l'existant en ce qui concerne les modèles d'incertitudes prévisionnelles. Nous avons ainsi pu mettre en avant l'absence de modèle permettant de caractériser les incertitudes mixtes (absolue et relative). Nous avons également montré l'absence de modèle concernant l'évolution de la qualité des prévisions en fonction de l'horizon de prévision. Suite à ce constat nous avons alors développé deux modèles permettant de modéliser cette incertitude.

Nous avons, dans la deuxième section, présenté une méthode permettant de caractériser de façon empirique l'incertitude mixte à partir de deux coefficients et ainsi avoir un modèle au plus proche des données industrielles. Le modèle d'incertitude permet donc de passer d'une incertitude soit absolue soit relative à une incertitude mixte ces deux-ci. Cette méthode a ensuite été appliquée sur un cas industriel réel, ce qui a permis de la valider.

Nous avons dans la troisième section de ce chapitre présenté un modèle permettant de caractériser l'évolution de l'erreur de prévision en fonction de l'horizon de prévision. En effet, notre étude de l'existant nous a montré que ce type de modèle n'existait pas. Nous pouvons grâce à ce modèle déterminer l'évolution de l'incertitude sur la demande en fonction de l'horizon de prévision. Nous avons également montré que l'incertitude prévisionnelle se dégradait rapidement dans les premières périodes pour atteindre une évolution de l'incertitude quasi-nulle par la suite. Ce modèle a également été confronté à un cas réel. Nous avons ainsi pu montrer la parfaite adéquation entre le modèle et le réel.

Le but de ces modélisations est d'une part de montrer que nos modélisations sont plus performantes que celles existant dans la littérature, et que les modèles proposés correspondent bien à la réalité. Ceci va nous permettre par la suite de les intégrer dans les modèles de pilotage de flux et en particulier dans le cas du Global Sourcing.

Chapitre 3 : Pilotage de flux et sécurisation des approvisionnements dans le cadre du Global Sourcing

Nous allons dans ce chapitre nous intéresser à la partie pilotage de flux de la Supply Chain. En effet, après avoir étudié la réalisation des prévisions de la demande, nous avons caractérisé l'incertitude résiduelle sur ces prévisions. Nous allons maintenant voir comment sécuriser notre chaîne logistique afin de pouvoir répondre à une demande d'un client prévue ou non au moindre coût. L'utilisation du Global Sourcing via une bonne sécurisation de la Supply Chain peut alors être nécessaire. Les questions qui se posent sont alors : Quelles sont les politiques de pilotage de flux existantes ? Qu'est-ce que le Global Sourcing et pourquoi le Global Sourcing ? Quels modèles pour le Global Sourcing ?

Nous tentons de répondre à ces questions dans ce troisième chapitre. Nous allons alors mettre en application l'utilisation de l'incertitude prévisionnelle dans les politiques de pilotage de flux. Nous présenterons rapidement dans une première section les méthodes de pilotage de flux classiques. Suite à cela, nous présenterons le cadre spécifique dans lequel nous avons placé notre étude, à savoir le Global Sourcing. Nous pourrions alors dans une troisième section présenter nos travaux et comparer les modèles que nous proposons aux politiques de la littérature ou industrielles.

Les politiques classiques de pilotage de flux

Dans cette partie, nous allons faire un rapide état des lieux des politiques classiques de pilotage de flux. En effet, afin de pouvoir présenter clairement les spécificités du pilotage de flux dans le cadre du Global Sourcing, il est important de bien cerner les problématiques plus générales du pilotage de flux.

Ainsi, nous allons commencer par présenter les méthodes classiques de gestion de stock et les modèles correspondants. Pour cela, nous nous appuyons sur les travaux de (Babai 2005). La majorité des figures de cette première partie en ont été tiré. Nous présenterons ensuite la gestion des flux sous incertitudes avec les différentes méthodes associées. En effet, notre périmètre d'étude se restreindra à ce cas précis.

I. La gestion des stocks classique

A. Introduction

La globalisation de l'économie rend, aujourd'hui encore plus qu'hier, la compétitivité des entreprises primordiale pour leur bon fonctionnement. Pour cela, le pilotage de flux et la gestion des stocks à coûts réduits tout en satisfaisant un niveau de service requis pour les clients sont des axes majeurs du fonctionnement des entreprises. Dans ce contexte, différentes politiques de pilotage de flux ont vu le jour depuis plusieurs décennies. Une rapide synthèse portant sur ces politiques se révèle nécessaire afin de bien cerner les particularités de chacune d'entre elles.

Nous allons donc commencer par présenter un état de l'art des principales politiques de pilotage de flux étudiées dans la littérature. Après avoir décrit leur principe de fonctionnement, nous présenterons leurs avantages et leurs inconvénients en nous référant aux travaux de base qui ont été réalisés dans ce domaine. Nous reprendrons pour cela la classification proposé par (Babai 2005) avec comme critère l'information sur la demande.

B. Le pilotage de flux dans les chaînes logistiques

1. Notion de chaîne logistique

Jusqu'au milieu des années 70, la tendance générale dans l'industrie a été de "pousser" la production dans l'objectif d'inonder le marché puisque la demande était supérieure à l'offre. Dans la plupart des entreprises, les responsables d'activités essayaient de diminuer les coûts au niveau de leurs activités, sans se préoccuper des répercussions de ces décisions sur l'ensemble des activités de l'entreprise. A la fin des années 70, la présence de nombreuses entreprises dans un même segment de marché a eu pour effet l'augmentation de l'offre et donc une concurrence plus forte. Il est alors apparu nécessaire de prendre en compte dans les problèmes d'organisation industrielle, non seulement les contraintes de production, mais également les contraintes d'approvisionnement, de distribution, etc. Ceci a pour objectif d'avoir une structure globale cohérente, capable de s'ajuster rapidement à la demande du client final. C'est la naissance de la notion de Supply Chain.

D'un point de vue plus conceptuel, une chaîne logistique peut être considérée comme une succession d'activités d'approvisionnement, de fabrication et de distribution traversées par divers flux. Ces flux peuvent être classés en trois types, à savoir : les flux physiques, les flux d'information et les flux financiers.

- **Les flux physiques** : ces flux concernent toutes les entités physiques qui traversent la chaîne logistique, en particulier les flux de matière première, d'encours et de produits finis. Ces flux traversent la chaîne logistique essentiellement d'amont en aval. D'autres flux physiques annexes peuvent circuler dans la chaîne logistique d'amont en aval et aussi d'aval en amont, tels que les conteneurs, les emballages, les palettes et les produits retournés.
- **Les flux d'information** : il s'agit des échanges d'information entre les acteurs de la chaîne. L'information peut concerner l'état du système, le niveau des stocks et des encours, ou la demande du client. Ces flux peuvent s'effectuer dans les deux sens.
- **Les flux financiers** : il s'agit des flux monétaires associés aux flux physiques. Ces flux traversent la chaîne essentiellement d'aval en amont. Certains flux financiers peuvent aussi avoir lieu de l'amont vers l'aval, tels que les remboursements ou les paiements en cas de litige.

Dans le cadre de cette thèse, nous nous intéressons principalement aux flux physiques et aux flux d'information. L'aspect financier reste hors du périmètre de notre travail. Cependant, nous utiliserons différents types de coûts (coûts de stocks, coûts de commande, etc..) dans les modèles que nous étudions.

2. Pilotage de flux

La notion de pilotage de flux a connu une évolution très importante à travers le temps. Cette évolution a suivi celle de la notion de chaîne logistique. Le pilotage de flux se limitait au début, à l'ensemble des règles de gestion des stocks. Par la suite, il a évolué pour intégrer plusieurs caractéristiques endogènes des systèmes de production, à savoir : les contraintes de coordination des différents flux au sein des systèmes de production, les contraintes de capacité dans les systèmes de production, etc. Actuellement, cette notion s'étend de plus en plus pour englober toute la chaîne logistique depuis l'approvisionnement jusqu'à la distribution. Dès lors, le pilotage de flux consiste aujourd'hui à prendre toutes les décisions visant, à court terme, à coordonner tous les flux, à tous les niveaux de la chaîne logistique, dans l'objectif de garantir un certain niveau de service vis-à-vis du client final tout en minimisant les coûts.

D'un point de vue plus pratique, piloter les flux dans la chaîne logistique consiste à prendre des décisions qui, à chaque étape de la chaîne (depuis les fournisseurs jusqu'au client final) et pour chaque entité (matière première, composant ou produit fini), répondent aux deux questions clés suivantes : quand lancer une activité (activité d'approvisionnement, de fabrication, d'assemblage, de transport ou de déploiement) et en quelle quantité ? Généralement, ces décisions sont concrétisées par des ordres d'approvisionnement, de fabrication, d'assemblage, de transport et de déploiement (Figure 27).

Les décisions en pilotage de flux tiennent compte de plusieurs informations que nous pouvons classer en trois types :

- Les informations sur l'état du système (telles que les machines en panne, etc.).
- Les informations sur les niveaux de stock.

- Les informations sur la demande.

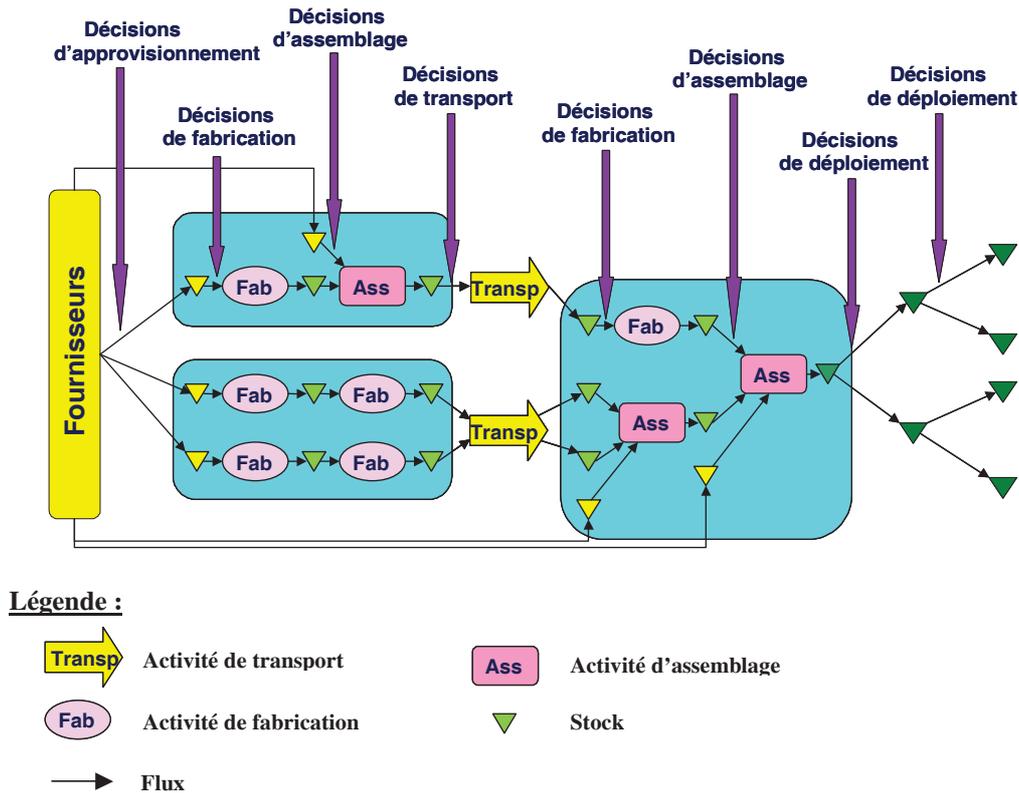


Figure 27: Le pilotage de flux dans la chaîne logistique

Si les deux premiers types sont internes au système et peuvent être obtenus de diverses façons, l'information sur la demande est un paramètre difficile à cerner qui a une grande influence sur le mode de pilotage des chaînes logistiques. Une partie considérable de nos travaux traite de l'information sur la demande, en particulier lorsque l'information se présente sous la forme de prévisions de la demande.

C. Les différentes politiques de pilotage de flux

Nous présentons, dans cette section, les politiques de pilotage de flux décrites dans la littérature, en les classifiant en deux familles. La première famille, appelée "politiques de pilotage par renouvellement de la consommation", regroupe les politiques de pilotage de flux basées sur la consommation du stock. La deuxième famille, appelée "politiques de pilotage par les besoins futurs", regroupe les politiques de pilotage basées sur des commandes fermes ou prévisionnelles. Nous étudierons plus en détail cette classification des politiques de pilotage de flux dans la section 3.

Pour donner un état de l'art des politiques de pilotage de flux, nous nous limitons dans le cadre de ce chapitre, aux travaux qui se sont intéressés au développement de nouvelles politiques de pilotage de flux.

1. Politiques de pilotage par renouvellement de la consommation

Les politiques de pilotage par renouvellement de consommation peuvent être classées en deux sous-familles, à savoir : les politiques de gestion des stocks classiques et les politiques basées sur le système Kanban.

a) Politiques de gestion des stocks classiques

Nous appelons politiques de gestion des stocks classiques, les premières politiques de gestion des stocks développées depuis les années 1930. Ces politiques assurent la gestion d'un ou plusieurs stocks alimentés par des systèmes d'approvisionnement qui peuvent être composés d'un ensemble d'activités de production, d'assemblage et de transport. L'objectif est de satisfaire la demande du client tout en minimisant le niveau de stock. A certains moments, des commandes sont passées pour réapprovisionner les stocks (Figure 28) en fonction de la demande. L'intervalle de temps séparant le moment où une commande est passée et la réception des produits est en général appelé délai d'approvisionnement. Cet intervalle correspond, dans la réalité, aux délais engendrés par le lancement de la commande, la fabrication des produits si ceux-ci ne sont pas en stock, le transport et la mise en stock de ces produits. Lorsque le contrôle de l'état du stock se fait en continu, on parle alors de politiques à suivi continu. Dans le cas où le contrôle est fait avec des périodes de temps fixes, on parle de politiques à suivi périodique.

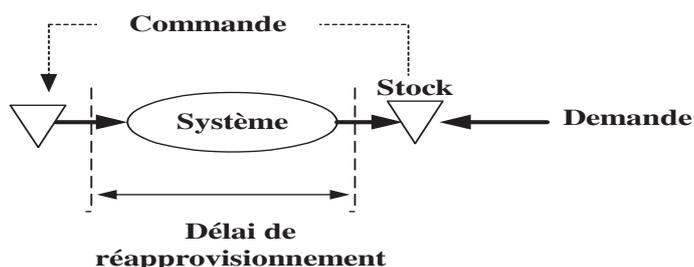


Figure 28: Schéma d'une politique de gestion des stocks classique

Dans les politiques de gestion des stocks classiques, on s'intéresse généralement à deux niveaux de stock : le stock net et la position du stock. Le stock net représente la différence entre le stock physique disponible et les demandes non encore satisfaites. Il représente un paramètre important à considérer pour l'évaluation des coûts de stock. La position du stock intègre, en plus du stock net, les commandes déjà passées et dont la livraison est encore attendue. Elle constitue un paramètre important à considérer pour la prise de décision du type instant de commande ou quantités à commander.

Les politiques de gestion des stocks classiques les plus utilisées sont : la politique "à suivi continu et à point de commande", notée généralement (r,Q) , la politique dite "à recombplètement périodique", notée (T,S) et plusieurs autres variantes de ces politiques telles que la politique (s,S) , la politique (T,r,S) et la politique (T,r,Q) . Ces politiques sont utilisées pour la gestion des stocks dans des systèmes mono-étage ainsi que des systèmes multi-étages. Nous présentons les principales politiques de gestion des stocks classiques dans le cas des systèmes mono-étage.

(1) Politique à point de commande (r,Q)

Cette politique est à suivi continu. Elle consiste à commander une quantité fixe Q chaque fois que la position de stock descend en dessous d'un seuil appelé point de commande, et noté r . La commande est réceptionnée à l'issue du délai d'approvisionnement L . L'évolution du stock suivant cette politique est donnée par la Figure 29.

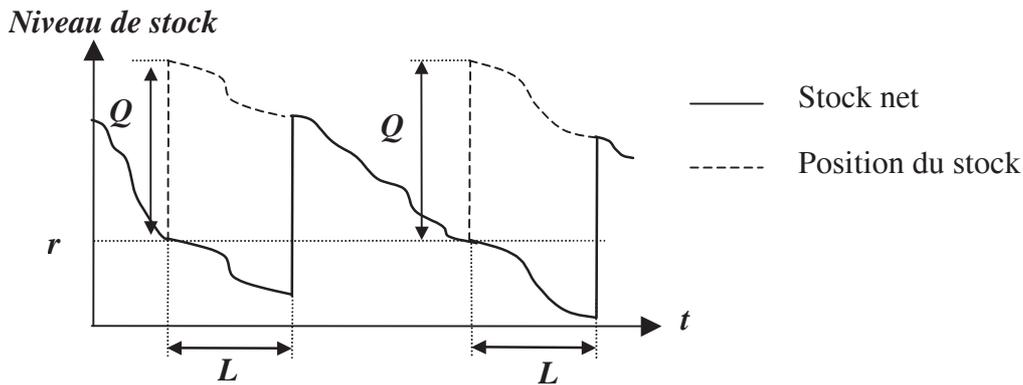


Figure 29: Evolution du stock avec la politique (r,Q)

Notons que dans le cas de cette politique, l'instant de passation de commande est variable : si la demande est plus grande que la moyenne, le point de commande sera atteint plus tôt; si la demande se ralentit, le point de commande sera atteint plus tard. Le stock correspondant au point de commande a pour but de couvrir la demande jusqu'à la réception de la commande.

Du fait que cette politique soit à suivi continu, la connaissance du stock disponible à tout instant est nécessaire pour être alerté dès qu'un produit atteint son point de commande. Ceci peut entraîner en pratique des coûts de gestion élevés (par exemple la mise en place d'un système de suivi informatisé). De plus, dans le cas où plusieurs produits proviennent d'un même fournisseur, on ne peut pas effectuer un regroupement des commandes parce que tous les produits n'atteignent pas forcément leurs points de commande au même moment.

(2) Politique à reapprovisionnement périodique (T,S)

Cette politique est à suivi périodique. Au début de chaque période de longueur T , si la position du stock descend en dessous d'une valeur donnée, appelée niveau de reapprovisionnement et notée S , un ordre de réapprovisionnement est lancé de manière à ramener la position du stock à S . La commande est réceptionnée à l'issue du délai d'approvisionnement L . L'évolution du stock suivant cette politique est donnée par la Figure 30.

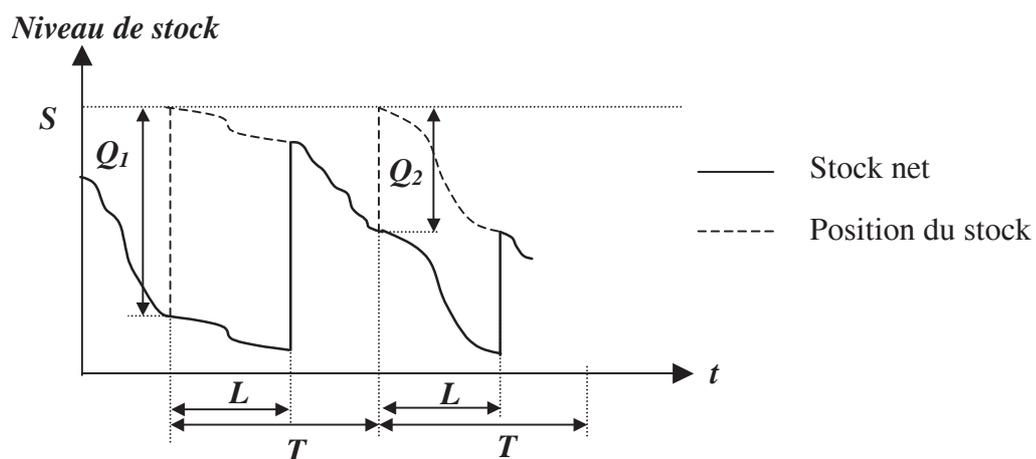


Figure 30: Evolution du stock avec la politique (T,S)

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

Il faut rappeler que la politique (T,S) présente aussi certains inconvénients. En effet, d'abord cette politique est "aveugle" à l'intérieur d'une période de révision, donc, une variation instantanée de la demande laisse le système insensible (à la différence de la politique (r,Q) qui est plus réactive du fait de son suivi continu). De plus, dans certains cas, le rechargement se fait en petites quantités, c'est à dire qu'à chaque période, si le niveau de stock baisse même très peu en dessous de S , une commande doit être lancée pour atteindre S même si la quantité en question est très petite.

(Wilson 1934) est l'un des premiers à avoir étudié les politiques (r,Q) et (T,S) en présence d'une demande déterministe. Par la suite, au début des années 50, ces politiques ont été développées pour le cas d'une demande stochastique par (Scarf 1959), (Karlin 1960), (Iglehart 1964) et (Hadley & Whitin 1963).

(3) Politique (s,S)

Dans cette politique à suivi continu, dès que la position du stock descend en dessous du seuil de commande s , on reconstitue la position du stock jusqu'à un niveau de rechargement S . Contrairement à la politique (r,Q) où la quantité commandée est fixe, avec cette politique, la commande est de taille variable. L'évolution du stock suivant cette politique est donnée par la Figure 31.

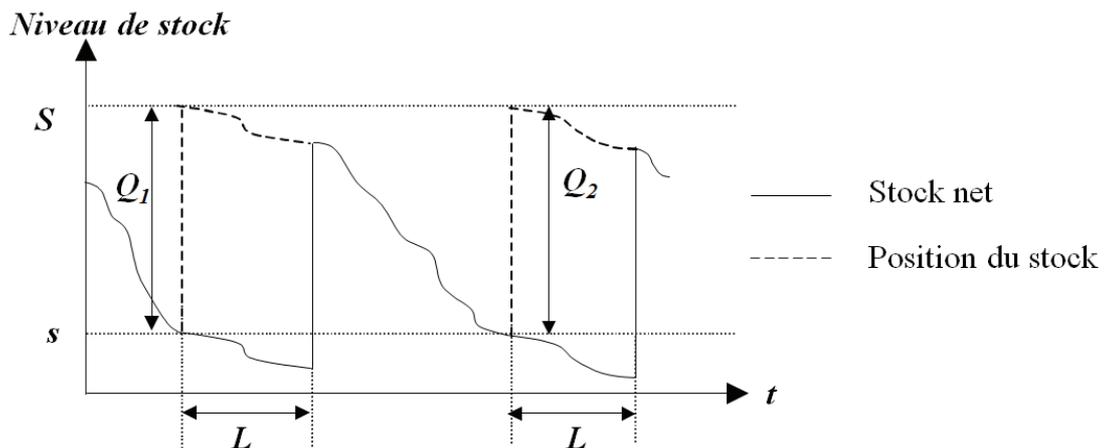


Figure 31: Evolution du stock avec la politique (s,S)

Il faut remarquer que si toutes les demandes sont unitaires, les commandes sont lancées exactement quand la position du stock atteint le niveau s , la quantité commandée est alors fixe et elle est égale à $S-s$, nous retrouvons alors la politique (r,Q) décrite précédemment (avec $r = s$ et $Q = S-s$). Le cas particulier de la politique (s,S) où les demandes sont unitaires et le seuil de commande est tel que $s = S-1$, est appelé politique à *stock nominal* (appelée aussi dans la littérature anglo-saxonne politique *Base stock*). Cependant, si les demandes ne sont pas unitaires, la quantité commandée pour reconstituer le niveau de stocks à S est variable et elle est supérieure ou égale à $Q = S-s$.

L'inconvénient de cette politique est la complexité de la procédure de détermination des paramètres optimaux s et S .

(Clark & Scarf 1960) et (Karlin 1960) font partie des premiers à avoir étudié la politique (s,S) . Par ailleurs, (Gross & Harris 1973) et (Buzacott & Shanthikumar 1993) se sont intéressés également à la politique (s,S) . Ils ont étudié des politiques du type (s,S) à travers une analyse basée sur la théorie des files d'attente.

(4) Politique (T,r,S)

Dans cette politique à suivi périodique, les deux politiques (r,Q) et (T,S) sont combinées. En effet, à la fin de chaque période de suivi T , on examine la position du stock. On ne passe une commande que si cette position est inférieure à un seuil de commande noté r . La quantité commandée a pour but de ramener la position du stock à un niveau de reapprovisionnement S . L'évolution du stock suivant

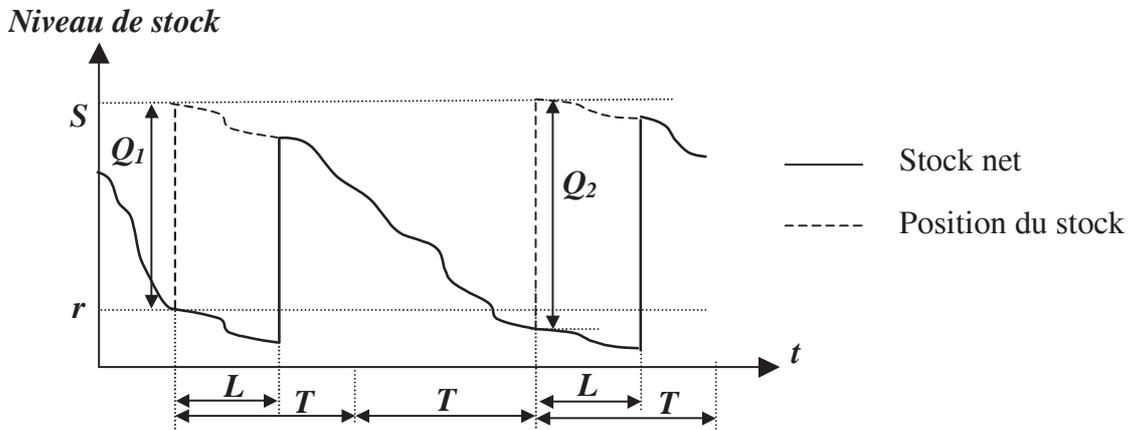


Figure 32: Evolution du stock dans la politique (T,r,S)

cette politique est donnée par la Figure 32.

Par rapport à la politique (T,S) , l'avantage de cette stratégie est qu'elle permet d'éviter de passer des commandes de trop petite taille si la demande pendant la période a été très faible.

Il est à noter que la politique (s,S) est un cas particulier de la politique (T,r,S) qui correspond au cas où la période de suivi T tend vers zéro. Donc, la politique (T,r,S) peut être considérée comme une version périodique de la politique (s,S) . Pour le cas où $r = S - 1$, nous retrouvons également la politique (T,S) .

(5) Politique (T,r,Q)

Dans cette politique à suivi périodique, on combine les deux politiques (r,Q) et (T,S) . En effet, on revoit périodiquement l'état du stock et à chaque période T , si la position du stock est supérieure à un seuil de commande r , aucune commande n'est lancée, mais si la position du stock descend en dessous du seuil r , on commande une quantité fixe Q (Figure 33).

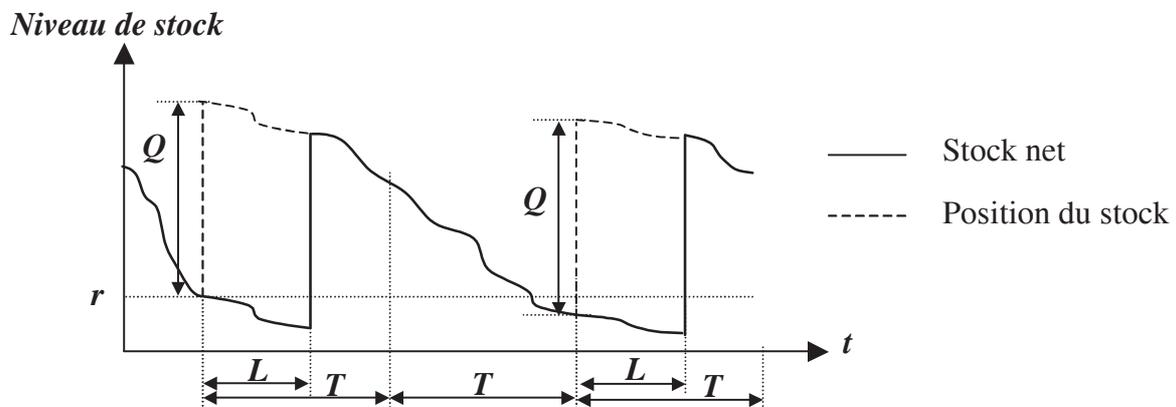


Figure 33: Evolution du stock dans la politique (T,r,Q)

Cette politique est presque similaire à la politique (T,r,S) , sauf que l'approvisionnement dans ce cas se fait par des quantités fixes. De plus, cette politique permet aussi d'éviter de passer des commandes de trop petite taille si la demande pendant la période a été très faible comme c'est le cas dans la politique (T,S) .

Nous voyons bien que la politique (r,Q) représente un cas particulier de la politique (T,r,Q) lorsque la période de suivi T tend vers zéro.

De bons recueils bibliographiques sur les politiques de gestion des stocks classiques sont donnés par (Hadley & Whitin 1963), (Silver & Peterson 1985), (Zipkin 2000) et (Axsäter 2006).

b) Politiques de type Kanban

Le mot "Kanban" signifie "carte" en japonais et fait référence au mécanisme qui consiste à attacher une carte à une pièce (ou plus généralement à un lot de pièces), autorisant son lancement dans une étape de fabrication.

Les premiers travaux parlant du système Kanban sont ceux présentés par (Sugimori *et al.* 1977) et (Kimura & Terada 1981) à la fin des 70 décrivant les systèmes de production Toyota et faisant le point sur le nouveau système Kanban mis en place. Dans ce qui suit, nous allons décrire le principe de fonctionnement de la politique Kanban.

La Figure 34 (Babai 2005) illustre le principe de fonctionnement de la politique Kanban pour un système à deux étages.

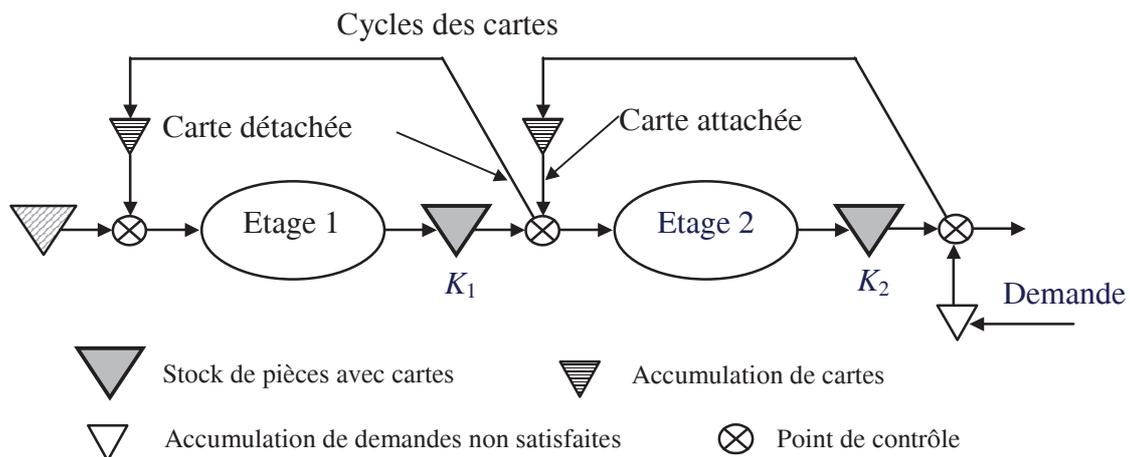


Figure 34: La politique Kanban dans un système à deux étages

Les paramètres de cette politique de gestion sont les nombres de cartes, K_k pour chaque étage k sachant que dans cette politique, un nombre de cartes est associé à chaque étage. Lorsqu'une demande se présente au dernier étage (étage 2), si une pièce avec une carte est présente dans le stock, la demande est satisfaite et la carte est détachée pour être transmise en amont. Cette carte propage la demande au point de contrôle précédent. A ce niveau, si une pièce est présente, sa carte est détachée (carte qui lui vient du premier système dans notre exemple) elle est remplacée par la carte qui a transmis la demande et la pièce est lancée en fabrication dans le dernier étage. La carte détachée est alors transmise en amont, propageant à son tour la demande. Ce mécanisme peut remonter ainsi toute la chaîne. Cependant, s'il arrive qu'une pièce ne soit pas disponible à un étage, aucune carte n'est transmise. Les cartes de l'étage en question s'accumulent et l'information qui déclenche la production est bloquée à ce niveau de la chaîne.

La politique Kanban permet une meilleure coordination entre les étages, n'autorisant la fabrication à chaque étage que si une pièce a été effectivement consommée en aval de cet étage. Une conséquence intéressante de ce mécanisme est que le nombre de pièces en cours de fabrication

est limité par le nombre de cartes de chaque étage. Cependant, la demande pouvant ne pas être immédiatement transmise à toute la chaîne, les délais de fabrication peuvent être plus longs que pour la politique à stock nominal. Lorsque l'étage représente toute la chaîne de production, le pilotage revient à lancer en production une pièce dans l'usine, dès qu'un produit quitte le système en aval. Ce cas particulier de la politique Kanban est aussi connu sous le nom de CONWIP (CONstant Work In Process).

Beaucoup de travaux traitant de la politique Kanban ont été développés depuis son apparition. Une revue détaillée de la littérature sur la politique Kanban est donnée par (Berkley 1992). D'autres travaux tels que (Buzacott & Shanthikumar 1993), (Frein *et al.* 1995) et (Dallery & Liberopolous 2000) se sont basés sur la théorie des files d'attente pour évaluer les performances de la politique Kanban dans des systèmes mono-étage et multi-étages. Outre ces politiques, ils ont proposé des extensions de politiques basées sur le système Kanban, telles que la politique Kanban Généralisé (Buzacott 1989) et la politique Kanban Etendu (Dallery & Liberopolous 2000).

2. Politiques de pilotage par les besoins futurs

Dans cette section, nous nous intéressons aux politiques de pilotage de flux exploitant la demande future. Dans la littérature, les travaux se divisent en deux types : ceux qui s'intéressent à la politique Material Requirement Planning (MRP) et ceux qui étudient les politiques de gestion des stocks sur prévisions.

a) *La politique Material Requirements Planning (MRP)*

La politique MRP est développée depuis les années 70. Elle se base sur trois points essentiels, à savoir : le *Plan Directeur de Production* (PDP) qui spécifie les quantités à produire dans chaque période et pour chaque produit, la *nomenclature* qui spécifie les différents composants intervenant aux différentes étapes de la fabrication des produits, et enfin les *délais de production*, supposés constants, à chaque étape du processus. Le principe de fonctionnement de la politique MRP peut être résumé par les deux notions suivantes :

- Eclatement des besoins : Les besoins en produits finis, donnés par le plan directeur de production, sont transformés en besoins de produits semi-finis et de composants en utilisant la nomenclature.
- Décalage des besoins : Les besoins calculés sont transmis à tous les niveaux de la chaîne avec un décalage dans le temps suivant le principe de lancement "au plus tard" en tenant compte des délais de production. Ces décalages sont faits de façon à avoir les composants dans chaque étage et les produits finis juste à temps.

La mise en œuvre de la politique MRP peut être faite en utilisant des tableaux permettant d'une façon simple de déterminer les décisions de lancement prévisionnelles pour chaque produit et à chaque période de l'horizon.

La politique MRP consiste à déterminer, pour chaque produit et à chaque période de l'horizon, les différents éléments du tableau MRP en appliquant les deux principes énoncés précédemment et ce, dans l'objectif d'avoir les produits finis disponibles juste à temps. Ainsi, en présence de délais de production constants et en l'absence d'aléas, nous remarquons que la politique MRP peut être considérée comme un cas particulier d'une politique JAT. Par ailleurs, en présence d'aléas dans le système, la politique MRP nécessite la mise en place de paramètres de sécurité.

La littérature sur la politique MRP est très riche. La première référence décrivant les fondements de la politique MRP est (Orlicky 1974) dans laquelle les avantages de cette politique de pilotage de flux sont évoqués. On peut également citer le livre de (Vollmann *et al.* 2005) qui représente un

recueil des premiers travaux étudiant la politique MRP. Cette dernière référence comporte des discussions intéressantes qui mettent en valeur les différents problèmes liés à la politique MRP, tels que les paramètres de sécurité, la capacité de production, etc. Les auteurs évoquent également les interactions entre la politique MRP et les politiques de type JAT. Il faut dire que, exceptés les quelques premiers travaux étudiant et analysant les performances de la politique MRP, la majorité des travaux de recherche se sont intéressés, essentiellement, soit au problème de calcul de la taille de lots dans la politique MRP (problème connu dans la littérature sous le nom de *lot-sizing problem*), soit aux paramètres de sécurité qui permettent de remédier à l'incertitude dans la politique MRP.

(Buzacott 1989) et (Buzacott & Shanthikumar 1989) sont parmi les premiers à avoir utilisé des modèles stochastiques pour analyser les performances de cette politique. Ils ont étudié des systèmes mono-étage pilotés par une politique MRP à temps continu (Continuous time MRP), c'est à dire où les prévisions de la demande et l'état du système sont connus de façon continue. Il a également étudié des systèmes mono-étage pilotés par une politique MRP à temps discret (Discret time MRP system), c'est à dire une politique MRP dans laquelle les prévisions de la demande, les inventaires et les ordres de fabrication des produits sont effectués à des instants périodiques. (Buzacott & Shanthikumar 1994) ont également étudié l'impact du choix entre l'utilisation des stocks de sécurité et l'exploitation de délais de sécurité sur les performances des systèmes, notamment dans le cas où les prévisions ne sont pas fiables, ou en présence de délais de fabrication incertains.

b) Politiques de gestion des stocks sur prévisions

Durant la dernière décennie, le pilotage de flux basé sur des prévisions de la demande a occupé une place importante dans la littérature. Nous avons constaté que les politiques proposées sont généralement des extensions des politiques de gestion des stocks classiques. Une partie considérable de ces travaux utilise, en général, une approche de pilotage basée sur des modèles de mise à jour des prévisions, appelés dans la littérature *Forecast Updates models*. Les politiques proposées sont généralement des politiques à suivi périodique du type stock nominal.

La première politique de gestion des stocks sur prévision a été proposée par (Lee *et al.* 1997). Elle est appelée *politique avec niveau de reemplètement* (connue aussi dans la littérature anglo-saxonne sous le nom de *Order-Up-To-Level policy*). Dans cette politique, à chaque période, une quantité qui correspond à la différence entre le niveau de reemplètement et la position du stock est commandée. La quantité commandée est livrée après le délai d'approvisionnement. Puisque les prévisions sont variables dans le temps, le niveau de reemplètement est dynamique.

La deuxième politique étudiée dans la littérature est appelée *politique à stock nominal adaptatif*. Cette politique, connue dans la littérature sous le nom *Adaptive Base Stock policy*, a été introduite par (Graves 1999). La politique à stock nominal adaptatif est une extension de la politique à stock nominal classique. Dans la politique à stock nominal adaptatif, à chaque période, après avoir observé la demande, la quantité commandée est constituée de deux parties. La première partie permet de réapprovisionner la quantité qui correspond à la dernière demande et qui vient d'être consommée (comme dans le cas d'une politique à stock nominal classique), alors que la deuxième partie sert à ajuster le niveau du stock nominal pour s'adapter au changement de la demande prévisionnelle durant le délai d'approvisionnement.

Notons que les modèles de mise à jour des prévisions utilisés dans ces deux politiques ainsi que dans la majorité des politiques de gestion des stocks sur prévisions se basent sur un modèle connu sous le nom de *Martingale Method of Forecast Evolution (MMFE)* développé par (Graves 1986) et par (Heath & Jackson 1994).

Se basant sur les travaux de (Lee *et al.* 1997) et de (Graves 1999), plusieurs travaux ont développé d'autres politiques de gestion des stocks sur prévisions. Pour plus de détails sur ces

travaux, voir (Chen *et al.* 2000), (Lee, So, *et al.* 2000), (Raghunathan 2001), (Toktay & Wein 2001) et (Guellue 1996). La particularité de ces derniers travaux vient de leur utilisation du formalisme de files d'attente pour modéliser le système.

Notons aussi que le problème de pilotage par les prévisions dans des systèmes multi-étages et multi-acteurs a été toujours mêlé avec le problème connu sous le nom de *l'effet de coup de fouet* (connu dans la littérature sous le nom de *Bullwhip effect*). Ce problème est caractérisé par un phénomène d'amplification de la variabilité de la demande lorsque l'on se déplace vers l'amont de la chaîne logistique. Dans ce même cadre, (Chen *et al.* 2000) et (Lee, So, *et al.* 2000) ont quantifié *l'effet de coup de fouet* dans un système de production multi-étages lorsque le pilotage se fait en présence de prévisions. Par ailleurs, (Aviv 2002) a étudié le concept de processus de prévision collaboratif dans un système d'approvisionnement multi-acteurs et a montré la valeur du partage des prévisions entre les acteurs pour l'amélioration du pilotage du système.

D. Classification des politiques suivant le type de l'information sur la demande

Nous allons maintenant présenter une classification des politiques basée sur le critère de l'information sur la demande. Cette classification a été proposée par (Babai 2005). Dans ce qui suit, nous commençons par présenter quelques notions relatives à l'information sur la demande et nous exposons, par la suite, la classification des politiques de pilotage de flux. En se basant sur cette classification, nous présentons rapidement quelques éléments d'aide au choix des politiques de pilotage.

1. Information sur la demande

Les entreprises sont dans l'obligation d'anticiper les besoins de leurs clients et d'avoir la bonne information au bon moment pour mieux gérer leurs systèmes. Par ailleurs, l'information sur les besoins du client peut être disponible sur des horizons différents et variables dans le temps. Cette information demeure incertaine pour l'entreprise. Cette information est moins fiable quand on s'éloigne dans le temps et la demande est ainsi de plus en plus incertaine. Dès lors, nous pouvons classer l'information sur la demande en trois types, comme le montre la Figure 35. Nous distinguons alors :

- **Les commandes fermes** : Elles représentent une information fiable sur la demande, tant sur les quantités que sur les dates de besoin. Les commandes fermes sont définitives et ne comportent pas d'incertitude, c'est à dire qu'elles représentent un engagement de la part des clients.
- **Les prévisions** : Elles représentent une information incertaine sur la demande. Elles peuvent être de deux types :
 - Les commandes prévisionnelles : Ce sont les commandes émanant des clients finaux mais, contrairement aux commandes fermes, elles contiennent une incertitude sur la quantité et/ou sur la date du besoin.
 - Les prévisions de la demande : Ce sont des données provenant d'études prospectives marketing ou obtenues à l'aide d'autres méthodes qualitatives ou quantitatives de prévision basées sur des historiques de la demande.
- **Absence d'information avancée sur la demande** : C'est le cas où il n'y a pas d'information disponible sur la demande future.

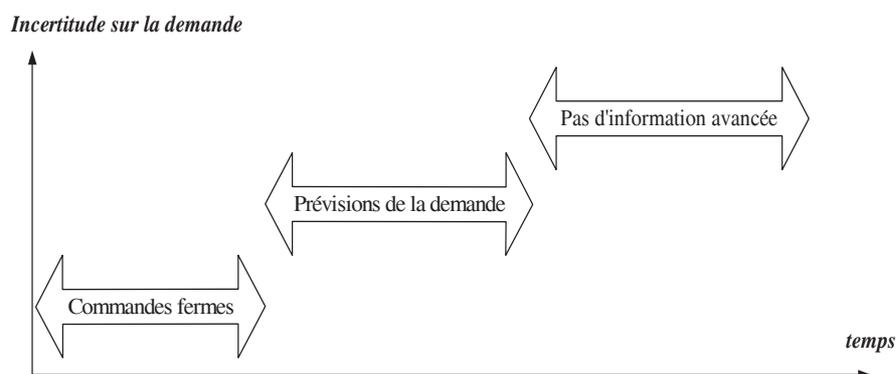


Figure 35: Visibilité sur la demande et incertitude

Les deux premiers types de l'information sur la demande, à savoir : les commandes fermes et les prévisions, représentent ce que nous appelons une information avancée sur la demande.

Le pilotage de flux doit constamment réagir et s'adapter au mieux à la demande du client, quel que soit le type d'information disponible, pour atteindre et maintenir un niveau de service objectif. Ce paramètre est d'une grande importance pour le contrôle du système et, suivant son degré de fiabilité, les approches de pilotage seront différentes.

Dans la suite, nous donnons les approches de pilotage de flux et les modes de gestion qui s'adaptent le mieux avec chaque type d'information sur la demande.

2. Pilotage de flux et information sur la demande

Tenant compte des différents types d'information sur la demande, nous classons les politiques de pilotage de flux en deux approches. Le choix de la première approche, que nous avons appelée "pilotage par les besoins futurs", doit se faire, généralement, dans le cas où on dispose d'information avancée sur la demande. En revanche, si on ne dispose d'aucune information à l'avance sur la demande, on optera pour la deuxième approche que nous avons appelée "pilotage par renouvellement de la consommation".

Notons que lorsque nous parlons de pilotage de flux en absence d'information avancée sur la demande, nous voulons dire absence d'information pour le pilotage du système et non pas pour le paramétrage du système (tel que le choix du nombre de Kanbans). En effet, il est évident que pour le paramétrage du système, il faut disposer d'un minimum d'information sur la demande. Cette information peut être obtenue par des estimations statistiques à partir de l'historique des demandes.

L'approche de pilotage par renouvellement de la consommation se base, essentiellement, sur la consommation des stocks et peut être considérée comme une approche de pilotage en temps réel. Dans cette approche, le choix d'une politique doit se faire parmi les politiques de gestion des stocks classiques ou parmi les politiques de pilotage basées sur le système Kanban. Une fois l'approche de pilotage par renouvellement de la consommation choisie, plusieurs autres critères peuvent être pris en compte pour le choix d'une politique particulière dans cette approche. Ces critères sont liés aux paramètres des politiques et influencent le choix de la politique de pilotage, à savoir : le type de suivi (suivi continu ou suivi périodique), le type de groupage (commandes groupées ou Lot par Lot), le type de système d'approvisionnement (système avec capacité limitée ou système avec capacité illimitée), etc.

L'approche de pilotage par les besoins futurs doit, quant à elle, être utilisée lorsqu'on dispose d'une information avancée sur la demande donnée sous la forme de commandes fermes ou de prévisions de la demande. Plus précisément, si on dispose de commandes fermes exprimées par le client, la politique MRP est bien adaptée. Par ailleurs, si l'information sur la demande est donnée sous la forme de prévisions qui ne sont pas très fiables, alors le choix doit se faire parmi les politiques

de gestion des stocks sur prévisions. Il est évident que si les prévisions sont très fiables, la politique MRP est également bien adaptée à cette situation. (Babai 2005) a montré que dans le cas où les prévisions ne sont pas fiables, il est préférable d'utiliser une politique de pilotage par renouvellement de la consommation.

Par ailleurs, avec la distinction des différents types d'information sur la demande, nous pourrions présenter une deuxième classification des politiques de pilotage suivant le mode de réponse à la demande. Cette classification distingue entre les politiques de *production à la commande* et les politiques de *production par anticipation*. En effet, dans le cas où l'on n'a pas une bonne visibilité sur la demande future (aucune information ou demande prévisionnelle), on constitue généralement des stocks d'anticipation et les lancements en production ont pour but de renouveler ce stock. Le client qui arrive est servi immédiatement à partir du stock, s'il est possible de satisfaire sa commande. Dans ce cas, on parle de politique de production par anticipation. En revanche, si la demande est connue sur un horizon donné (commandes fermes) et que la visibilité est suffisamment importante, il n'est pas nécessaire de constituer des stocks à l'avance, la production ne se déclenche qu'en réponse à une commande du client. Dans ce cas, on parle de politique de production à la commande.

Nous résumons notre classification des différentes politiques et approches de pilotage de flux en fonction du type de l'information sur la demande, dans la Figure 36.

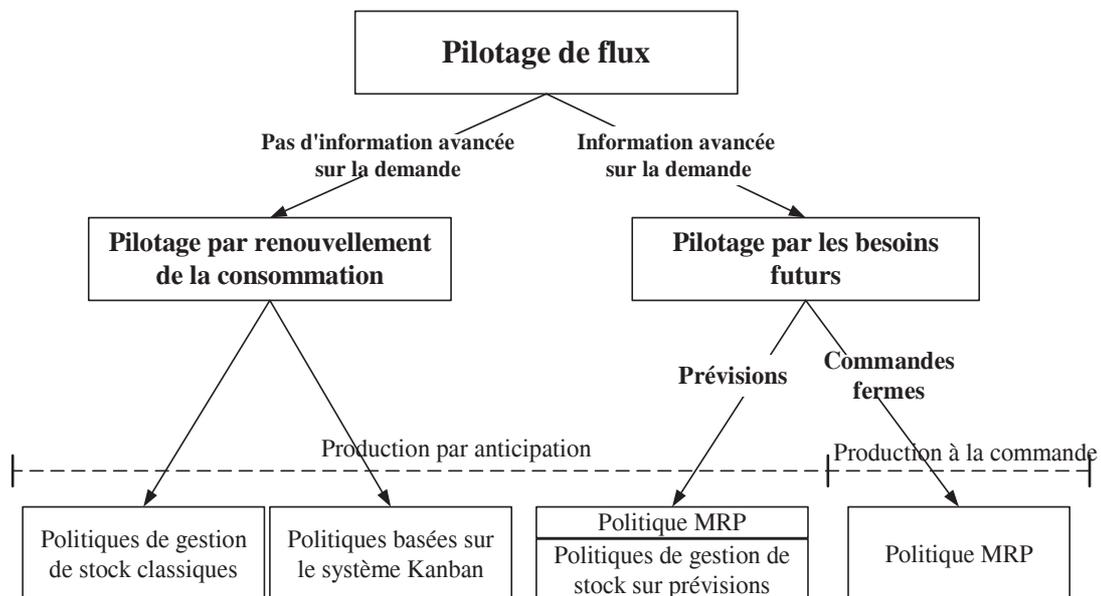


Figure 36: Classification des politiques de pilotage de flux en fonction du type de l'information sur la demande

En pratique, dans une chaîne logistique, la fiabilité de l'information sur la demande diminue en allant de l'aval vers l'amont, d'où la nécessité de combiner plusieurs politiques de pilotage de flux en fonction de l'information disponible sur la demande. La Figure 37 montre un modèle hybride qui combine les différentes approches de pilotage de flux dans une chaîne logistique.

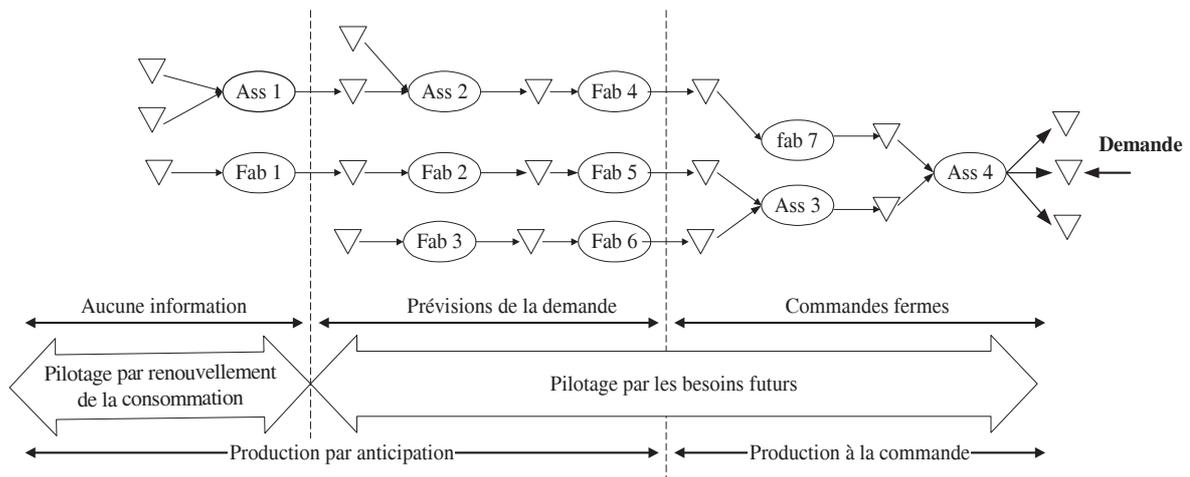


Figure 37: Information sur la demande et méthodes de pilotage

Généralement, en aval de la chaîne, les produits présentent une forte diversité et on trouve plusieurs références pour un seul produit de base. Ces produits doivent être pilotés par une politique de production à la commande. Plus précisément, si l'information dont on dispose, concernant la demande, est suffisamment fiable (des commandes fermes), alors une politique de pilotage par les besoins futurs, telle que la politique MRP, est très bien adaptée à cette situation.

Concernant les composants des produits et les matières premières qu'on trouve, généralement, en amont de la chaîne logistique, ils sont pilotés avec une politique de production par anticipation. De plus, si aucune information sur la demande n'est disponible, alors une politique de pilotage par renouvellement de la consommation doit être appliquée. Ceci s'explique, tout simplement, par le fait que les composants et les matières premières nécessitent, généralement, un simple réapprovisionnement basé sur la consommation du stock.

Dans un niveau intermédiaire de la chaîne logistique, on trouve, généralement, des produits standards et des produits semi-finis. Pour ces produits, l'information sur la demande, peut être donnée sous la forme de prévisions, ce qui nécessite une politique de pilotage par les besoins futurs.

E. Conclusions

Après avoir donné quelques concepts généraux relatifs au pilotage de flux dans une chaîne logistique, nous avons présenté un panorama des politiques de pilotage de flux étudiées dans la littérature en expliquant le principe de fonctionnement de chacune d'elles. En outre, tout au long de cette section, nous avons donné un aperçu sur les travaux de référence qui ont étudié ces politiques. Cette présentation permet donc de visualiser les différentes études portant sur les politiques de pilotage de flux en les classifiant selon le critère de l'information sur la demande.

Dans la suite, nous allons nous intéresser plus précisément à l'étude des politiques de pilotage de flux sous incertitudes.

II. La gestion de flux sous incertitudes

La logique MRP montre ses limites face aux incertitudes. En effet cette méthode donne des résultats exacts dans un environnement déterministe, mais dans l'environnement réel, les aléas perturbe le fonctionnement de la méthode MRP qui n'est pas adaptée à cela. Par conséquent plusieurs travaux se sont basés sur l'adaptation de la MRP aux environnements stochastiques. D'après (Dolgui & Prodhon 2007), pour appliquer la MRP en présence d'incertitudes il faut modifier certains paramètres de la MRP. Les paramètres qui peuvent agir sur les incertitudes sont :

- Le stock de sécurité
- Le délai de livraison de sécurité ou planifié
- Les règles de la taille des lots (lot-sizing)
- Gel du PDP (Freezing master production schedule)

Dans la littérature il existe plusieurs travaux qui s'intéressent, d'après les objectifs et les hypothèses choisis par les auteurs, à la modification de un ou plusieurs de ces paramètres.

Nous allons donc, dans cette partie donner quelques exemples de travaux pour chaque paramètre pour donner une vision d'ensemble des modifications qui peuvent survenir.

A. Le stock et le délai de sécurité

(Dolgui & Prodhon 2007) donne les définitions suivantes pour expliquer le stock et le délai de sécurité :

- Les stocks de sécurité sont importants pour la production car leur intérêt consiste à éviter les facteurs aléatoires. Mais au-delà de leur réduction des risques, ils augmentent les coûts de possession ; c'est pour cette raison qu'il est important de trouver un équilibre pour réduire au plus les ruptures de stocks tout en veillant à ne pas dépasser un certain coût pour garantir un bon niveau de service.
- Les délais de sécurité suivent le même principe que les stocks de sécurité. La différence est que ces derniers concernent les quantités alors que les délais de sécurité concernent le temps. Le délai de sécurité est égal à la déviation des délais et le délai planifié est égal à la somme du délai de sécurité et du délai théorique.

En nous basant sur l'analyse de (Dolgui & Prodhon 2007), nous constatons que d'après (Whybark & Williams 1976), pour minimiser les coûts de stockage et assurer un taux de disponibilité satisfaisant, il faut utiliser le stock de sécurité quand il y a incertitude dans les quantités et le délai de sécurité quand il s'agit d'estimer le délai théorique. Par contre pour (Grasso & Taylor 1984), les stocks de sécurité sont appropriés pour les deux types d'incertitudes : quantité et délai. Quant à (De Bodt & Wassenhove 1983), ils affirment que l'utilisation des stocks de sécurité n'est pas adaptée au cas où la variation de la demande est faible.

En ce qui concerne les travaux basés sur les stocks et les délais de sécurité nous citons (Enns 2002). Le but de cet article est d'étudier l'impact des erreurs de prévision et de l'incertitude de la demande. Aussi l'utilisation des stocks de sécurité et des délais planifiés exagérés (gonflés) pour compenser les erreurs de prévision est évaluée. L'auteur affirme que la solution pour traiter le problème des incertitudes de la demande client et le délai d'achèvement des produits est l'utilisation des stocks et des délais de sécurité. Ces deux derniers améliorent considérablement le niveau de service et la performance. Le choix de l'utilisation de l'un ou l'autre dépend des incertitudes présentes (l'incertitude de la demande nécessite un stock de sécurité).

B. Règles de lot-sizing

Le problème de la taille des lots a fait l'objet de plusieurs travaux. Ce problème est d'ailleurs divisé en plusieurs sous-problèmes. (Jans & Degraeve 2007) développe les différentes variantes de lot-sizing dynamique qui sont :

- Le problème de lot-sizing sans limite de capacité et concernant un seul produit (ULS, *The single item uncapacitated lot sizing problem*)
- Le problème de lot sizing avec capacité limitée et concernant plusieurs produits (*The capacitated lot sizing problem, CLSP*) où plusieurs produits peuvent être fabriqués sur

une seule machine en une seule période. Ceci est appelé large bucket model. Nous retrouvons ce modèle ainsi que le suivant dans l'article de (Gicquel *et al.* 2008).

- (*continuous set up lot sizing problem*, CSLP) Small bucket models où à chaque période un seul produit peut être fabriqué
- (*Multi-level lot sizing*) où le planning de production n'est pas fait seulement pour le produit fini mais aussi pour les composants et l'assemblage.

(Jans & Degraeve 2007) donne les formulations mathématiques pour chacun de ces modèles ainsi que leurs extensions. Les auteurs s'intéressent par la suite aux méthodes de résolutions. Dans le cas de la méthode MRP, plusieurs règles de calcul de tailles de lot existent. (Jans & Degraeve 2007) propose 9 règles de lot-sizing. Les définitions que nous proposons sont celle données par (Dolgui & Prodhon 2007).

- Wagner–Whitin algorithm (WW) : c'est une procédure qui détermine le coût minimal de la passation de commande et de possession pour une demande dynamique déterministe sans contrainte de capacité.
- The economic order quantity (EOQ): c'est une méthode facile qui consiste à calculer la quantité à commander en se basant sur la formule de Wilson.
- Period order quantity (POQ) : C'est une méthode qui peut être déduite de EOQ et où le temps optimal entre les commandes est déterminé. De ce temps la quantité à commander pour chaque période est obtenue.
- Least period cost (LPC) ou aussi connue sous le nom de Silver-Meal (SM) heuristic : cette heuristique permet de couvrir P périodes à partir d'une seule commande. Le but est donc de trouver P qui permet de minimiser la moyenne des stocks par période. D'après (Dolgui & Prodhon 2007) cette heuristique est plus puissante que l'algorithme de WW dans le cas où les incertitudes sont prises en compte.
- Least unit cost (LUC) : c'est une procédure qui estime différente quantité à commander en accumulant les besoins des différentes périodes jusqu'à ce que le coût commence à augmenter.
- Part period balancing (PPB) : permet de calculer le nombre de périodes à couvrir de manière à minimiser les coûts de commande et de possession.
- Least total cost (LTC) : c'est une méthode similaire à la méthode EOQ et qui consiste à supposer que le coût total atteint le minimum quand les différents coûts sont égaux.
- Marginal cost difference
- The technique for order placement and sizing

(Simpson 2001) compare 9 heuristiques de lot-sizing, et ajoute de plus aux heuristiques précédentes 3 autres heuristiques. Il s'agit de :

- Groff's algorithm (GROFF),
- McLauren's order moment (MOM)
- Maximum part period gain algorithm (MPG) dont l'explication est détaillée dans (Simpson 2001),

Dans l'article de (Dolgui & Prodhon 2007), nous retrouvons une analyse de quelques heuristiques. D'après cet article, les règles les plus utilisées sont : LFL, EOQ et POQ, et seulement dans certains cas l'algorithme de WW et l'heuristique de SM sont utilisés.

Nous remarquons donc que les règles de lot-sizing sont nombreuses et par conséquent le choix d'une méthode parmi toutes les autres n'est pas évident. L'analyse de ces méthodes et leur comparaison dont le but de connaître la meilleure solution ont fait l'objet de beaucoup de travaux. Par exemple (Simpson 2001) a comparé 9 règles de lot-sizing et a constaté que d'après les conditions de travail ces règles manifestent des faiblesses et des tendances diverses. (Plenert 1999), quant à lui

propose l'utilisation de la règle LFL pour tous les produits de classe A et la majorité des produits de classe B en se basant sur la classification de Pareto.

C. Plan Directeur de Production (master production schedule)

Le PDP est le plan de la production qui définit les quantités à produire pour les semaines à venir en vue de faire face aux demandes prévisionnelles et fermes. En présence d'incertitudes le PDP doit constamment être mis à jour afin de pouvoir tenir compte des évolutions du marché. Ceci nous mène, d'après (Dolgui & Prodhon 2007), à nous poser les questions suivantes :

- quelle est la fréquence des mises à jour du PDP ?
- est-ce que toutes les données doivent être mises à jour au même moment ?

En guise de réponse, (Dolgui & Prodhon 2007) affirme que les mises à jour fréquentes ainsi que la mise à jour de toutes les données cause le changement constant du plan ce qui provoque des nervosités. De plus ces changements coûtent de l'argent. Par conséquent la mise à jour du PDP ne doit pas se faire fréquemment et elle doit concerner uniquement quelques données et non pas toutes les données à la fois. Aussi, pour réduire les nervosités, il est possible de geler le PDP et d'obtenir ce qu'on appelle la zone ferme ou il n'est pas possible de modifier le PDP. Pour obtenir des bons résultats il faut donc replanifier à la fin de la zone ferme. En outre, des bonnes prévisions et la zone ferme permettent d'agir contre les incertitudes et les nervosités causées.

D. Applications au cas de la méthode MRP

Il est intéressant de connaître l'impact de chacun de ces facteurs (stock de sécurité, délai de sécurité, règle de lot-sizing et la zone ferme) sur la MRP. Aussi, il est important de choisir la règle adéquate au système étudié. (Grasso & Taylor 1984) propose une étude de l'impact des quatre facteurs suivants sur la performance des méthodes MRP en présence d'incertitudes selon les critères suivants

- La quantité du stock de sécurité
- La variabilité des délais de livraison /Le délai de sécurité
- Les règles de lot-sizing
- Coût de possession et les pénalités de retard

L'intérêt de cet article est de voir si ces facteurs influencent le coût total de la MRP. Le système étudié est un système multi-niveaux avec trois produits finaux, et basé uniquement sur l'incertitude de l'approvisionnement, la demande étant supposée constante.

Les résultats obtenus sont :

- Le coût total est affecté par chacun des quatre facteurs
- Le délai de sécurité affecte la performance de la MRP mais pas le stock de sécurité
- La variabilité dans les délais de livraison affecte le choix des règles de lot-sizing

Il est donc judicieux de bien choisir chacun de ces facteurs.

Pour conclure cette partie, le schéma proposé par (Dolgui & Prodhon 2007) représenté dans la Figure 38, est un bon récapitulatif des analyses apportées. Il résume les actions à effectuer en fonction des incertitudes qui se présentent.

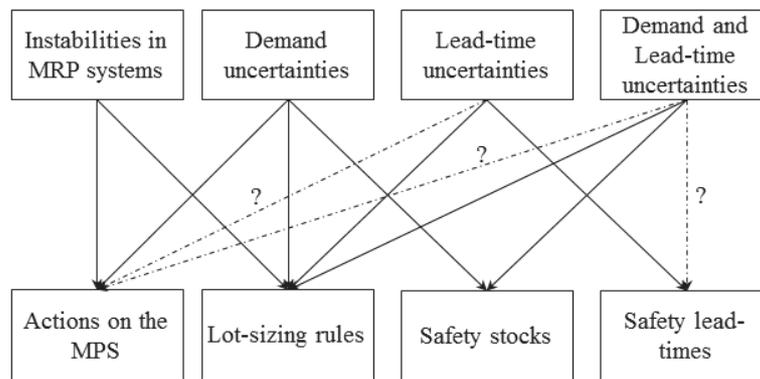


Figure 38: Techniques de planification généralement utilisées

Un autre point important à noter est le fait que le problème de planification peut être aussi résolu avec des méthodes autres que la MRP ou la programmation mathématique. En effet, dans l'article de (Babai *et al.* 2009), l'auteur se base sur les politiques de gestion des stocks classiques avec en particulier la politique (r, Q) et (T, s) . Les travaux de (Babai & Dallery 2009) proposent des extensions de ces deux politiques. Deux politiques dynamiques sont donc étudiées (r_k, Q) , (T, S_k) et comparées avec les politiques statiques.

Pour choisir entre l'utilisation de la MRP ou l'utilisation de politiques de gestion des stocks, (Hautaniemi & Pirttila 1999) propose d'utiliser la classification ABC pour les produits puis d'utiliser la MRP pour les produits de classe A et une politique de réapprovisionnement pour ceux des classes B et C.

III. Conclusion

A travers cette présentation des méthodes, modèles et recherche sur le pilotage des flux, nous voyions qu'un grand nombre de techniques différentes et de pistes de recherche existent. Nous avons choisis de nous concentrer sur les méthodes permettant de prendre en compte des incertitudes afin de pouvoir ensuite appliquer ces méthodes au cas réel du Global Sourcing sous incertitudes. Dans ce champs-là, nous avons montré que plusieurs pistes différentes existaient pour faire face à ces incertitudes : stock et délai de sécurité ; règle de lot-sizing ; mise à jour du PDP ou encore utilisation de la MRP. Toutes ces méthodes différentes offrent des avantages et des inconvénients. Dans notre travail, nous avons choisis de nous intéresser à la mise en place de stocks de sécurité pour faire face aux incertitudes sur la demande. Nous présenterons ces travaux par la suite.

Le Global Sourcing

I. Introduction

Le Global Sourcing, par l'importance qu'il prend depuis quelques années dans le panorama industriel du fait de la globalisation, est un sujet encore peu étudié d'un point de vue quantitatif, même si beaucoup de travaux y portent un regard qualitatif. Ainsi, Il est possible de se faire une idée du design d'une Global Supply Chain ainsi que des besoins organisationnels pour réussir un approvisionnement lointain. Toutefois il est difficile de trouver des modèles de gestion des flux spécifiquement dédiés au Global Sourcing. C'est donc pour cette raison qu'il nous a paru pertinent d'étudier les stratégies de planification dans le cas du Global Sourcing. De plus, la complexité de l'économie actuelle oblige à considérer automatiquement l'existence d'incertitudes dans leurs modèles de gestion des flux.

Un très grand nombre de modèles prennent en compte la demande mais une majorité la considère comme une donnée exogène. Or nous avons mis en évidence que les méthodes utilisées pour modéliser la demande ont un effet important sur les résultats donnés par le modèle d'approvisionnement. C'est pourquoi la considération de la demande comme paramètre endogène nous apparaît comme une piste intéressante pouvant mieux nous informer sur l'interaction entre les paramètres de la demande et les autres variables du problème. Cela nous permettrait ainsi de comprendre les limites des modèles utilisés et de connaître alors les leviers d'amélioration possibles.

Enfin nous avons pu remarquer un obstacle au Global Sourcing qu'il faudra résoudre si l'on veut assurer l'expansion de cette stratégie. En effet, la majorité des industries ont adopté la philosophie du juste à temps au niveau de leurs outils de production. Cependant le Global Sourcing et le juste à temps apparaissent à première vue comme deux méthodes incompatibles, c'est pourquoi il apparaît nécessaire d'investiguer cette piste de recherche pour découvrir une méthodologie capable d'allier ces deux stratégies et de créer ainsi un lien solide entre la production et l'approvisionnement, deux sujets encore considérés de manière disjointe malgré leur interdépendance.

II. Présentation du Global Sourcing

Aujourd'hui par l'internationalisation des marchés, le rôle de la Supply Chain s'est étendu et complexifié afin d'assurer le contrôle des coûts et le développement des bonnes méthodes d'approvisionnement. Ainsi, à cause de l'évolution de l'exigence des clients et le développement des moyens de transport et de communication, les entreprises ont vu leurs barrières d'approvisionnement s'élargir à la planète entière. Dans le contexte actuel, quand une entreprise cherche à se procurer un des composants de son produit final, elle se retrouve devant deux possibilités :

- Choisir un fournisseur présent sur le marché local et ainsi mettre en avant le critère de la proximité,

- S’approvisionner dans des marchés extérieurs soit pour des raisons économiques en ayant accès à des produits équivalents mais à des prix plus avantageux, soit pour des raisons technologiques avec l’accès à des produits de hautes technicités. .

Mais il est important de se rendre compte que malgré son bénéfice financier net, cette dernière option peut très rapidement perdre ses avantages à cause d’une taxe trop importante sur le produit importé, ou de frais de transports extravagants dus à la nécessité d’avoir le produit au plus tôt, ou de taux de rupture significatifs dû aux délais ou aux retards à répétition à cause de l’éloignement géographique. Ainsi la mondialisation a fait du Global Sourcing le nouveau défi que doivent relever les supply chains de toute entreprise qui cherche à augmenter sa rentabilité en s’approvisionnant à l’international. Cette nouvelle pratique si elle est mal gérée peut avoir des conséquences néfastes sur les résultats d’une entreprise, d’où l’intérêt grandissant que lui accorde le monde de la recherche sous le concept de « global supply chain management » (Prasad & Babbar 2000). Ainsi, avant de s’intéresser au modèle d’approvisionnement dédié au Global Sourcing il est nécessaire de découvrir ce domaine et d’en définir les caractéristiques.

A. Qu’est-ce que le Global Sourcing ?

L’approvisionnement lointain, ou *global sourcing*, signifie être livré par un fournisseur (qui peut être interne à l’entreprise) qui se trouve à une certaine distance du destinataire. Cette distance est généralement temporelle plutôt que géographique. L’approvisionnement à l’international (international sourcing) se réfère aux composants et matériels importés par une entreprise, son fournisseur étant localisé en dehors des frontières du pays où elle exerce son activité (Nassimbeni 2006). Ce type d’approvisionnement peut prendre des formes différentes en fonction de l’extension géographique de la base de fournisseurs de l’entreprise étudiée, du plan de distribution et de production des produits fabriqués par cette dernière ou même de l’existence d’une stratégie d’approvisionnement et de vente qui décide du lieu de fabrication des produits.

Plusieurs termes existent dans la littérature pour parler du Global Sourcing. Les chercheurs parlent par exemple de l’import sourcing (Swamidass 1993) ; de l’offshore sourcing (Kotabe & Swan 1994) ; du Global Sourcing (Arnold 2000) ; du worldwide sourcing (Monczka *et al.* 2010).

L’approvisionnement lointain touche pratiquement toutes les entreprises internationales. Citons par exemple les secteurs de l’automobile et de la grande distribution qui représentent des utilisateurs majeurs de cette pratique.

La problématique principale de l’approvisionnement lointain réside dans le fait que les flux sont longs, donc la chaîne logistique devient plus rigide. La Supply Chain doit alors faire face à des problèmes tels que les coûts de transport, les taux de change variables (avec un pays étranger), les législations locales différentes, des réseaux (transport, télécommunications, énergie) mal établis dans certains cas, des employés étrangers mal habitués à des nouvelles techniques de travail, qui ne parlent pas la même langue...

Afin d’externaliser la gestion de ces problématiques, les entreprises font généralement appel à différentes sociétés spécialisées dans l’approvisionnement lointain, comme SDV, ID Logistics, Geodis ou encore Global Sourcing Solutions.

B. Pourquoi le Global Sourcing

Le Global Sourcing est la conséquence de l’apparition d’un autre phénomène qui est l’externalisation et la sous-traitance. La complication de l’environnement économique a contraint les entreprises à minimiser leurs coûts et à se concentrer sur leur vrai cœur de métier « Lean entreprise », ce qui a eu pour conséquence la diminution de la valeur ajoutée apportée en interne. Cela a poussé les entreprises à externaliser plusieurs fonctions faites à l’origine en interne. Avec le

développement des outils de communication et de transport, la recherche d'un spécialiste capable de prendre en charge ces fonctions a pu se faire à l'échelle mondiale entraînant l'apparition du Global Sourcing. Dans ces nouveaux modèles de production les fournisseurs sont devenus les responsables des activités de production (physique). Les industriels de biens matériels prennent de plus en plus le profil d'un fournisseur de service s'occupant néanmoins du marketing et des achats. La conséquence de ces nouvelles stratégies est que le Supply Chain Management est en train de devenir une des principales valeurs ajoutées au niveau de l'entreprise.

La montée en force du Global Sourcing s'est en fait réalisée en même temps que la mondialisation. C'est la surcapacité des pays industrialisés et le désavantage naissant du coût important de la main d'œuvre et la qualification croissante de cette main d'œuvre couplée à l'apparition de nouveaux marchés comme l'Amérique du sud qui a fait du Global Sourcing une alternative stratégique. Selon (Arnold 1989), le choix du Global Sourcing doit se faire suivant une ligne directrice : celle du gain de compétitivité. Dans ce cadre la mondialisation se développe sous deux aspects :

- Opérer sur un marché mondial : la mondialisation signifie le choix systématique de fournisseurs de marché étranger pour une extension des activités,
- Orientation stratégique : la mondialisation signifie l'extension de la base de fournisseurs ainsi que des marchés pour sécuriser la base de profit de l'entreprise.

La question qui se pose alors est la suivante : Pourquoi les entreprises étendent leurs approvisionnements à l'international et en quoi est-ce que cela augmente leur compétitivité ? C'est à cette question que la littérature scientifique s'efforce de répondre (Alguire *et al.* 1994); (Ettlie & Sethuraman 2002) ; (Frear *et al.* 1992); (Smith & others 1999); (Trent & Monczka 2003); (Birou & Fawcett 1993); (Womack & Jones 1996); (Bozarth *et al.* 1998); (Monczka & Guinipero 1984); (Bello *et al.* 2004); (Quintens *et al.* 2006). (Golini & Kalchschmidt 2010) considèrent que la recherche de prix plus compétitifs reste la raison la plus importante, mais sûrement pas la seule. Les marchés internationaux peuvent être la source d'un meilleur savoir-faire qui génère un produit fini de meilleure qualité. Les différences de politiques de taxation ou le taux de change d'une monnaie par rapport à une autre peut aussi être une raison puisque cela entraîne une baisse du prix du produit. Il peut exister des raisons plus stratégiques comme l'accès à de nouveaux marchés, des processus de fabrication plus courts ou même l'image de l'entreprise. (Handfield 1994) mentionne 5 principaux bénéfices qu'une entreprise retire du Global Sourcing : l'amélioration de la qualité de ses produits, la réduction des coûts, l'accès à de nouvelles technologies, l'extension de sa base de fournisseurs et enfin il considère que le Global Sourcing peut aider les entreprises à mieux répondre à leurs exigences de calendrier.

C. Les contraintes du Global Sourcing

Il existe un certain nombre de contraintes au sein d'une Global Supply Chain qu'il est important de souligner. Pour mettre en évidence ces difficultés, plusieurs auteurs le comparent à une Supply Chain locale (Meixell & Gargeya 2005); (Dornier *et al.* 2008); (Wood 2002) ; (MacCarthy & Atthirawong 2003). En effet, s'il est évident que l'éloignement géographique entre l'entreprise et son fournisseur entraîne une augmentation des coûts de transport, il est important de préciser que cet éloignement est à l'origine d'autres contraintes moins directes parmi lesquelles nous pouvons citer la différence de culture, de langue, de pratique industrielle et le manque d'infrastructures. Ces différences peuvent avoir des conséquences directes sur des processus comme la planification des approvisionnements entraînant des retards importants et des lead-times assez aléatoires, ce qui contribue à l'introduction de nouvelles incertitudes dans la supply chain. Les entreprises vont donc essayer de limiter l'effet de ces incertitudes et de sécuriser la chaîne d'approvisionnement.

Différentes actions existent, parmi les plus connues et utilisées : l'augmentation du niveau de stock. Néanmoins cette pratique n'est pas sans conséquence puisqu'elle affecte la santé financière de l'entreprise en augmentant les coûts fixes liés aux stocks.

Dans le cadre du Global Sourcing (Golini & Kalchschmidt 2010) considère que les entreprises ont toujours tendance à vouloir se protéger de deux principaux effets : la variabilité et la perturbation. Cela touche principalement la production et l'approvisionnement. Afin de contrer ces effets néfastes les entreprises ont deux paramètres à leur disposition : le niveau de stock et la capacité de production (Stratton & Warburton 2006). Ainsi de nombreux modèles de gestion des stocks prédisent une forte dépendance entre le stock moyen, le lead-time et sa variabilité (Minner 2003). Il semble en effet logique qu'un approvisionnement à l'échelle mondiale puisse entraîner des délais de livraison beaucoup plus importants, la réponse des entreprises à cette question est donc la mise en place d'un niveau de stock de sécurité suffisamment important pour pouvoir absorber l'incertitude créée par le Global Sourcing. En effet, si l'on prend l'exemple des modèles de gestion des stocks standard et que l'on suppose que la demande est modélisée par une loi normale avec une moyenne m_D et un écart-type σ_D . Les paramètres optimaux des modèles (r,Q) et (T,s) par l'approche séquentielle (optimisation du paramètre d'économie d'échelle suivie de l'optimisation du paramètre de stock de sécurité) sont donnés par les équations (1) et (2) avec $\phi(\cdot)$ la fonction de répartition de la loi normale et CSL la probabilité de ne pas avoir de rupture.

$$Q = \sqrt{\frac{2Am_D}{h}} \quad r = m_D(L+1) + \phi^{-1}(CSL)\sigma_D\sqrt{L+1} \quad (1)$$

$$T = \sqrt{\frac{2A}{m_D h}} \quad S = m_D(L+T) + \phi^{-1}(CSL)\sigma_D\sqrt{L+T} \quad (2)$$

Q : la quantité à commander

L : délai d'approvisionnement

R : point de commande

A : coût de passation de commande

S : niveau de rechargement

T : période à la fin de laquelle le niveau de stock est vérifié

Il est évident, comme on le verra dans la suite de ce travail que l'allongement du délai de livraison (L) va avoir des conséquences directes sur le stock : au niveau du modèle (r,Q) le point de commande va être plus haut et le modèle (T,s) va voir son niveau de rechargement augmenter aussi.

De la même façon (Golini & Kalchschmidt 2010) se sont intéressés à la possibilité de gérer le niveau de stock dans le cas d'un approvisionnement mondial. Plus précisément nous nous intéresserons à l'étude qu'ils ont menée auprès de 711 entreprises dans 23 pays. Parmi les 4 scénarii qui mettent en évidence 4 hypothèses différentes, celui qui nous semble pertinent est celui qui suppose que le Global Sourcing a pour conséquence l'augmentation du niveau de stock. L'étude démontre ainsi que les entreprises qui s'approvisionnaient le plus à l'international avaient tendance à avoir un niveau de stock plus important. Ce résultat souligne l'importance de considérer les effets secondaires du Global Sourcing. En effet les entreprises ont tendance à s'approvisionner à l'étranger dans le but de profiter des coûts moins importants qui peuvent exister dans d'autres pays. Néanmoins cela peut conduire à l'augmentation du niveau de stock donc à des coûts de détention qui peuvent dépasser les gains apportés par l'approvisionnement à l'international. (Handfield 1994) confirme également que le lead-time et le coût des stocks font partis des 5 principaux problèmes que rencontrent les entreprises qui s'approvisionnent à l'échelle planétaire. Il affirme que le Global

Sourcing a pour conséquence une augmentation des retards de livraisons et du lead-time. Nous y ajouterons également l'augmentation du coût des stocks.

L'objectif sera alors de trouver des solutions pour diminuer ces effets qui paraissent contre-productifs. Dans cette optique le juste à temps a beaucoup été utilisé pour réduire les stocks ou au moins les contrôler, mais il semblerait que sa mise en place demande un environnement spécifique (de petits lots, des livraisons fréquentes et rapides) qui ne permet pas son utilisation dans tous les domaines. Selon (Golini & Kalchschmidt 2010) pour la réussite d'un JIT international ou simplement la mise en place d'un approvisionnement à l'échelle planétaire, il est important de créer une coordination et une communication entre les clients et les fournisseurs. En effet, lorsqu'une entreprise se lance dans l'approvisionnement à l'échelle internationale, elle va se trouver confrontée à une base de fournisseurs très fournie, ce qui impose à l'entreprise d'avoir un système d'information suffisamment flexible pour être capable de gérer un nombre important de fournisseurs.

D. La littérature sur le Global Sourcing

A l'image de l'intérêt que porte le monde de l'industrie au Global Sourcing, le nombre de travaux dédiés à ce sujet a augmenté dans les années 90. Selon (Nassimbeni 2006), cette littérature peut être classée en trois catégories :

- Les articles qui se sont intéressés d'un côté aux raisons qui ont encouragé les industriels à opter pour le Global Sourcing et d'un autre côté aux obstacles principaux qui font de cette nouvelle stratégie d'approvisionnement une activité complexe. Ainsi la littérature a mis en évidence que le choix du Global Sourcing se faisait par la prise en compte d'une combinaison de facteurs :

- La possibilité d'obtenir des ressources rares (matière première, composants, main d'œuvre, technologie) (Monczka & Trent 1992) ; (Birou & Fawcett 1993) ;
- La recherche de ressources moins chères (Carter & Narasimhan 1990) ; (Min & Galle 1990) ; (Handfield 1994) ; (Meijboom & Vos 1997) ; (Spekman *et al.* 1999) ;
- La possibilité de consolider sa présence sur le marché international (Kotabe & Murray 1990) ; (Monczka & Trent 1992) ; (Saarenketo *et al.* 2004) ;
- Les obstacles à la mise en place d'un approvisionnement à l'international : transport, transaction internationale, taxes, logistique, main d'œuvre qualifiée... (Swamidass 1993) ; (Fawcett *et al.* 1993) ; (Fraering & Prasad 1999).

- Les articles qui se sont intéressés aux profils et aux trajectoires de développement du Global Sourcing (Kotabe & Murray 1990); (Monczka & Trent 1992) ; (Swamidass 1993) ; (Arnold 1989) ; (Trent & Monczka 2003))

- Les articles qui se sont intéressés au management de l'approvisionnement à l'international (Caddick and Dale 1987) ; (Narasimhan & Carter 1990) ; (Sweeney 1994) ; (Smith & others 1999). En effet Le Global Sourcing a des spécificités managériales qui n'existent pas dans le cadre d'un approvisionnement local.

Suite à cette classification (Nassimbeni 2006) considère à juste titre qu'il existe un manque important dans la littérature sur le Global Sourcing pour les points suivants :

- La majorité des études sont dédiées à des pays spécifiques (USA, Japon ...)
- La majorité des études existantes ne considèrent que le cas de multinationales

- La compatibilité entre le juste-à-temps et l'approvisionnement à l'international et plus généralement la relation entre le niveau d'intégration de la supply chain et l'approvisionnement à l'international
- Le lien au niveau stratégique entre la production et l'approvisionnement à l'international
- Les compétences et les besoins organisationnels nécessaires pour répondre aux enjeux que soulèvent le Global Sourcing

Parmi les manques que soulève (Nassimbeni 2006) nous allons essayer d'en explorer deux. D'abord, le lien approvisionnement-production qui est rarement étudié dans les différents modèles. Parmi ceux qui se sont intéressés à cette problématique cherchant à fournir un modèle de planification global, (Hong & Hayya 1999) ont considéré simultanément une gestion de production et d'approvisionnement. Au niveau de l'approvisionnement, les auteurs imposent une certaine taille de lot et définissent des contraintes sur l'outil de production : une même taille de lots pour toute la production et un unique temps de production. Cet article a pour objectif de mettre en évidence la dépendance entre la demande en produits finis et les composants approvisionnés. Ainsi les auteurs déterminent dans un premier temps une solution générale pour trouver la meilleure politique de production et d'approvisionnement correspondante et étudient dans un deuxième temps les effets de la demande sur les politiques de production et l'effet de ces dernières sur le processus d'approvisionnement.

Le deuxième point soulevé par (Nassimbeni 2006) est la compatibilité entre le juste-à-temps et l'approvisionnement à l'international. Effectivement, un certain nombre d'obstacles persistent quant à l'utilisation de fournisseurs étrangers. Les principales exigences du juste à temps sont la commande de petits lots et une fréquence de livraisons importante. Ainsi le conflit majeur entre le Global Sourcing et le JIT est le manque de proximité entre le fournisseur et l'entreprise car cela réduit considérablement les fréquences de livraisons et pour des raisons de réduction de coût les quantités commandées sont très importantes. De plus il est évident que le travail coopératif auquel encourage le JIT n'est pas favorisé dans le Global Sourcing. En effet, pour sécuriser au maximum la supply chain une proximité organisationnelle entre les deux acteurs est avantageuse, or l'approvisionnement à l'international ne fait que rajouter des risques car elle fait intervenir un grand nombre d'acteurs en sus du fournisseur et de l'entreprise. Pour résumer, si la ligne directrice de la philosophie JIT est la flexibilité et la fiabilité, les principales faiblesses du Global Sourcing sont l'incapacité de garantir ces deux aspects.

Ainsi dans un premier temps, il semblerait que ces deux stratégies ne soient pas compatibles et beaucoup d'articles se sont efforcés de le démontrer (Vickery 1989) ; (Das & Handfield 1997) ; (Humphreys *et al.* 1998). Néanmoins quelques articles se sont intéressés à cette problématique (Fawcett *et al.* 1993) ; (Vickery 1989) et ont essayé d'apporter un début de réponse. (Vickery 1989) s'est intéressé aux pratiques de trois entreprises américaines qui ont essayé de conjuguer l'approvisionnement à l'international et le juste à temps. De cette investigation sont ressortis les axes principaux de la réussite du projet. Le premier est la nécessité pour l'entreprise d'optimiser ses méthodes de planification de sa logistique et de sa production. En deuxième lieu il est important de créer une relation de communication entre l'entreprise et le fournisseur en tirant parti du décalage horaire existant entre les acteurs. Troisièmement, une relation à long terme doit s'établir entre les deux acteurs avec l'assurance de quantité conséquente d'un côté et la garantie d'une logistique efficace de l'autre. Enfin, la rapidité du passage en douane semble être un facteur influant dans la minimisation des délais de livraison. Malgré les efforts qui ont pu être faits dans ce domaine, (Das & Handfield 1997) sont arrivés à la conclusion que les performances acquises grâce à l'implémentation

du JIT dans le domaine de l'approvisionnement et de la logistique dans le cadre du Global Sourcing ne sont en rien comparables à l'efficacité de cette méthode dans le cadre local.

III. Conclusion

Dans cette section, nous avons présenté de façon synthétique le Global Sourcing et les objectifs liés à la mondialisation croissante de l'économie auxquels il répondait. Cependant, le Global Sourcing impose un grand nombre de contraintes. Nous avons en effet montré qu'il complexifiait la Supply Chain et que des nouveaux compromis entre les coûts constituant les produits étaient à faire. Nous avons alors présenté les travaux traitant de cette problématique et nous avons vu que les études quantitatives sur le sujet étaient extrêmement rares même si les analyses stratégiques (Cook 2007) ou les études qualitatives sont nombreuses. Cette étude renforce donc la pertinence de notre recherche dont le but est de proposer des méthodes quantitatives de pilotage de flux via la gestion des stocks dans le contexte particulier du Global Sourcing. Nous allons donc maintenant présenter le pilotage de flux en Global Sourcing avec les modèles que nous avons développés afin de répondre à cette problématique.

Le pilotage de flux en Global Sourcing

Suite à la présentation des politiques de pilotage de flux classiques et à la présentation générale du Global Sourcing, nous allons maintenant présenter les méthodes de pilotage de flux et de sécurisation des approvisionnements lointains que nous proposons afin de prendre en compte les spécificités du Global Sourcing.

Nous allons commencer par la description de notre objectif de recherche, puis nous présenterons la méthode utilisée. La dernière partie sera consacrée à la présentation du modèle proposé et des résultats obtenus.

I. Objectifs de recherche

L'objectif de notre recherche a été de définir une méthode permettant de sécuriser l'incertitude sur la demande. Cette sécurisation va se faire par la mise en place d'un stock de sécurité. Chaque source d'incertitude devant être traitée spécifiquement, les autres sources d'incertitudes comme le délai d'approvisionnement doivent être traité sécurisés via d'autres mesures comme la mise en place d'un stock tampon par exemple.

L'ensemble de ces sécurisations mène à un stock de sécurité qui doit être analysé non pas par sa globalité mais par ses différentes raisons d'être de façon à éviter que la conjugaison simultanée de deux causes n'induisse une pénurie de produits.

Ici, nous nous focalisons donc sur le stock de sécurité permettant de faire face aux aléas de la demande et aux erreurs de prévisions, ce que nous pourrions appeler la variabilité commerciale. Les incertitudes liées aux délais d'approvisionnements ou aux quantités délivrées ne sont donc pas traitées ici.

II. Méthode de recherche

Le travail décrit dans ce chapitre est réalisé dans le cadre de la chaire Supply Chain pour le groupe PSA. L'internationalisation du groupe PSA fait que l'entreprise est confrontée aux approvisionnements lointains pour l'approvisionnement de ses usines situées sur les différents continents. De plus, l'industrie automobile est un secteur ultra-concurrentiel où la place de la logistique dans l'efficacité globale des entreprises est un point clef. Dans le but de sécuriser et d'optimiser sa Supply Chain mondiale, PSA veut développer de nouvelles méthodes pour déterminer les bons niveaux de stock de sécurité à mettre en place pour répondre à la variabilité commerciale. Cette problématique est commune à l'ensemble des industries traitant avec des flux de renouvellement de consommation internationaux.

Dans le but de répondre au challenge de la gestion des stocks en Global Sourcing, nous avons développé un modèle de détermination du niveau de stock basé sur une sécurisation via l'observation du passé que nous avons nommé « Horizon Safety Stock (HSS) ». Nous avons validé notre modèle par des simulations sur des données provenant d'un cas d'étude réel. Ce cas est le suivant : Des commandes sont passées quotidiennement à des fournisseurs locaux et d'autres internationaux. Les fournisseurs locaux approvisionnent en une semaine tandis que les approvisionnements internationaux demandent plusieurs semaines. Une synchronisation est de plus nécessaire entre les différentes commandes afin d'avoir les produits aux bons moments pour la production quotidienne. Dans le cas de variabilité de demande et d'erreur de prévision, les réceptions de commandes ne correspondent plus aux demandes réelles et peuvent donc entraîner des ruptures. La mise en place de stock de sécurité permettant de faire face à ces fluctuations est donc nécessaire. Le but est alors de déterminer le bon niveau de ces stocks de sécurité afin d'absorber les erreurs de prévisions sur le délai d'approvisionnements.

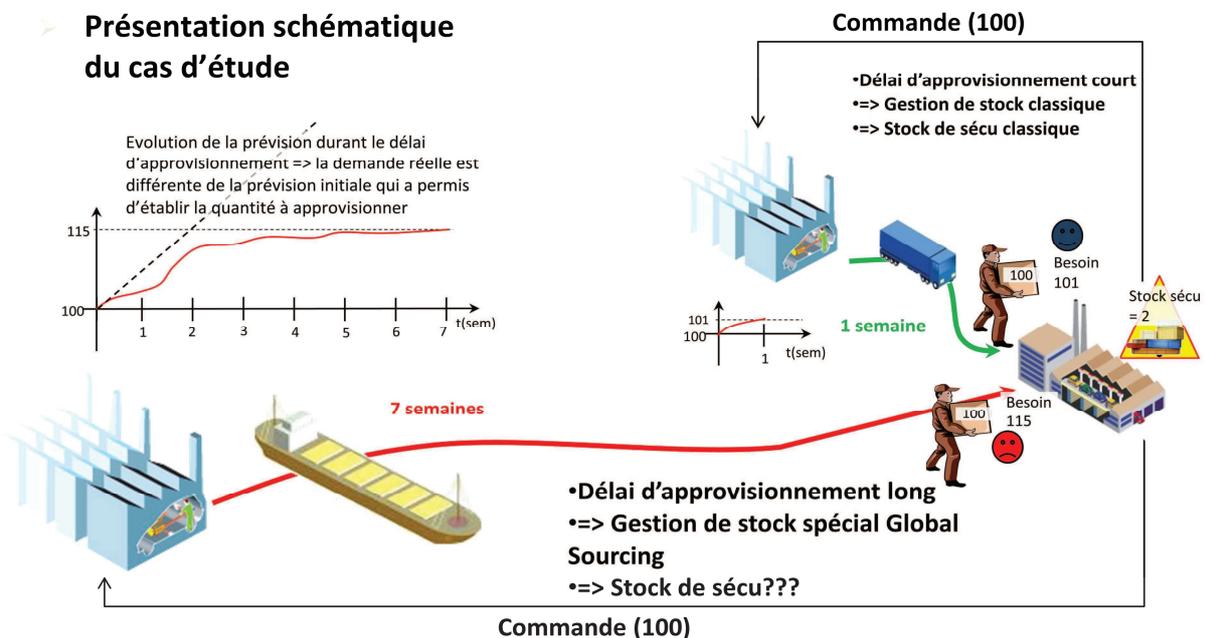


Figure 39: Présentation schématique du cas d'étude

III. Présentation du modèle de pilotage des flux en Global Sourcing

Les prévisions réalisées sur l'horizon de planification des approvisionnements ne peuvent pas être exactes du fait de la variabilité commerciale. Cependant, la sécurisation des commandes de réapprovisionnement permettant d'assurer un taux de service important (en général supérieur à 95%) est nécessaire. Une rupture de stock ne peut pas être acceptée du fait des processus industriels en aval de la chaîne d'approvisionnement. Dans le contexte automobile, l'arrêt d'une usine est extrêmement coûteux. L'arrêt d'une usine entraîne des coûts de l'ordre du million d'euros par jour. En cas de rupture annoncée, un mécanisme de réapprovisionnement d'urgence, plus coûteux que les approvisionnements classiques est alors mis en place. Les réapprovisionnements peuvent par exemple être faits par avion ou hélicoptère en lieu et place du transport maritime ou terrestre.

Cependant, lors d'une rupture annoncée, les procédures permettant d'éviter cette rupture sont extrêmement coûteuses, ce qui explique la nécessité d'avoir un taux de service élevé.

A. Présentation des paramètres des modèles de gestion de flux

Dans la suite de ce mémoire, nous utiliserons les notations suivantes :

L : Le délai d'approvisionnement fixe;

α : Le paramètre d'horizon de sécurisation que nous utilisons dans le modèle *HSS*. Ce paramètre représente la taille de l'historique pris en compte dans l'étude des erreurs permettant de définir la sécurisation future. Plus alpha est petit, plus l'horizon est court et moins on gardera d'historique en considération. A l'inverse, plus alpha est grand plus la taille de l'historique pris en compte sera importante ;

nr : Le nombre de rupture de stock sur l'horizon de taille alpha précédent, c'est à dire durant les alphas périodes précédentes;

NEA : Le nombre d'erreurs acceptables sur l'horizon de taille alpha précédent, c'est à dire sur les alphas périodes précédentes;

ASL : Le taux de service réel. Il est calculé *a posteriori* avec le nombre réel de rupture de stock sur l'horizon alpha étudié.

$$ASL = 1 - \left(\frac{nr}{\alpha} \right)$$

TSL : Le taux de service cible;

$ATSL$: Le taux de service cible réel;

UC : L'unité de commande

D_i : La demande réelle pour la période i ,

$F_{i,j}$: La prévision pour la période j réalisée à la période i ,

O_i : La commande de la période i ,

PS_i : Le stock physique à la période i ,

UI_i : Le stock utile à la période i ,

CE_i : L'erreur cumulative de la période i ,

SS_i : Le stock de sécurité de la période i ,

RO_i : La commande réelle de la période i ,

B. Fonction objectif et contraintes des modèles

Le but de notre contribution est de réduire le stock physique tout en maintenant un haut niveau de taux de service. Dans la suite, nous allons présenter la fonction objectif ainsi que les contraintes qui ont guidé notre travail. Notre but est de minimiser le stock physique sur l'horizon considéré.

Ce type de problème a deux formulations classiques. La première traite des coûts. Un coût de stock est associé à chaque unité de produit étant en stock pour chaque période. De la même façon, un coût est associé aux ruptures. A partir du calcul de ces différents coûts, nous pouvons trouver le compromis « Coût de stock vs coûts de rupture » permettant de minimiser le coût total et donc déterminer le bon niveau de stock.

La seconde formulation s'appuie sur le taux de service comme contrainte pour déterminer le bon niveau de stock. Cette formulation est plus utile lorsque la détermination des coûts (coûts de stock et coût de rupture) est difficile à réaliser. Dans ce cas, la contrainte est d'assurer un taux de service qui

est donnée par le gestionnaire des stocks. Pour cela la mise en place d'un niveau de stock s'impose. L'objectif est alors de minimiser ce stock tout en satisfaisant la contrainte de taux de service.

Nous nous appuyerons dans notre travail sur cette seconde formulation du fait de la difficulté à estimer les coûts réels de stock et de rupture dans la première formulation.

Nous partirons donc d'un taux de service cible (TSL) qui nous permettra de déterminer les paramètres de notre modèle. Ce taux de service est alors obtenu pour un profil de demande particulier qui répondrait à la modélisation théorique de la demande et de la prévision. Dans la réalité, la demande et la prévision peuvent ne pas suivre exactement ce profil. Le taux de service réel est alors différent du taux de service cible. La difficulté est donc d'avoir une bonne robustesse sur le taux de service réel par rapport au taux de service cible.

1. Fonction objectif

L'objectif est de minimiser le stock physique sur l'horizon considéré. Cela revient donc à minimiser la moyenne du niveau de stock.

$$OF = \min(\text{mean inventory})$$

2. Contraintes

L'unique contrainte que nous avons est le taux de service que l'on doit garantir. Ce taux de service est défini par le gestionnaire du stock, selon ses besoins. Nous prendrons comme exemple pour la suite un taux de service de 95%.

$$ASL > 95\%$$

Nous avons alors à déterminer le bon niveau de stock permettant d'obtenir le taux de service réel (ASL) de 95%. Pour cela, nous avons fixé un taux de service cible (TSL) qui est défini par l'équation (3). Ce TSL nous permet ensuite de déterminer le nombre d'erreurs acceptables (NEA) sur l'horizon d'étude qui est défini par l'équation (4).

$$TSL \geq 1 - \left(\frac{NEA}{\alpha} \right) \quad (3)$$

$$NEA = \lfloor \alpha \cdot (1 - TSL) \rfloor \quad (4)$$

Prenons un exemple illustratif. Considérons le cas où $\alpha = 35$ et $TSL = 90\%$. Dans ce cas, nous obtenons $NEA = \lfloor \alpha \cdot (1 - TSL) \rfloor = \lfloor 3.5 \rfloor = 3$. Nous allons alors pouvoir accepter les 3 erreurs de prévision cumulative les plus importantes dans la définition de notre stock de sécurité donc dans notre (TSL) tandis que les erreurs inférieures devront être absorbées par le stock de sécurité. La Figure 40 propose une représentation graphique de ceci.

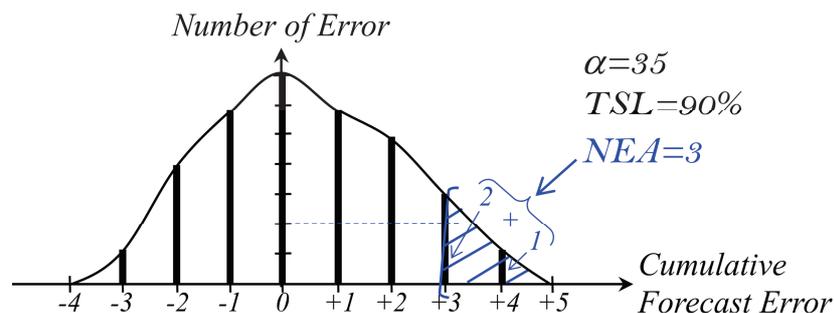


Figure 40: Présentation du TSL

Ce calcul nous montre qu'il existe une différence entre le TSL et l'ATSL. En reprenant l'exemple précédent, du fait des approximations aux parties entières, nous obtenons un ATL = 91% et non 90% comme le TSL. L'équation (5) présente le mode de calcul de l'ATSL. Cette différence est due à la discrétisation de la demande et sera considérée comme négligeable dans la suite du travail.

$$ATSL = 1 - \left(\frac{NEA}{\alpha} \right) \quad (5)$$

Notre travail se base donc sur la loi empirique déduit des données réelles. Cette loi empirique permet d'avoir un modèle collant au maximum à la réalité en prenant en compte toutes ces particularités. Nous pouvons ainsi avoir des lois de toutes les formes. Cela permet de s'affranchir des contraintes liées à la modélisation théoriques via des lois comme la loi normale généralement utilisé. De plus, nous prenons en compte l'évolution de l'erreur prévisionnelle sur le délai d'approvisionnement en prenant en compte la réactualisation des prévisions sur cet horizon.

Nous allons maintenant présentée la méthode permettant de gérer les approvisionnements et le niveau de stock de sécurité dans l'étude de cas que nous avons réalisée.

C. Gestion des flux avec prise en compte de l'historique des erreurs dans le cas du Global Sourcing

Avec la technique de gestion des approvisionnements que nous allons maintenant présenter, nous définissons les deux méthodes de détermination du stock de sécurité permettant de sécuriser les réapprovisionnements en Global Sourcing. Nous simulons la méthode sur des données issues d'un cas réel de réapprovisionnement d'une usine d'assemblage automobile. L'échantillon de données permettant de simuler notre méthode correspond à un ensemble de produits présentant des profils de demande aléatoire non stationnaire différents (demande forte, faible, lisse, variable) et un délai d'approvisionnement fixe L .

Les commandes sont basées sur des demandes prévisionnelles sur l'horizon L , les stocks existants et les commandes passées durant les L périodes (jours) précédentes. L'utilisation de l'historique des erreurs de prévision nous permet de déterminer l'incertitude prévisionnelle et ainsi optimiser le niveau de stock tout en sécurisant la Supply Chain.

Voici la présentation des six étapes permettant de déterminer les commandes pour chaque période. Notre contribution est principalement située au niveau de la définition du stock de sécurité via les deux méthodes que nous allons présenter.

1) Détermination du stock physique dans la chaîne logistique globale

$$PS_j = PS_{j-1} - D_j + RO_{j-L}$$

2) Détermination du besoin en stock permettant de couvrir les demandes des L jours à venir.

$$UI_j = \sum_{i=j+1}^{j+L} F_{j,i}$$

3) Détermination du stock de sécurité dynamique

a. Détermination de l'erreur cumulative

$$CE_j = \sum_{i=1}^L RO_{j-i} - UI_j$$

b. Détermination du stock de sécurité dynamique : Horizon Safety Stock (HSS).

Ce modèle se base sur la contrainte du taux de service cible fixé par l'utilisateur (TSL) et sur la minimisation du niveau de stock. L'analyse des erreurs de prévisions passées va permettre de déterminer le nombre d'erreurs acceptables (NEA) et ainsi le niveau de stock de sécurité à mettre en place afin de sécuriser les erreurs de prévisions situés en deçà des erreurs acceptables. Pour ce faire, nous allons alors prendre la NEA^{ième} valeur maximale de l'erreur cumulative afin de respecter le TSL pour déterminer le niveau du stock de sécurité. Ceci va nous permettre de garantir le taux de service cible sur les périodes futures dans l'hypothèse où les erreurs de prévisions à venir seraient similaires aux erreurs de prévisions passées.

$$SS_j = NEA^{th} \max_{i \in [j-1; j-\alpha]} (CE_i)$$

Le second paramètre (α) permet de s'appuyer sur le principe de répétabilité. Nous faisons en effet l'hypothèse qu'en regardant les erreurs du passé, nous devrions pouvoir prévoir les erreurs du futur. Donc en se fixant un niveau de stock supérieur aux erreurs du passé, nous ne devrions plus avoir de rupture sur les erreurs du futur. Le paramètre α représentant la taille de l'historique à prendre en compte pour l'analyse des erreurs passées est donc celui qui va nous permettre également de jouer sur la confiance que l'on peut avoir dans notre sécurisation. L'utilisation d'un α faible (14 jours) ne nous prémunira que sur un nombre réduit d'erreurs de prévision tandis que l'utilisation d'un α grand (126 jours) nous permettra d'avoir une confiance importante dans notre stock de sécurité. Le pendant de cette confiance sera un niveau de stock de sécurité plus important.

Un exemple de stock de sécurité à horizon (HSS) déterminé à partir de l'erreur cumulative avec

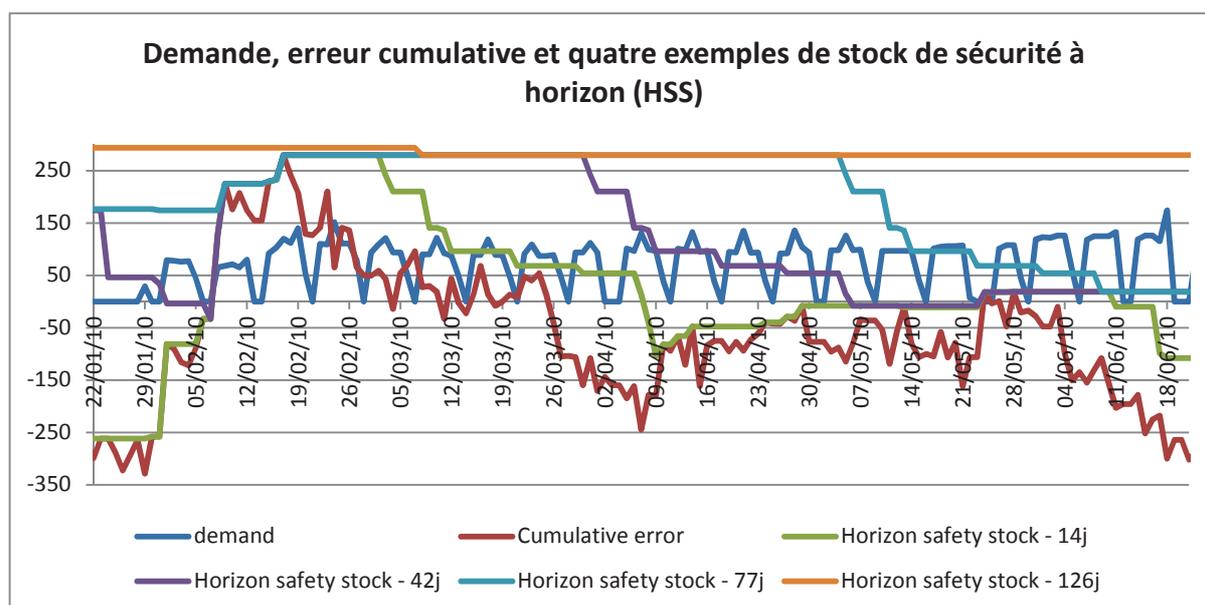


Figure 41: Présentation du niveau de stock de sécurité à horizon (HSS) pour quatre paramètres α différents et un TSL=100%

quatre paramètres d'horizon différents et un même TSL de 100% est présenté sur la Figure 41.

Un second exemple de stock de sécurité à horizon (HSS) déterminé à partir de l'erreur cumulative avec quatre paramètres de taux de service cible différents pour un même horizon de sécurisation de 21 jours est présenté sur la Figure 42.

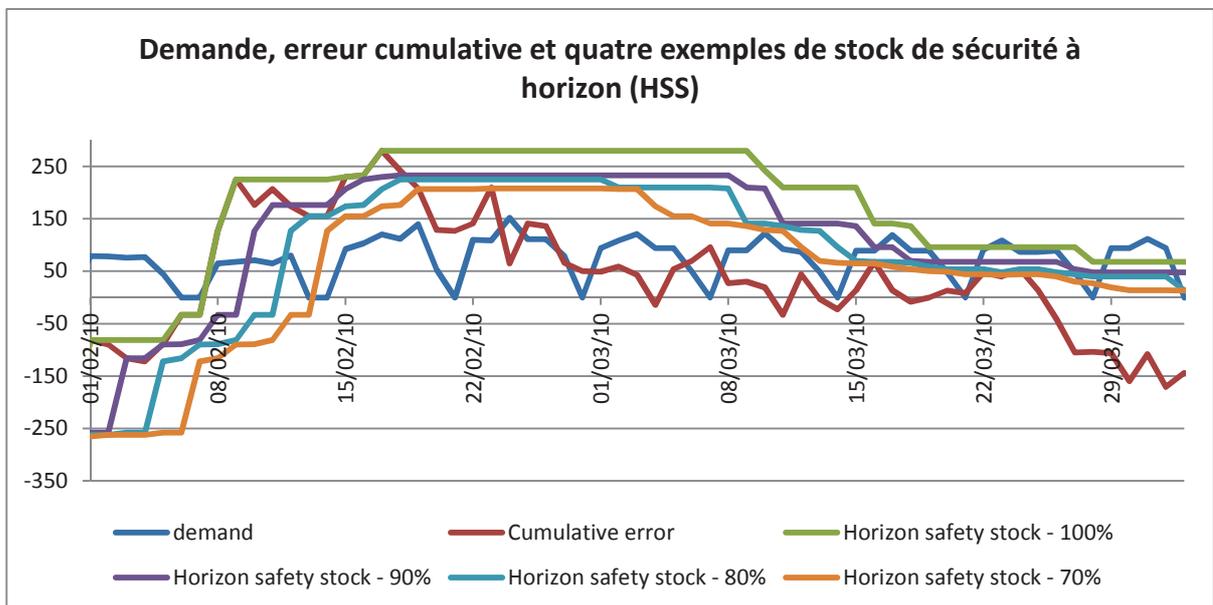


Figure 42: Présentation du niveau de stock de sécurité à horizon (HSS) pour quatre paramètres TSL différents et un $\alpha=21$ jours

Nous voyons que l'utilisation d'un paramètre α grand permet d'éviter d'avoir une erreur cumulative supérieure au stock de sécurité dans la majorité des cas mais impose un niveau de stock de sécurité sur toutes les périodes. A l'inverse, un paramètre α petit permet d'avoir un stock de sécurité relativement faible mais avec une erreur cumulative dépassant régulièrement le niveau du stock de sécurité. De la même façon, le paramètre TSL permet de faire varier la sécurisation mais également le niveau de stock.

Nous présenterons les résultats obtenus avec ce type de modèle de gestion des stocks dans la suite de notre travail.

4) Détermination de la commande à passer pour assurer le bon niveau de stock

$$O_j = UI_j - \sum_{i=j-1}^{j-L-1} RO_i + SS_j - PS_j$$

5) Commande de la quantité compatible avec les contraintes de lotissement

$$RO_j = \left\lfloor \frac{O_j}{UC} \right\rfloor * UC$$

6) Lancement de la commande

IV. Présentation des résultats

Nous allons maintenant présenter l'application des modèles que nous venons d'exposer sur un échantillon de données réelles. Cela va nous permettre de déterminer la performance de chacune de ces méthodes de façon indépendante, puis de les comparer les unes aux autres ainsi qu'à la méthode industrielle.

A. Application de notre méthode

L'échantillon de données provient d'un cas réel d'approvisionnement d'une usine d'assemblage automobile du groupe PSA. Cet échantillon va nous permettre de valider nos modèles.

Cet échantillon représente la demande journalière ainsi que des prévisions à la maille quotidienne sur un horizon supérieur au délai d'approvisionnement mises à jour quotidiennement pour trente produits présentant des profils de demande stochastique non stationnaire différents. Certains présentent des demandes fortes, d'autres faibles, certaines lisses et d'autres très variables. Les modèles présentés peuvent néanmoins être appliqués à d'autres cas que celui-ci. Un historique de près de 3 ans soit plus de 1000 jours a été utilisé. De façon à obtenir des résultats significatifs, l'historique nécessaire doit être au minimum égal à deux fois le délai d'approvisionnement. Celui-ci est dans notre cas de 49 jours depuis le lancement de la commande jusqu'à la réception des produits commandés.

Nous devons donc définir le bon niveau de stock de sécurité afin de réduire le niveau moyen de stock physique tout en maintenant un taux de service à un niveau convenu. D'autres contraintes comme le lissage des commandes font partie des perspectives de recherche apportées par nos travaux. Des simulations permettant de présenter les résultats suivants ont été obtenues via le logiciel VBA de la suite office afin de tester différents paramètres.

Nous allons maintenant présenter sur le modèle HSS.

B. Horizon safety stock

Nous avons testé l'effet des deux paramètres du modèle HSS à savoir le paramètre d'horizon (α) et le paramètre de taux de service cible (TSL) sur l'échantillon de données présenté précédemment. Nous avons fait varier le premier paramètre de 7 jours (1 semaine) à 126 jours (18 semaines soit environ 4 mois) par incrément d'une semaine. Nous avons pris cette plage afin de voir l'impact de la prise en compte des erreurs passées dans la prédiction des erreurs futures et dans leur sécurisation via le stock de sécurité. Un horizon d'une semaine est le minimum à considérer du fait du contexte de global sourcing. Nous considérons que 126 jours est une bonne borne supérieure étant donné que cet horizon correspond à plus de deux fois et demi le délai d'approvisionnement de notre étude et que ce délai dépasse rarement les quatre mois dans la pratique. De plus, nos résultats montrent que la différence tend à devenir non significative au fur et à mesure de l'augmentation de α . Concernant le second paramètre (TSL), nous avons simulé six valeurs différentes : 70%, 80%, 85%, 90%, 95% et 100%. Les résultats sont présentés dans le Tableau 21. Nous y retrouvons pour chaque taux de service cible (TSL) le niveau de stock physique pour chacun des paramètres d'horizon α . Nous avons également fait apparaître le taux de service cible réel (ATSL) de façon à montrer la petite différence existant entre le TSL et le ATSL.

De façon à rendre ces résultats plus clairs, nous présentons également deux graphes représentant la corrélation entre l'horizon pris en considération (c'est-à-dire la valeur du paramètre α) et le niveau de stock d'une part et entre l'horizon pris en considération et le taux de service réel (ASL) d'autre part. Ces deux graphes permettent également de voir l'influence du taux de service cible (TSL).

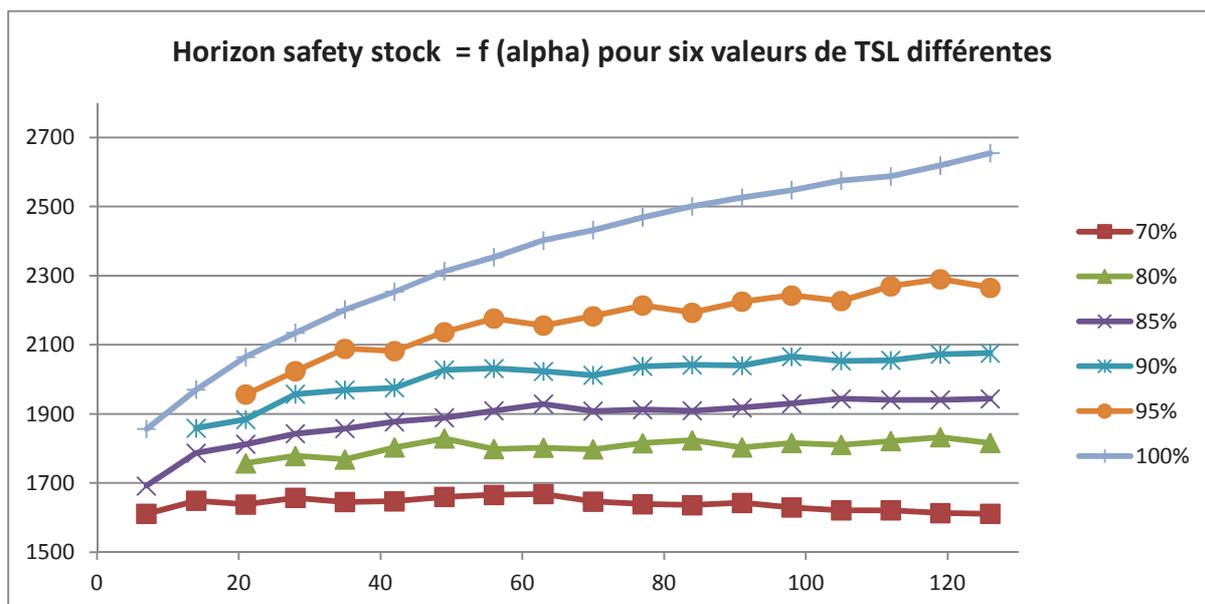


Figure 43: Présentation du niveau de stock physique en fonction de α pour six valeurs de TSL

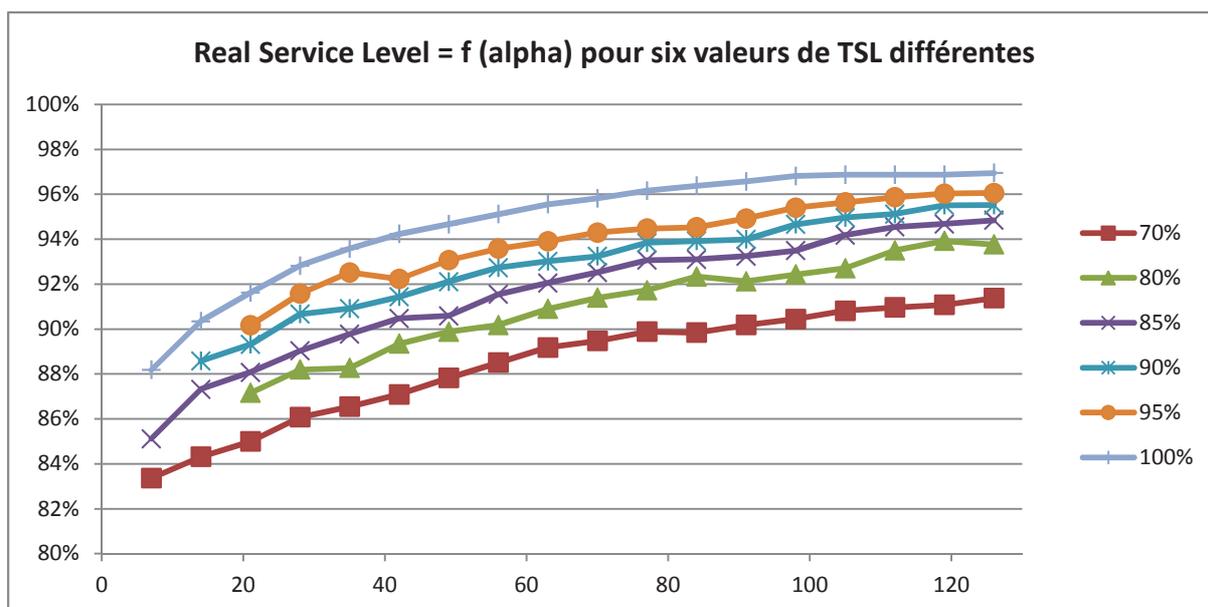


Figure 44: Présentation du niveau de taux de service réel en fonction de α pour six valeurs de TSL

Nous pouvons à partir de ces représentations voir que plus α est grand, plus le niveau de stock physique est important. De la même façon, l'augmentation de α entraîne l'augmentation du taux de service réel. Le paramètre TSL va dans le même sens que α . Son augmentation génère une augmentation du stock physique ainsi qu'une augmentation du taux de service réel (ASL).

La Figure 45 rassemble l'ensemble des résultats présentés dans le Tableau 21. Elle combine la Figure 43 et la Figure 44. Nous pouvons ainsi clairement voir la corrélation entre le niveau de stock et le taux de service réel. Nous pouvons également voir que le taux de service réel (ASL) peut être inférieur ou supérieur au taux de service cible (TSL) selon la valeur du paramètre d'horizon α . Cependant, le taux de service réel de 100% ne peut pas être obtenu de cette façon. Nous pouvons expliquer cela par le fait que nous ne pouvons pas anticiper l'intégralité des erreurs futures en ne

regardant les erreurs passées que sur un horizon fini. Cela explique la tendance asymptotique vers la valeur de $ASL=100\%$ que l'on retrouve en particulier pour les simulations menées avec le TSL de 100%.

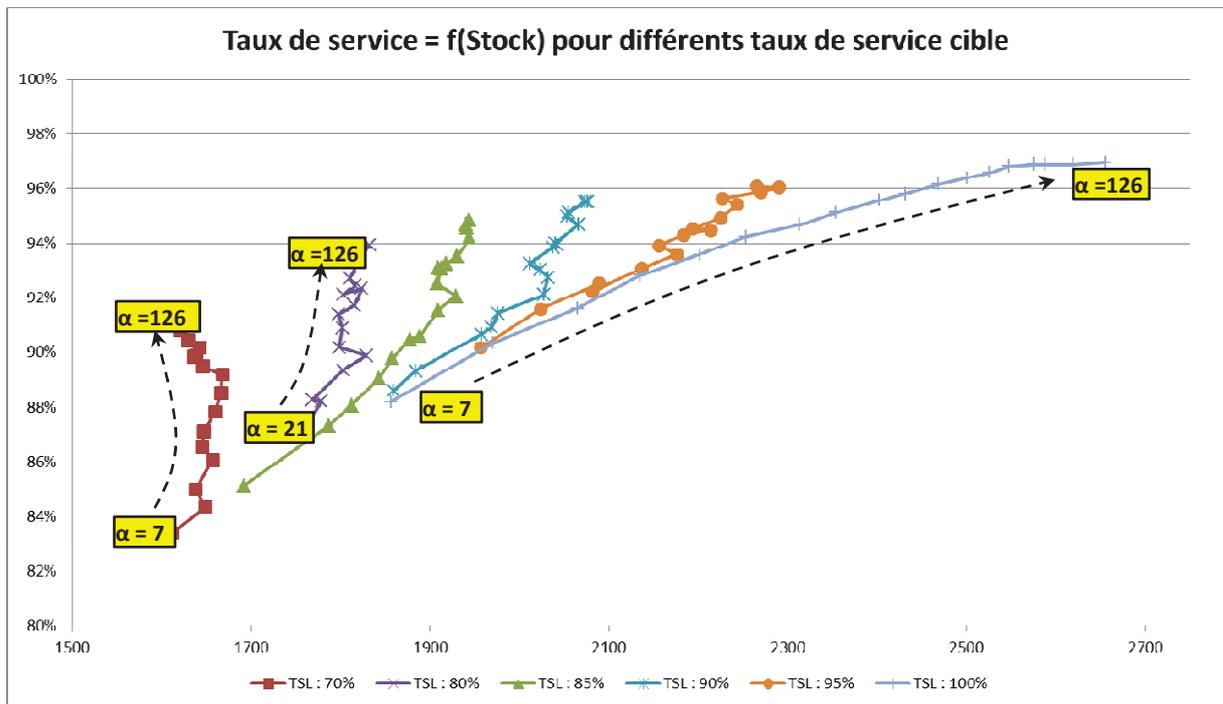


Figure 45: Présentation du niveau du taux de service réel en fonction du niveau du stock physique pour l'ensemble des simulations réalisées

Nous pouvons également voir l'existence d'un compromis à faire entre taux de service réel et niveau de stock. Ce compromis amène à la détermination d'un couple (α, TSL) qui permet de déterminer le niveau du stock de sécurité permettant d'avoir le bon ASL.

La simulation que nous avons réalisée a été validée par l'étude du niveau de stock lorsque la prévision prise en compte était exacte. Dans ces conditions, nous avons bien obtenu un taux de service de 100% avec un niveau de stock nul. En effet, ce cas revient à considérer un cas déterministe où les commandes servent uniquement à répondre aux demandes fermes connues et anticipées.

V. Conclusion

Nous avons ici présenté les objectifs de notre recherche sur le pilotage de flux en Global Sourcing. La sécurisation des approvisionnements est en effet, un des besoins du monde industriel. Nous avons alors présenté notre démarche via la collaboration avec le groupe PSA. Suite à cela, nous avons présenté le modèle HSS (Horizon Safety Stock) avec la description de ses paramètres. Les résultats de simulation ont ensuite été présentés afin de voir les apports qu'offrait ce modèle que ce soit en termes de lissage de la variation du stock ou en termes de niveau de service obtenu ou encore en termes de niveau moyen de stock. Nous allons maintenant présenter le mode de fonctionnement de notre partenaire industriel PSA en ce qui concerne son pilotage de flux en Global Sourcing avant de comparer les résultats obtenus par notre méthode vis-à-vis des autres politiques.

Tableau 21: Présentation des résultats des simulations pour le modèle HSS

Paramètre de TSL	Paramètre d'horizon α	7	14	21	28	35	42	49	56	63	70	77	84	91	98	105	112	119	126
70%	Stock - modèle HSS	1611	1649	1638	1657	1645	1647	1660	1666	1668	1647	1639	1636	1643	1629	1621	1621	1613	1611
	ASL	83%	84%	85%	86%	87%	87%	88%	89%	89%	89%	90%	90%	90%	90%	91%	91%	91%	91%
	ATSL	71%	71%	71%	71%	71%	71%	71%	71%	71%	71%	70%	70%	70%	70%	70%	70%	71%	71%
80%	Stock - modèle HSS			1757	1779	1769	1803	1829	1799	1802	1798	1816	1824	1803	1816	1810	1822	1833	1816
	ASL			87%	88%	88%	89%	90%	90%	91%	91%	92%	92%	92%	92%	93%	93%	94%	94%
	ATSL			81%	82%	80%	81%	82%	80%	81%	80%	81%	81%	80%	81%	80%	80%	81%	80%
85%	Stock - modèle HSS	1692	1787	1812	1843	1858	1877	1889	1909	1929	1908	1913	1909	1918	1930	1944	1941	1941	1944
	ASL	85%	87%	88%	89%	90%	90%	91%	92%	92%	93%	93%	93%	93%	93%	94%	95%	95%	95%
	ATSL	86%	86%	86%	86%	86%	86%	86%	86%	86%	86%	86%	86%	86%	86%	86%	86%	86%	86%
90%	Stock - modèle HSS		1859	1884	1958	1969	1976	2027	2032	2024	2012	2038	2042	2040	2066	2054	2055	2073	2076
	ASL		89%	89%	91%	91%	91%	92%	93%	93%	93%	94%	94%	94%	95%	95%	95%	96%	96%
	ATSL		93%	90%	93%	91%	90%	92%	91%	90%	90%	91%	90%	90%	91%	90%	90%	91%	90%
95%	Stock - modèle HSS		1957	2024	2089	2082	2137	2176	2156	2183	2214	2194	2226	2243	2227	2270	2291	2266	
	ASL		90%	92%	93%	92%	93%	94%	94%	94%	94%	95%	95%	95%	96%	96%	96%	96%	
	ATSL		95%	96%	97%	95%	96%	96%	95%	96%	96%	95%	96%	96%	95%	96%	96%	95%	
100%	Stock - modèle HSS	1856	1970	2065	2135	2202	2254	2313	2354	2402	2432	2469	2501	2526	2548	2576	2588	2619	2655
	ASL	88%	90%	92%	93%	94%	94%	95%	95%	96%	96%	96%	96%	97%	97%	97%	97%	97%	97%
	ATSL	100%	100%	100%	100%	100%	100%	100%	100%	100%	100%	100%	100%	100%	100%	100%	100%	100%	

Application au cas de PSA et comparaison avec les modèles de la littérature.

Dans ce chapitre, nous présentons d'abord la méthode utilisée par PSA pour la sécurisation des flux lointains. Nous comparons ensuite les résultats obtenus par notre méthode, à la fois, à ceux de la littérature et à la méthode de PSA.

I. Méthode de calcul de stock de sécurité utilisée par PSA

Nous allons commencer tout d'abord par décrire la problématique de l'approvisionnement lointain chez PSA. Ensuite nous allons présenter la méthode dichotomique proposée par PSA, qui sert à déterminer un coefficient de flexibilité par semaine pour assurer un taux de service élevé en évitant les ruptures. Par la suite, nous introduisons une méthode de l'incertitude relative cumulée qui est inspirée des modèles de la littérature. Puis nous comparons les deux méthodes. Tous nos calculs sont basés sur l'historique des références d'une usine terminale de PSA.

A. La problématique de l'approvisionnement lointain chez PSA

PSA approvisionne ses pièces chez des fournisseurs répartis dans un réseau mondial avec des délais de réapprovisionnement de 3 à 12 semaines. PSA sépare les problèmes de la sécurisation d'un flux lointain en 2 groupes : la sécurisation de flexibilité des prévisions et la sécurisation des aléas. En fait, la sécurisation de flexibilité des prévisions a pour objectif de traiter la non fiabilité des prévisions, qui est équivalent à l'incertitude prévisionnelle sur la demande que nous avons présentée dans le chapitre 2. Quant à la sécurisation des aléas, ce sont des incertitudes prévisionnelles sur le délai d'approvisionnement et sur la quantité reçue.

Donc, la problématique de l'approvisionnement lointain chez PSA est de trouver une méthode, qui permet de déterminer la quantité à commander au juste nécessaire en assurant un taux de service élevé.

Tous les jours, le besoin prévisionnel ajouté à la somme des besoins prévisionnels déjà approvisionnés sur le lead time permet de déterminer la quantité à approvisionner en le comparant à la somme des demandes prévisionnelles sur le lead time et sur la nouvelle période. La Figure 46 et la Figure 47 nous aident à comprendre la problématique de l'approvisionnement chez PSA.

b : le besoin prévisionnel, c'est le nouveau besoin brut non encore approvisionné. Supposons que nous sommes au jour J, si le délai d'approvisionnement de la pièce est L. On estime que le nombre de pièces nécessaires à la production dans l'usine à J+L est b.

B : la somme des besoins prévisionnels déjà approvisionnés sur le lead time hors J+0.

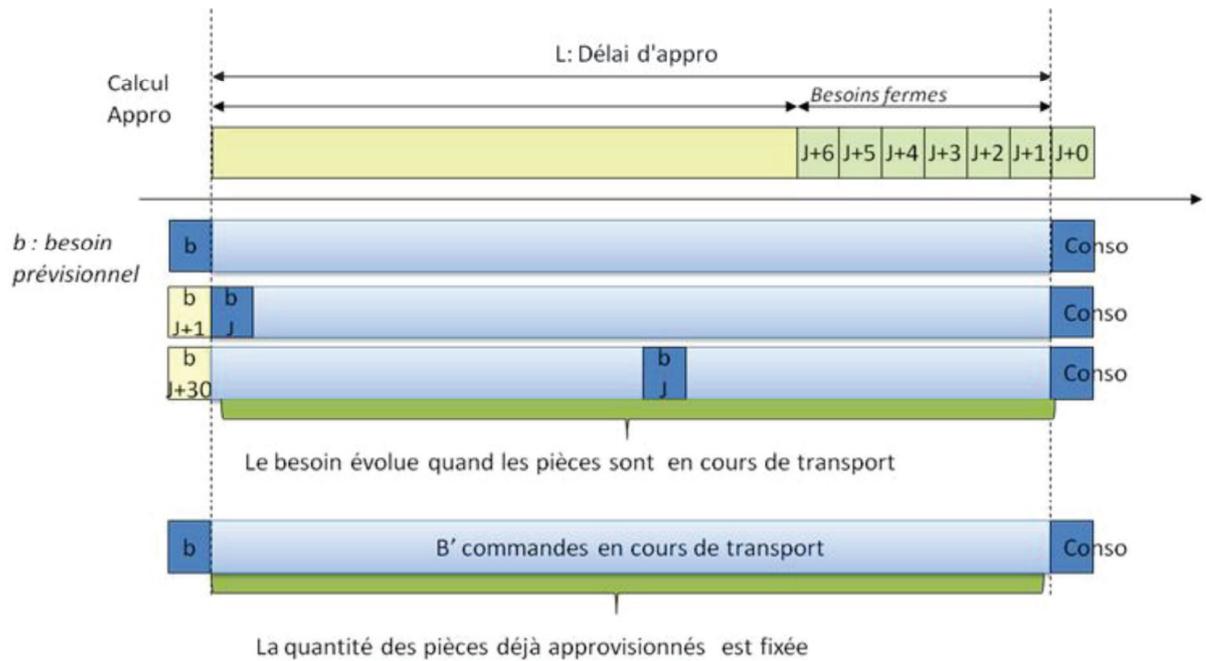


Figure 46: Illustration de la problématique de l'approvisionnement lointain chez PSA

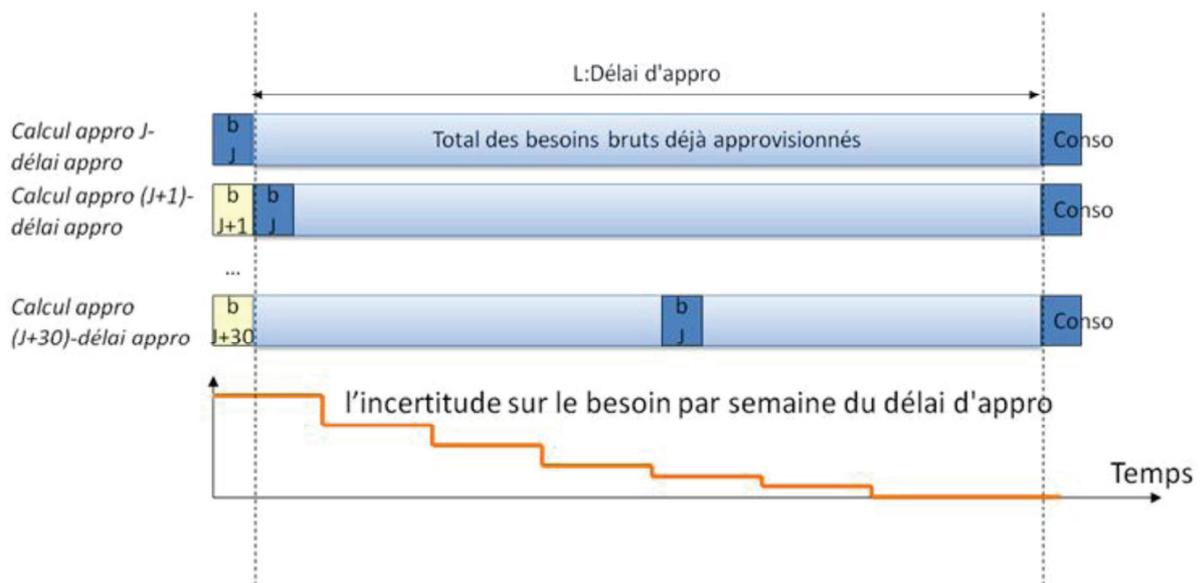


Figure 47: Illustration de l'incertitude sur la demande en approvisionnement lointain chez PSA

En pratique, la fiabilité des prévisions des véhicules et des pièces s’améliore au fil du délai d’approvisionnement, pour avoir une fiabilité de 100% lorsque les prévisions sont figées et transformées en besoins fermes, comme l’illustre la Figure 48.

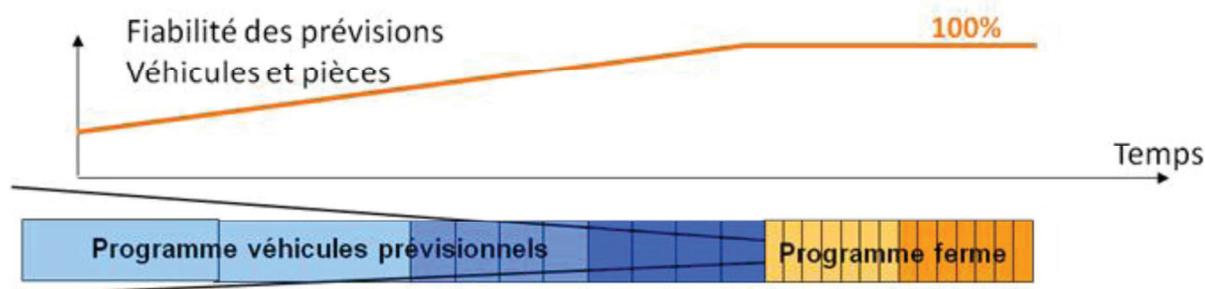


Figure 48: Fiabilité des prévisions

B. Méthodes étudiées

Nous allons présenter la méthode permettant de déterminer le coefficient de flexibilité de l’approvisionnement lointain. Le calcul est basé sur la recherche dichotomique.

Pour expliquer cette méthode, nous introduisons quelques notions.

1. Abaque « C&R »

Afin de calculer le coefficient d’approvisionnement lointain, PSA exploite un abaque industriel appelé « Chêne et Roseau » (C&R) qui définit les engagements de flexibilité entre PSA et ses fournisseurs pour l’approvisionnement des pièces. Cette table a été construite suite à une étude statistique et expérimentale, basée sur un échantillon représentatif de pièces consommées en usine de montage véhicules PSA sur une période de plusieurs mois.

Dans cet abaque, nous pouvons trouver la quantité maximale que nous pouvons appeler chez les fournisseurs à partir de la consommation moyenne journalière. Un extrait de l’abaque C&R est montré ci-dessous.

Tableau 22: Extrait de l'abaque C&R de PSA

Journalier			Hebdomadaire		
CMJ/K	Maxi J/K	Mini J/K	CMJ/K	Maxi J/K	Mini J/K
0	0	0	0	0	0
1	10	0	1	23	0
2	14	0	2	35	0
3	17	0	3	45	0
4	20	0	4	54	0
5	23	0	5	63	0
6	25	0	6	72	0
7	28	0	7	80	0
8	30	0	8	88	0
9	32	0	9	96	0
10	35	0	10	103	0
11	37	0	11	111	0
...
2000	2297	1703	2000	10308	9692

2. Coefficient de consommation K

Le coefficient de consommation d'une pièce est une pondération des coefficients de montage en fonction des volumes de production. Nous prenons un exemple pour montrer son calcul : La référence A est utilisée sur le véhicule X avec un coefficient de montage de 2. La même référence est utilisée sur le véhicule Y avec un coefficient de montage de 1. En sachant que le véhicule X est produit à 100 exemplaires par jour et que le véhicule Y est produit à 150 véhicules par jour, le coefficient de consommation de la référence A est : $2 * 40\% + 1 * 60\% = 0,8 + 0,6 = 1,4$.

3. Etapes de calcul du coefficient de flexibilité

Etape 1: Recherche du coefficient de flexibilité basé sur l'historique

L'objectif de cette étape est de fournir à l'approvisionnement un indicateur sur le niveau de sécurisation à mettre en place au juste nécessaire, vis-à-vis des variations de besoins sur le délai d'approvisionnement.

Ce coefficient de flexibilité est basé sur la réalité mesurée des fluctuations entre la quantité prévisionnelle et la consommation réelle. Il se base sur un historique des besoins pièces à N jours et le besoin ferme réel qui correspond à la consommation.

- Données en entrée de l'étape 1 : Historique (besoins bruts sur le délai d'approvisionnement, consommation réelle) pour couvrir le délai d'approvisionnement.
- Traitement : Le coefficient de flexibilité ou « Indicateur de sécurisation flexibilité » d'une référence sur un horizon de temps (délai d'approvisionnement entre l'appel et la nouvelle journée de consommation) est la plus petite valeur qui permette de sécuriser le flux, c'est à dire la valeur qui peut absorber les fluctuations sur cet horizon, sans rupture (ou rester en deçà d'un seuil de rupture jugé acceptable), avec un stock résultant le plus faible.

Chaque semaine, le calcul utilise un horizon glissant de 3 semaines glissantes de couples « besoin prévisionnel / consommation réelle », et calculera un stock théorique pour la sécurisation. Ce niveau est calculé par une méthode dichotomique jusqu'à l'obtention du niveau de sécurisation permettant d'éviter les ruptures. Cet indicateur est calculé à la référence, pour une usine donnée.

La Figure 49 représente le principe du calcul du coefficient. Nous considérons que les besoins sont fermes dans la semaine de consommation (entre J+0 et J+6). Pour un délai d'approvisionnement de N jours, nous avons des prévisions de J+7 jusqu'à J+N qui sont faites quotidiennement à la maille jour. Ces prévisions évoluent dans le temps et sont représentées par les cases bleues.

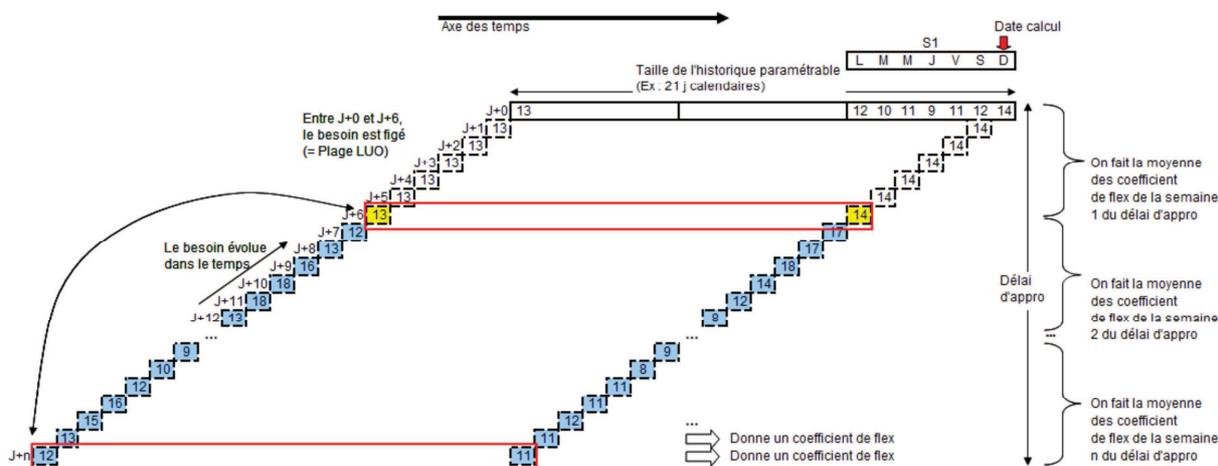


Figure 49: Illustration du calcul de coefficient de flexibilité

L'idée est de trouver un coefficient pour sécuriser l'écart entre ces prévisions et la quantité réelle à consommer. Le calcul se fait chaque jour durant le délai d'approvisionnement sur une taille de l'historique de trois semaines. Nous faisons par la suite la moyenne des valeurs des coefficients par semaine pour déterminer un coefficient hebdomadaire. L'exploitation efficace de la mesure par l'approvisionnement nécessite un historique minimum de 6 mois des coefficients calculés.

Afin de déterminer la valeur du coefficient de flexibilité, nous remplaçons dans l'abaque C&R la CMJ (Consommation Moyenne Journalière) par la valeur de prévision b. Pour la valeur b/K, on trouve la valeur C&R. La valeur C&R multiplié par le coefficient de consommation K est soustraite au besoin prévisionnel, le tout est multiplié par le coefficient de flexibilité et cela constitue la quantité de pièces à ajouter pour sécuriser la flexibilité d'un flux lointain.

Supposons que F est le coefficient de flexibilité, le calcul des pièces à rajouter à la prévision sous formule mathématique est : $[C\&R (b/K)*K-b]*F$.

Un exemple numérique illustre en détail ces étapes de calcul. La colonne « Besoin LUO » présente les besoins réels au jour de consommation dans l'usine. Dans les colonnes suivantes, nous trouvons les besoins prévisionnels et le coefficient de consommation. Après avoir calculé les quantités à ajouter aux prévisions, nous obtenons l'évolution du stock dans la dernière colonne. Comme l'illustration dans le Tableau 23, nous essayons avec un coefficient 0,125 en supposant que le stock initial est nul, et nous ne constatons pas de rupture de stock.

Tableau 23: Exemple 1 pour le calcul du coefficient de flexibilité

	Détail du calcul			Stock init		0		coeff		0,125		
	Besoin LUO	Besoin	Coef	Besoin/K	C&R	C&R x K	C&R - Besoin	x Coef	Besoin sécuris	Besoin + C&R - LUO + Stock		
lundi 2 juin 2008	192	200	2	100	175	350	150	19	219	27		
mardi 3 juin 2008	184	199	2	100	175	350	151	19	218	61		
mercredi 4 juin 2008	184	199	2	100	175	350	151	19	218	95		
jeudi 5 juin 2008	184	199	2	100	175	350	151	19	218	129		
vendredi 6 juin 2008	184	199	2	100	175	350	151	19	218	163		
samedi 7 juin 2008	148	0	2	0	0	0	0	0	0	15		
dimanche 8 juin 2008	0	0	2	0	0	0	0	0	0	15		
lundi 9 juin 2008	192	245	2	123	207	414	169	22	267	90		
mardi 10 juin 2008	184	245	2	123	207	414	169	22	267	173		
mercredi 11 juin 2008	184	245	2	123	207	414	169	22	267	256		
jeudi 12 juin 2008	184	245	2	123	207	414	169	22	267	339		
vendredi 13 juin 2008	184	244	2	122	205	410	166	21	265	420		
samedi 14 juin 2008	148	0	2	0	0	0	0	0	0	272		
dimanche 15 juin 2008	0	0	2	0	0	0	0	0	0	272		
lundi 16 juin 2008	192	0	2	0	0	0	0	0	0	80		
mardi 17 juin 2008	184	222	2	111	191	382	160	20	242	138		
mercredi 18 juin 2008	184	220	2	110	189	378	158	20	240	194		
jeudi 19 juin 2008	184	222	2	111	191	382	160	20	242	252		
vendredi 20 juin 2008	184	220	2	110	189	378	158	20	240	308		
samedi 21 juin 2008	158	0	2	0	0	0	0	0	0	150		
dimanche 22 juin 2008	0	0	2	0	0	0	0	0	0	150		

Au contraire, si nous faisons le calcul avec les mêmes données des besoins prévisionnels et des besoins réels, avec un coefficient d'une valeur de 0,0625, nous constatons une rupture du stock (Besoin + C&R + LUO + Stock < 0) comme on le voit dans le Tableau 24. Donc, le coefficient 0,0625 est considéré comme un coefficient trop faible.

Tableau 24: Exemple 2 pour le calcul du coefficient de flexibilité

	Détail du calcul			Stock init		0		coeff			0,063
	Besoin LUO	Besoin	Coef	Besoin/K	C&R	C&R x K	C&R - Besoin	x Coef	Besoin sécuris	Besoin + C&R - LUO + Stock	
lundi 2 juin 2008	192	200	2	100	175	350	150	10	210	18	
mardi 3 juin 2008	184	199	2	100	175	350	151	10	209	43	
mercredi 4 juin 2008	184	199	2	100	175	350	151	10	209	68	
jeudi 5 juin 2008	184	199	2	100	175	350	151	10	209	93	
vendredi 6 juin 2008	184	199	2	100	175	350	151	10	209	118	
samedi 7 juin 2008	148	0	2	0	0	0	0	0	0	-30	
dimanche 8 juin 2008	0	0	2	0	0	0	0	0	0	-30	
lundi 9 juin 2008	192	245	2	123	207	414	169	11	256	34	
mardi 10 juin 2008	184	245	2	123	207	414	169	11	256	106	
mercredi 11 juin 2008	184	245	2	123	207	414	169	11	256	178	
jeudi 12 juin 2008	184	245	2	123	207	414	169	11	256	250	
vendredi 13 juin 2008	184	244	2	122	205	410	166	11	255	321	
samedi 14 juin 2008	148	0	2	0	0	0	0	0	0	173	
dimanche 15 juin 2008	0	0	2	0	0	0	0	0	0	173	
lundi 16 juin 2008	192	0	2	0	0	0	0	0	0	-19	
mardi 17 juin 2008	184	222	2	111	191	382	160	10	232	29	
mercredi 18 juin 2008	184	220	2	110	189	378	158	10	230	75	
jeudi 19 juin 2008	184	222	2	111	191	382	160	10	232	123	
vendredi 20 juin 2008	184	220	2	110	189	378	158	10	230	169	
samedi 21 juin 2008	158	0	2	0	0	0	0	0	0	11	
dimanche 22 juin 2008	0	0	2	0	0	0	0	0	0	11	

Le coefficient final est calculé par la moyenne des coefficients journaliers sur la semaine. Ce calcul se fait sur un historique de trois semaines glissantes.

- Recherche dichotomique

Afin d'effectuer une recherche relativement rapide du coefficient de sécurisation, une méthode de recherche par dichotomie est utilisée permettant, à chaque étape, de réduire l'espace de recherche de moitié comme l'illustre la Figure 50. Cette recherche permettra de trouver le plus petit coefficient tel que les valeurs de la colonne de droite du Tableau 23 (Besoin + C&R – LUO + Stock) soient supérieures ou égales à 0.

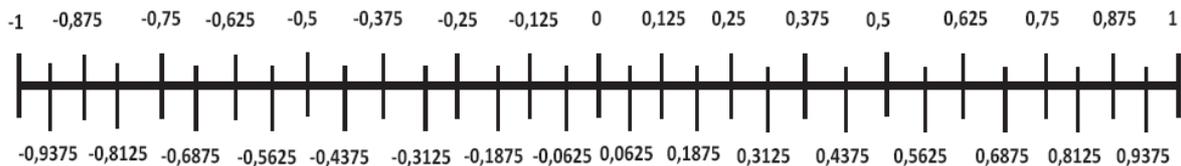


Figure 50: recherche dichotomique

Etape 2: Choix d'un coefficient par l'approvisionnement

La méthode décrite précédemment, permet pour chaque pièce d'avoir un ensemble de coefficients de flexibilité hebdomadaires s'étalant sur l'horizon J+6 à J+L ou L est le délai d'approvisionnement. Ces coefficients sont proposés à l'approvisionneur afin de l'aider dans le choix du bon coefficient de flexibilité. Ce dernier valide les valeurs proposées par le système ou saisie manuellement de nouvelles valeurs qui lui semblent plus appropriées.

Etape 3: Application du coefficient sur un besoin brut lors du calcul d'approvisionnement

Une fois qu'un coefficient a été validé par semaine du délai d'approvisionnement, il est utilisé pour le calcul d'approvisionnement

II. Comparaison avec le modèle proposé

Nous allons maintenant comparer le modèle que nous avons proposé avec la politique de gestion des stocks classique (T,s). Nous comparerons également notre modèle avec les politiques de gestion

des stocks basées sur les prévisions et développées par (Babai *et al.* 2009) de type (T, s_k) . Nous confronterons enfin notre modèle à la méthode empirique utilisée par notre partenaire industriel.

Comme pour l'obtention des résultats théoriques, nous avons réalisé des simulations sur les échantillons de données réelles dont nous disposons. Nous avons appliqué la politique (T, s) avec comme période $T=1$. Les résultats ont été comparés à ceux obtenus par notre partenaire et aux nôtres.

A. Comparaison entre la méthode HSS et la politique (T, s)

La comparaison entre la politique (T, s) et l'ensemble des autres méthodes de gestion des stocks est sans équivoque. Les paramètres utilisés sont une période de révision de 1 ($T=1$) de façon à coller aux contraintes industrielles intégrées dans notre modèle à savoir une commande quotidienne. Nous avons défini le paramètre de stock S de la façon suivante :

$$S = m \cdot (L + 1) + SS$$

où

m est la demande moyenne par jour

L est le délai d'approvisionnement

$SS = \Phi^{-1}(TSL) \cdot \sigma_D \cdot \sqrt{(L + 1)}$ est le stock de sécurité où TSL est le taux de service cible, $\Phi^{-1}(TSL)$ est la fonction inverse de la loi normale centrée réduite et σ_D est l'écart-type de la demande journalière.

La loi de la demande est calculée sur un horizon de 49 jours (7 semaines).

Suite aux simulations sur un échantillon de 30 produits sur un horizon temporel de plus de 3 ans à la maille quotidienne, nous obtenons la Figure 51 représentant l'évolution du stock pour un taux de service cible allant de 50% à 99%. Le stock physique moyen évolue lui de 1300 unités ($TSL=50\%$, $ASL=60\%$) à près de 140 000 unités ($TSL=99\%$, $ASL=100\%$).

La comparaison entre les résultats obtenus avec le modèle (T, s) et le modèle HSS est proposée dans la Figure 52. Nous y voyons clairement l'avantage du modèle HSS sur le modèle (T, s) . En effet,

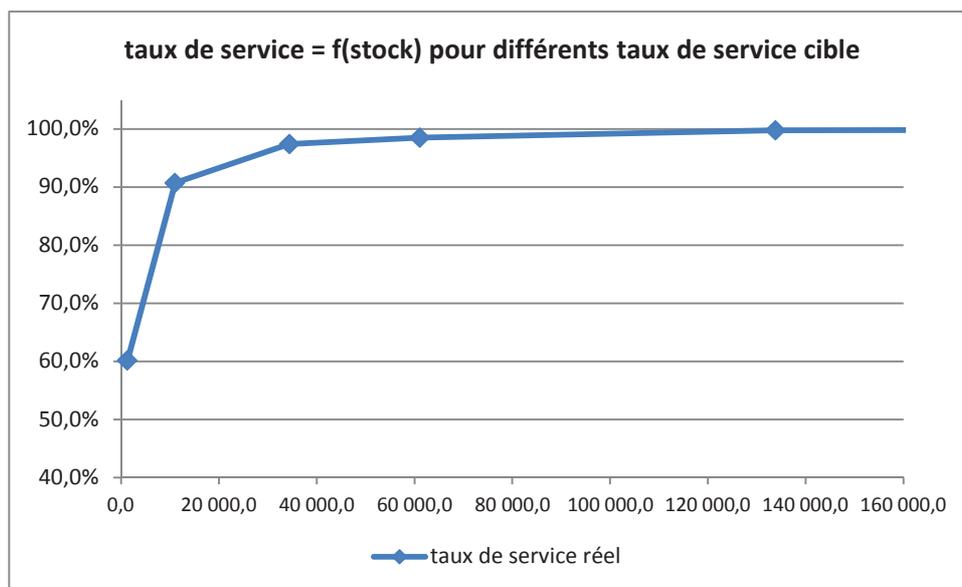


Figure 51: Présentation du taux de service réel et du stock physique moyen pour différents taux de service cible (50% à 99%) pour le modèle (T, s)

pour un taux de service réel identique de 95%, le stock physique est divisé par six en passant d'environ 25 000 à moins de 4 000.

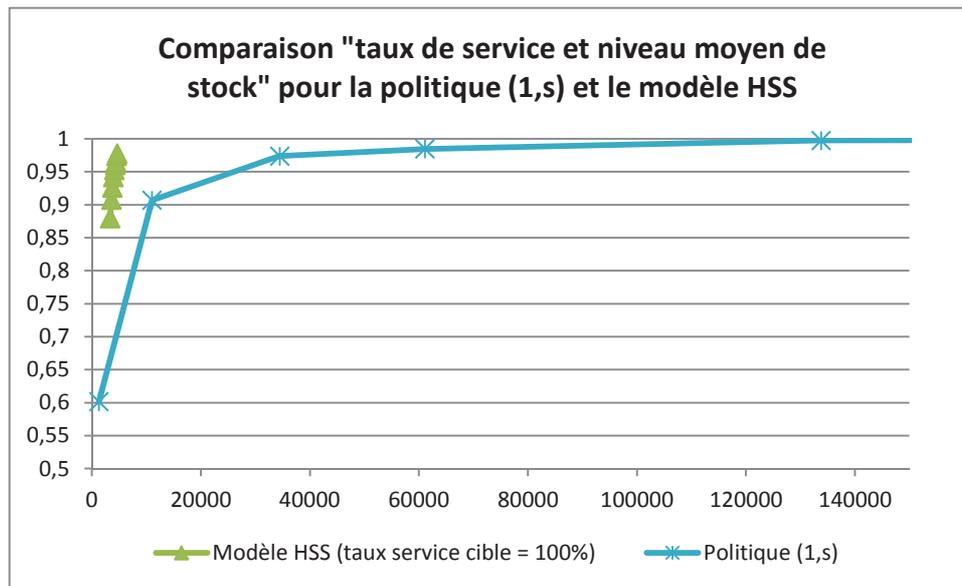


Figure 52: Comparaison "Taux de service et niveau moyen de stock" pour la politique (1,s) et le modèle HSS

Cette analyse montre que la politique (T, s) n'est pas applicable dans le pilotage de flux dans le cas des approvisionnements lointains du fait de la variabilité de la demande qui augmente considérablement avec le délai long de réapprovisionnement.

B. Comparaison politique industrielle

Selon les paramètres de sécurisation utilisés dans notre modèle (paramètre d'horizon de sécurisation et paramètre de taux de service cible), nous pouvons obtenir un taux de service variant de 60 à 100%. Nous pouvons alors comparer nos résultats avec ceux de PSA en se fixant comme minimum de taux de service, celui obtenu par PSA à savoir 96,2% en moyenne sur l'échantillon étudié. Pour ce taux de service et pour des taux supérieurs, nous obtenons un niveau de stock très inférieurs à ceux de PSA. Les niveaux obtenus sont en moyenne 80% inférieurs. C'est là l'un des apports principaux de notre travail. Nous présentons ces résultats en détails dans la suite.

Les cas permettant d'obtenir un taux de service supérieur à celui obtenu par notre partenaire (96,2%) sont les suivants : Il faut choisir comme paramètre d'horizon de sécurisation, une valeur supérieure à 84 jours (ce qui représente environ 12 semaines ou 3 mois) ainsi qu'un taux de service cible de 100%.

Le détail des différences entre les résultats du modèle industriel et les différentes variantes de notre modèle HSS selon les paramètres « Taux de service cible » et « Horizon de sécurisation » sont présentés dans le Tableau 25. La principale différence concerne le de niveau de stock. Notre modèle, selon les paramètres utilisés permet de réduire ce niveau de 75 à 85%, en limitant la dégradation du taux de service à 13% au maximum et en l'améliorant de 1% dans le meilleur des cas.

Tableau 25: Comparaison des niveaux de stock et du Taux de Service du modèle HSS par rapport au modèle industriel

Paramètre de taux de service cible	Paramètre d'horizon de sécurisation	7	14	21	28	35	42	49	56	63	70	77	84	91	98	105	112	119	126	
60%	Stock - Modèle HSS		-85%	-85%	-85%	-85%	-85%	-86%	-86%	-86%	-86%	-86%	-86%	-86%	-86%	-86%	-86%	-86%	-87%	
	Taux de Service		-13%	-13%	-13%	-13%	-12%	-11%	-10%	-9%	-9%	-9%	-9%	-9%	-9%	-9%	-9%	-8%	-8%	-8%
70%	Stock - Modèle HSS	-85%	-84%	-84%	-84%	-84%	-84%	-84%	-84%	-84%	-84%	-84%	-84%	-84%	-84%	-84%	-85%	-85%	-85%	-85%
	Taux de Service	-13%	-12%	-12%	-11%	-10%	-9%	-9%	-8%	-7%	-7%	-7%	-7%	-7%	-6%	-6%	-6%	-5%	-5%	-5%
80%	Stock - Modèle HSS			-83%	-83%	-83%	-83%	-83%	-83%	-83%	-83%	-83%	-83%	-83%	-83%	-83%	-83%	-83%	-83%	-83%
	Taux de Service			-9%	-8%	-8%	-7%	-7%	-6%	-6%	-5%	-5%	-4%	-4%	-4%	-4%	-4%	-3%	-2%	-3%
85%	Stock - Modèle HSS	-84%	-83%	-83%	-82%	-82%	-82%	-82%	-82%	-82%	-82%	-82%	-82%	-82%	-82%	-82%	-81%	-81%	-81%	-81%
	Taux de Service	-12%	-9%	-8%	-7%	-7%	-6%	-6%	-5%	-4%	-4%	-3%	-3%	-3%	-3%	-3%	-2%	-2%	-2%	-1%
90%	Stock - Modèle HSS		-82%	-82%	-81%	-81%	-81%	-81%	-81%	-81%	-81%	-81%	-81%	-81%	-81%	-80%	-80%	-80%	-80%	-80%
	Taux de Service		-8%	-7%	-6%	-5%	-5%	-4%	-4%	-3%	-3%	-2%	-2%	-2%	-2%	-2%	-1%	-1%	-1%	-1%
95%	Stock - Modèle HSS			-81%	-81%	-80%	-80%	-80%	-79%	-79%	-79%	-79%	-79%	-79%	-79%	-79%	-79%	-78%	-78%	-78%
	Taux de Service			-6%	-5%	-4%	-4%	-3%	-3%	-2%	-2%	-2%	-2%	-2%	-1%	-1%	-1%	0%	0%	0%
100%	Stock - Modèle HSS	-82%	-81%	-80%	-80%	-79%	-79%	-78%	-78%	-77%	-77%	-76%	-76%	-76%	-76%	-75%	-75%	-75%	-75%	-75%
	Taux de Service	-8%	-6%	-5%	-4%	-3%	-2%	-2%	-1%	-1%	0%	0%	0%	0%	0%	1%	1%	1%	1%	1%

La Figure 53 présente les résultats du modèle industriel et du modèle HSS avec 27 jeux de paramètres différents. Le paramètre de Taux de service cible varie de 80% à 100% tandis que le paramètre d'horizon de sécurisation varie de 14 jours à 112 jours.

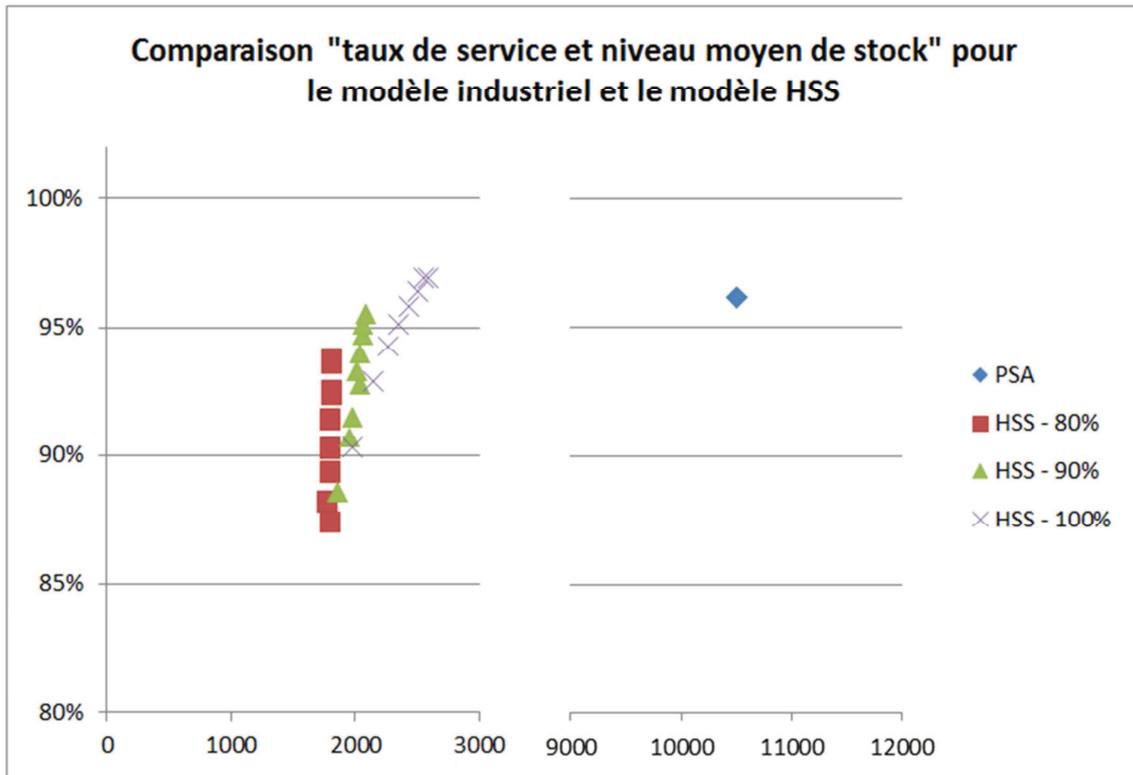


Figure 53: Comparaison "taux de service et niveau moyen de stock" pour le modèle industriel et le modèle HSS

La Figure 54 illustre les gains du modèle HSS par rapport aux résultats de notre partenaire pour les niveaux de stocks. Nous y voyons que le gain va de 74% à 86% pour les cas étudiés.

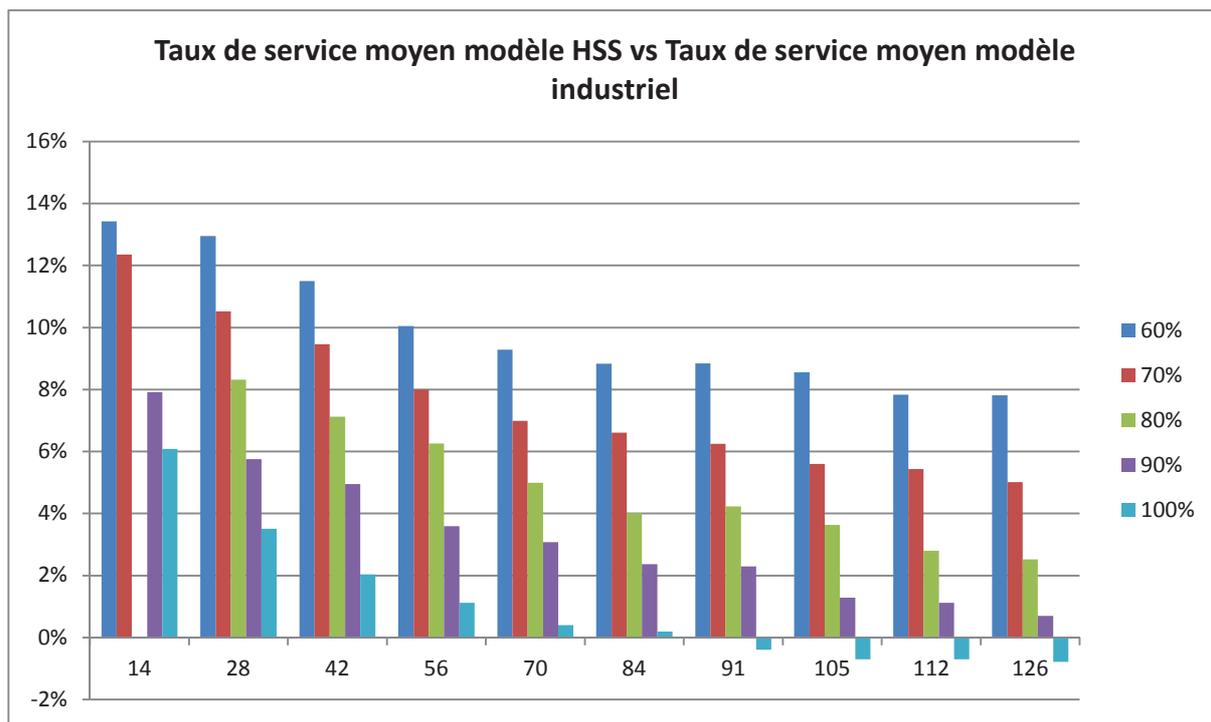


Figure 54: Stock moyen modèle HSS vs Stock moyen modèle industriel

La Figure 55 présente la comparaison entre le modèle HSS et les résultats de notre partenaire pour le taux de service réel. Nous voyons que notre modèle HSS induit un taux de service réel diminué de 13% dans le moins bon des cas simulés tandis qu'il améliore le taux de service réel de 1% dans le meilleur des cas qui correspond à la diminution du niveau moyen de stock de 74%.

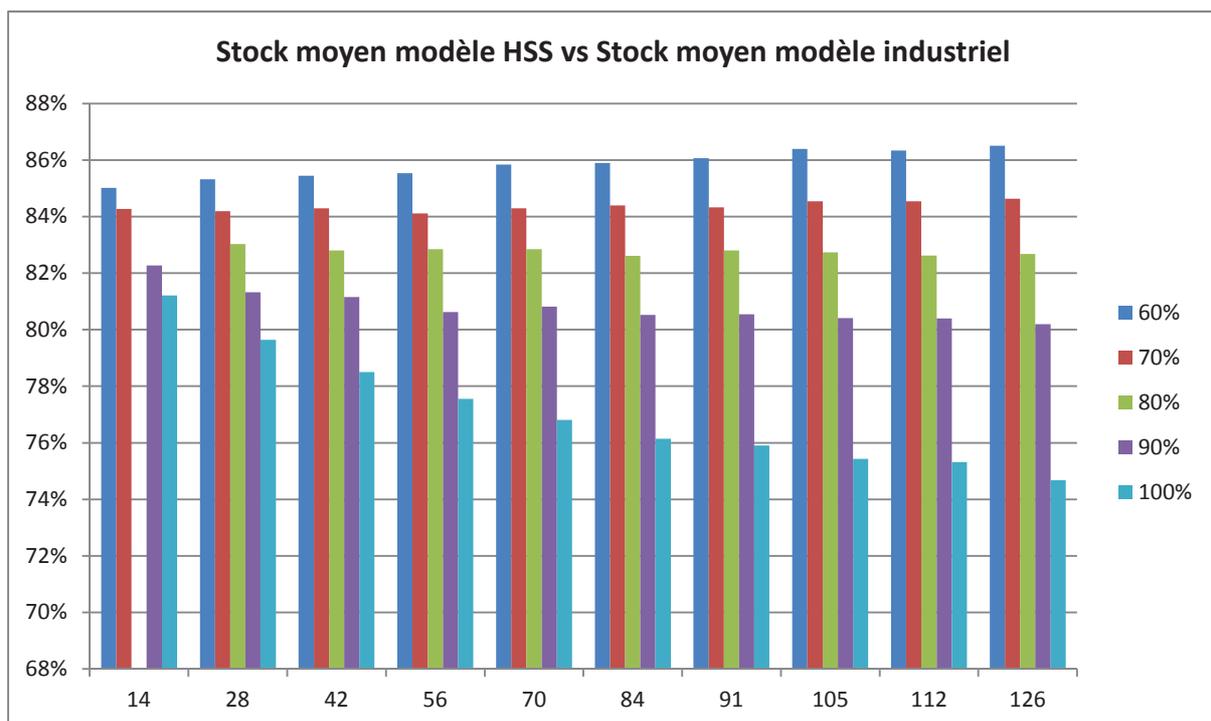


Figure 55: Taux de service moyen modèle HSS vs Taux de service moyen modèle industriel

C. Comparaison entre la méthode HSS et la politique (T,s_k)

La comparaison entre la politique (T,s_k) proposée par (Babai & Dallery 2009) et le modèle que nous proposons a également été réalisée. Comme pour les comparaisons précédentes, une simulation de gestion des stocks sur un échantillon de 30 produits sur un historique de plus de 3 ans avec les demandes réelles et les prévisions industrielles comme données d'entrées a été réalisée.

Les paramètres utilisés pour cette politique de gestion de stock sont les suivants :

Une période de révision de 1 (T=1) de façon à coller aux contraintes industrielles intégrées dans notre modèle à savoir une commande quotidienne.

Un stock défini par $S = m.(L+1) + SS$

où

m est la demande moyenne par jour

L est le délai d'approvisionnement (49 jours)

$SS = \Theta^{-1}(TSL; 0; \sigma_D)$ est le stock de sécurité où *TSL* est le taux de service cible, $\Theta^{-1}(TSL; 0; \sigma_D)$ est la fonction inverse de la loi normale et σ_D est l'écart-type de l'erreur de prévision additive cumulative sur T+L.

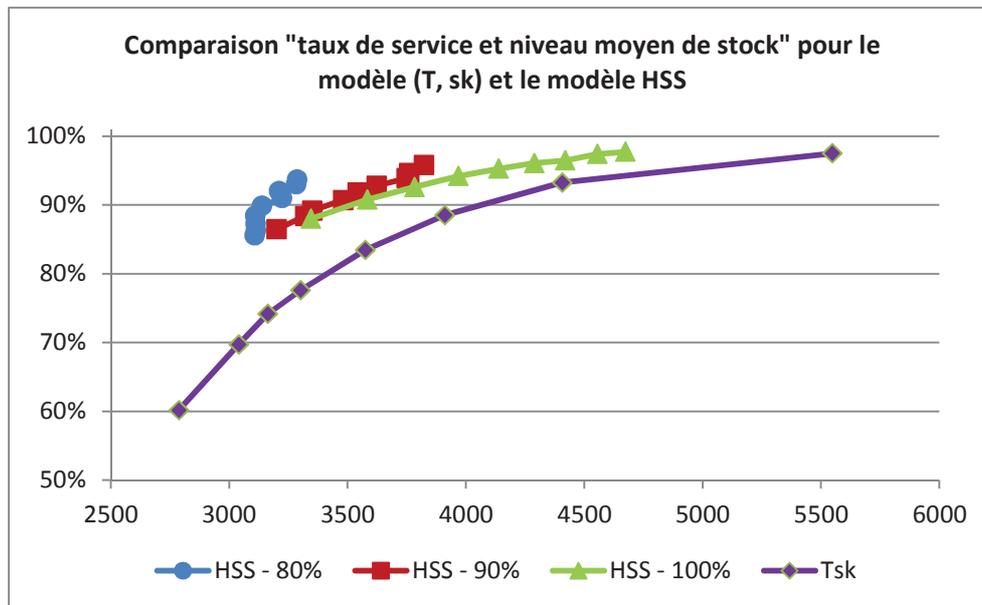


Figure 56: Comparaison "taux de service et niveau moyen de stock" pour le modèle (T,s_k) et le modèle HSS

Différents niveaux de sécurisations cibles ont été testés avec cette politique en partant d'un taux de service de 50% pour aller jusqu'à 99,9%. Comme on peut le voir sur la Figure 56, la politique (T,s_k) permet d'avoir de bons résultats mais ils ne sont jamais supérieurs à ceux obtenus par la méthode HSS. À taux de service égal, le niveau de stock de la politique (T,s_k) est supérieur d'environ 15%. Une raison à ce niveau de stock supérieur est le délai d'approvisionnement élevé conjugué à une forte variation de la qualité de prévision. En effet, l'erreur cumulative qui est la différence entre la somme des commandes pour les L périodes à venir (L=Lead-Time) et la somme des demandes sur les mêmes L périodes est très variable. Il en découle un niveau de stock plus élevé par la méthode (T, s_k). De plus, notre méthode se base sur les données empiriques réelles et actualisées des prévisions tandis que la méthode (T, s_k) s'appuie sur la loi normale sans réactualisation de la prévision. Cette prise en compte plus rapide et plus exacte des données permet d'améliorer le niveau du stock de sécurité pour coller au mieux aux besoins de sécurisations.

III. Réalisation d'un outil de simulation de gestion des stocks à destination de l'industrie

Suite à ces travaux, nous avons développé un outil d'aide à la décision à destination PSA. Cet outil basé sur un fichier Excel permet de simuler la gestion des stocks pour un profil de demande qui peut être générée ou récupérée via un historique de données.

Le but de cet outil est de pouvoir définir les paramètres de sécurisation du modèle HSS en fonction du profil de demande du produit à sécuriser. Le principal intérêt est de pouvoir faire varier différents paramètres tels que le profil de la demande, l'évolution de la qualité des prévisions, et les paramètres de sécurisation à prendre en compte. En effet, les paramètres de sécurisation peuvent évoluer en fonction du profil de la demande de façon à avoir à tout moment le meilleur compromis stock / taux de service. En effet, selon que la demande est croissante, décroissante, lisse ou variable, les résultats de sécurisation ne sont pas équivalents.

A. Présentation des paramètres variables

1. La demande

La possibilité de tester différents profils de demande et voir l'effet sur les paramètres de sécurisation est un des points forts de notre outil. En effet, celui-ci permet de générer des profils de demande différents. Le taux de croissance peut être défini, le niveau de la demande également tout comme la variabilité de la demande. Ceci permet de simuler la gestion des stocks par anticipation en fonction de l'évolution prévue de la demande. La Figure 57 présente trois types de demandes différentes.

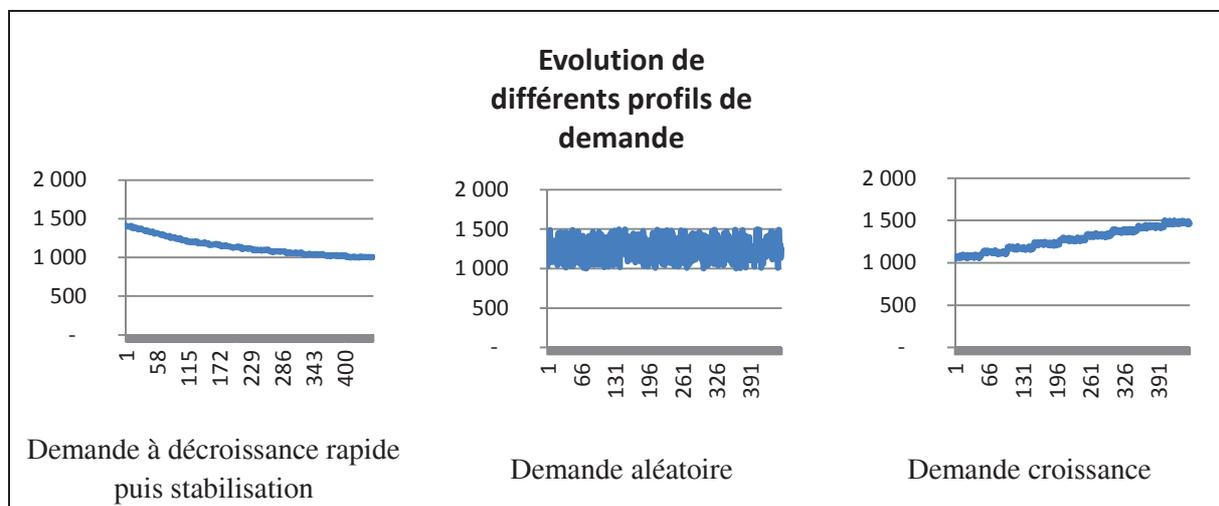


Figure 57: Présentation de différents profils d'évolution de demande

2. Modèles de prévision :

Afin d'avoir une flexibilité supplémentaire à l'outil de simulation, nous avons offert la possibilité de simuler la gestion des stocks avec différents profils d'évolution des prévisions. En effet, la qualité des prévisions est un des paramètres important du niveau de stock étant donné que le stock de sécurité va s'adapter en fonction de l'erreur de prévision cumulative. Nous avons donc intégré la possibilité de générer des prévisions de plus ou moins bonne qualité. L'évolution de la qualité est définie selon le modèle que nous avons proposé dans le chapitre 2 à savoir le modèle évolutif basé sur une loi exponentielle.

3. Délai d'approvisionnement

Afin d'avoir un outil de simulation s'adaptant au plus grand nombre de cas possibles, la modification du délai d'approvisionnement est possible. Le calcul des approvisionnements et de la sécurisation des flux va prendre en compte ce nouveau délai d'approvisionnement. Ainsi, l'étude du compromis entre le coût et le délai de transport et le coût du stock pourra être réalisée.

4. Paramètres du modèle HSS

Enfin, concernant la gestion des stocks à proprement parler, les deux paramètres sont également modifiables. Ainsi, le paramètre d'horizon de sécurisation (α) peut être choisi tout comme le taux de service cible (TSL). Nous allons ainsi pouvoir faire varier ces paramètres afin de pouvoir comparer les résultats obtenus et ainsi déterminer la meilleure sécurisation à mettre en place.

B. Présentation des résultats de simulation

Nous allons ici présenter des résultats de simulation qui nous permettent de donner des recommandations de sécurisation en fonction du type de demande. Pour ces simulations, nous avons donc fait varier la demande et les paramètres de sécurisation tout en gardant le modèle de prévision fixe ainsi que le délai d'approvisionnement fixé à 49 jours.

1. Effet de la variation de α pour une demande stationnaire entre 500 et 1000 pièces

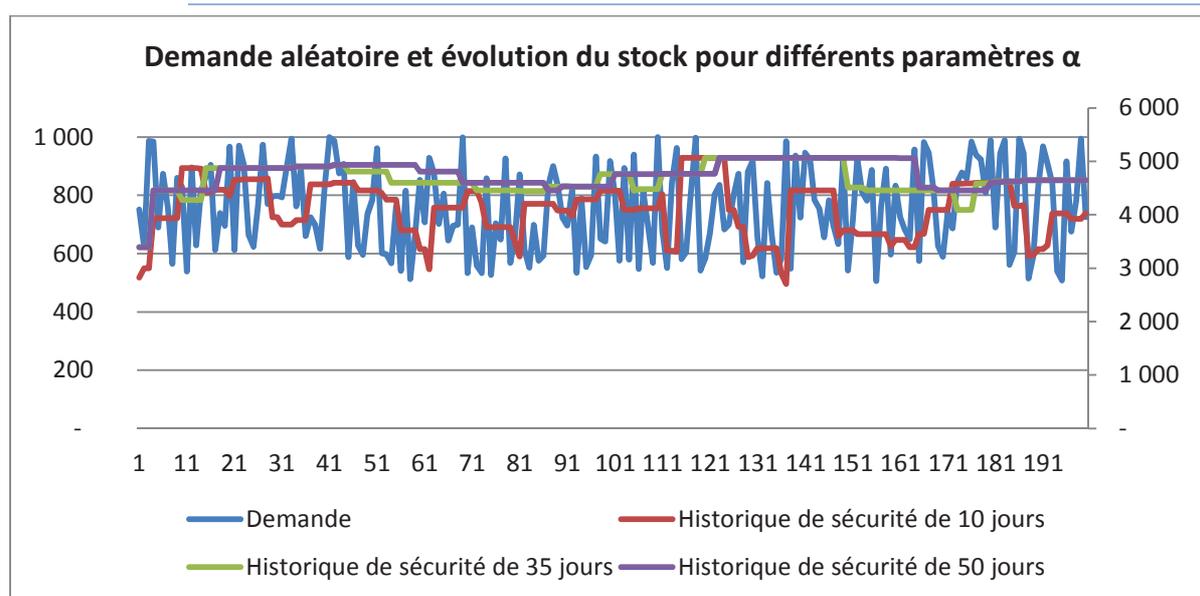


Figure 58: Présentation de la demande aléatoire et de l'évolution du stock pour différents paramètres de sécurisation α

Le tableau suivant présente les résultats obtenus sur ces courbes :

Tableau 26: Présentation des résultats de la simulation d'une demande aléatoire dans l'intervalle [500; 1000]

jours d'historique	10 jours	35 jours	50 jours
taux de service	92%	97%	98%
stockage moyen	4210	4751	4986

Comme le montre le tableau ci-dessus, un compromis doit être réalisé : un historique de 10 jours n'assure pas un taux de service suffisant tandis qu'un historique de 50 jours implique un stockage élevé. Un historique de 35 jours semble donc le plus adapté pour une demande aléatoire du type de celle simulée. Nous garantissons ainsi un taux de service acceptable avec un niveau de stock raisonnable.

2. Effet de la variation de α pour une demande croissante entre 100 et 1000 pièces

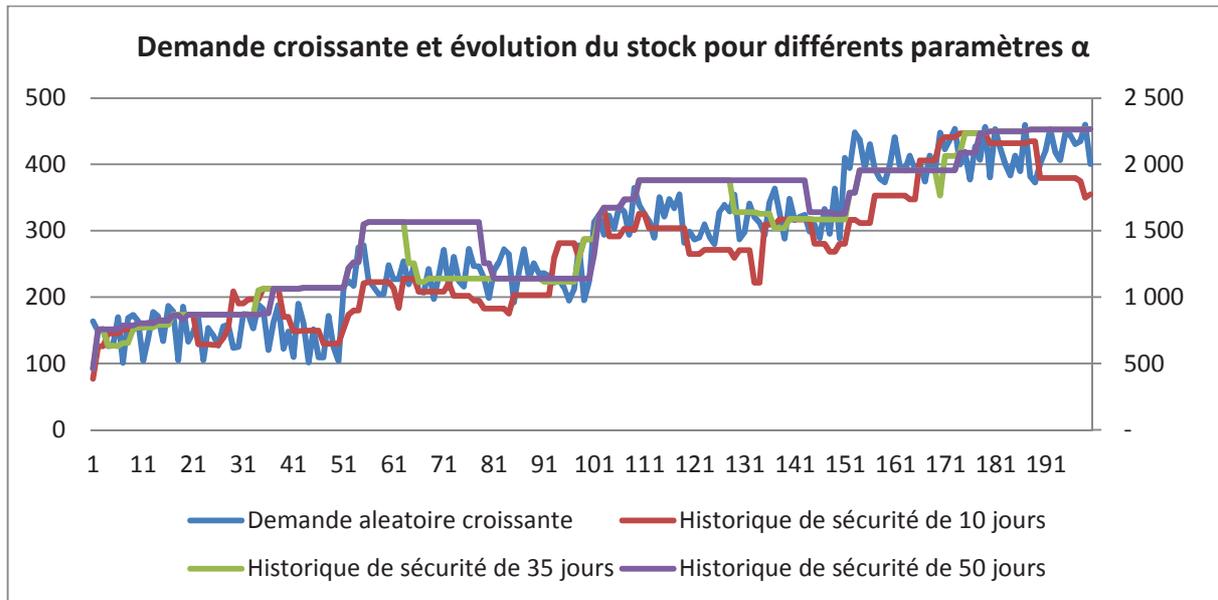


Figure 59: Présentation de la demande croissante et de l'évolution du stock pour différents paramètres de sécurisation α

Nous baserons notre interprétation sur les mêmes résultats que précédemment.

Tableau 27: Présentation des résultats de la simulation d'une demande croissante dans l'intervalle [100; 1000]

jours d'historique	10 jours	35 jours	50 jours
taux de service	89%	92%	95%
stockage moyen	2220	2495	2686

Pour une demande croissante, les taux de service sont relativement faibles. Pour un historique de 10 jours, nous avons ainsi 89% seulement. Dans ce cas-là, nous préconiserions le taux de service le plus important obtenu avec la prise en compte de l'historique de sécurité le plus grand à savoir 50 jours. En effet, la demande allant croissante, les erreurs de prévisions risquent également d'augmenter. Il faut donc privilégier une sécurisation plus importante. C'est ce que permet la prise en compte du plus grand historique.

3. Effet de la variation de α pour une demande décroissante entre 100 et 1000 pièces

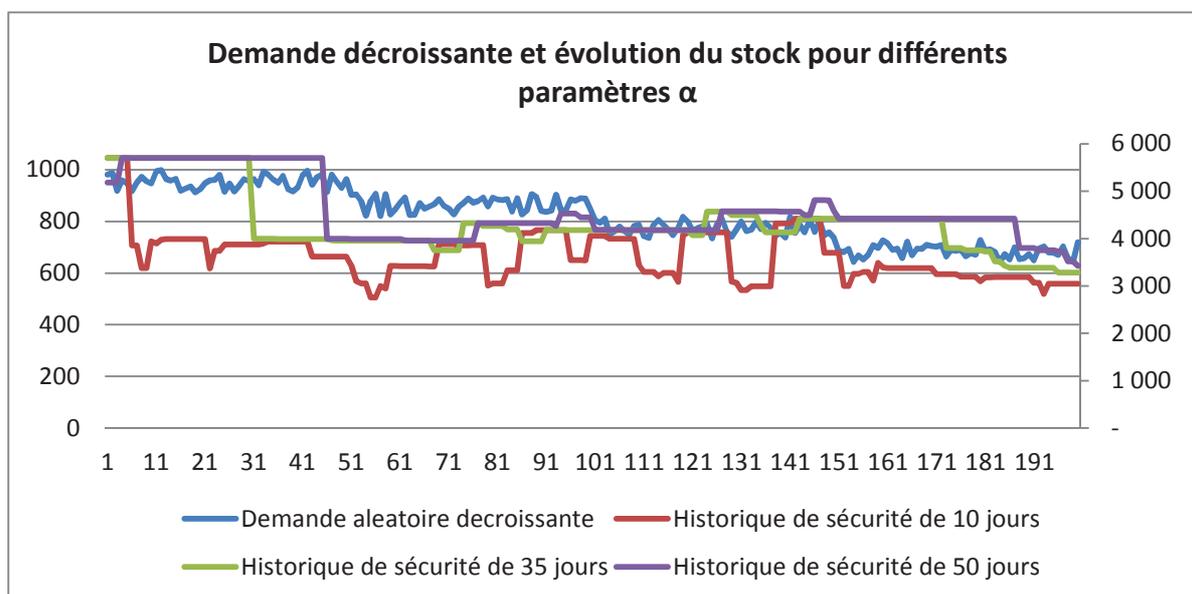


Figure 60: Présentation de la demande décroissante et de l'évolution du stock pour différents paramètres de sécurisation α

Voici les résultats obtenus.

Tableau 28: Présentation des résultats de la simulation d'une demande décroissante dans l'intervalle [100; 1000]

jours d'historique	10 jours	35 jours	50 jours
taux de service	95%	98%	99%
stockage moyen	2774	3237	3429

Contrairement au cas d'une demande croissante, l'erreur de prévision tout comme la demande va aller décroissante. Dans ce cas-là, l'ensemble des cas étudiés permettent d'avoir des taux de service intéressants. Si nous nous fixons comme limite 97% (cas de notre partenaire industriel), alors, un historique de 35 jours sera suffisant. Nous aurons ainsi un niveau de stock au plus juste pour satisfaire à notre objectif de taux de service. Dans ce cas-là, l'historique de 50 jours conserve une erreur de prévision trop longtemps alors que celle-ci diminue avec la demande. Il est alors plus intéressant de la remettre en question plus souvent.

Conclusion

La mondialisation a entraîné la multiplication des usines partout à travers le monde et donc le recours de plus en plus souvent au Global Sourcing. Le problème est que l'augmentation des distances d'approvisionnements engendre généralement une augmentation des incertitudes dans toute la chaîne logistique. Ces incertitudes peuvent être la cause de multiples désagréments pour une entreprise en termes de coûts mais aussi d'image. Pour faire face à ces enjeux, de nombreux travaux de recherche ont été effectués durant ces dernières décennies. Néanmoins, il reste encore de nombreuses recherches à mener au sujet des approvisionnements lointains au niveau opérationnel. Les techniques de base (réapprovisionnement (r,Q) , (T,s) et variantes) ne fonctionnent pas efficacement et on fait souvent appel à des méthodes empiriques avec tout ce que cela comporte comme risques.

Nous avons donc voulu au cours de ce chapitre apporter un éclairage sur les méthodes de gestion de flux en nous concentrant spécifiquement sur le cas du Global Sourcing.

La première section nous a permis de présenter les politiques de pilotage de flux classique avec une mise en avant des politiques permettant de prendre en compte les incertitudes. Suite à cela, nous nous sommes concentrés sur le Global Sourcing et nous avons donc introduit ce concept et la justification de son utilisation. Après l'étude des travaux portant sur ce sujet, nous avons présenté les modèles de gestion de flux que nous avons proposées et comparé les résultats obtenus avec notre modèle aux modèles classiques type (T,s) , ou encore (T, s_k) et la méthode initialement utilisée par PSA. Nous avons ainsi pu montrer les bénéfices que pouvait présenter l'utilisation d'une sécurisation dynamique avec prise en compte des prévisions et de l'évolution de leur qualité comme le permet notre méthode. Enfin, nous avons conclu ce chapitre par la présentation d'un outil de simulation permettant de modéliser l'évolution du stock en fonction d'une sécurisation voulue et d'un profil de demande déterminé. Cet outil va pouvoir servir dans un contexte industriel à déterminer rapidement quel type de sécurisation donnerait le meilleur résultat dans le cas d'application considéré.

Conclusion et perspectives

A. Conclusion :

La stratégie du Sourcing a beaucoup évolué durant ces dernières décennies. Avec une économie de plus en plus globalisée, les flux intercontinentaux des entreprises en direction de pays géographiquement lointains ont pris des proportions de plus en plus importantes. Que ce soit pour se fournir en matières premières et en composants que pour revendre les produits finis, de multiples raisons expliquent ce phénomène. Le Global Sourcing représente à la fois des enjeux industriels intéressants et une complexification du management de la chaîne logistique, d'où l'intérêt pour les entreprises de traiter ce sujet avec une démarche scientifique rigoureuse. Ce travail de recherche s'inscrit dans cette démarche et a pour objectif d'offrir aux industriels une vision globale pour le pilotage de flux en approvisionnements lointains allant de la prévision de la demande aux politiques de pilotage de flux.

Nous avons, ainsi, commencé par traiter le problème des prévisions. Suite à l'analyse de la littérature existante dans ce domaine, nous avons mis en exergue l'absence de méthodes à la fois efficaces et réactives pour le choix de modèles de prévision. Nous avons alors proposé une méthode permettant d'automatiser la sélection de modèle de prévision et d'améliorer la qualité de prévision obtenue dans un temps raisonnable. Cette méthode a ensuite été appliquée sur deux cas industriels, chez Gefco et Chez PSA-PR qui ont démontré la pertinence de notre outil.

Dans le deuxième volet de ce travail, nous nous sommes intéressés à la caractérisation de l'erreur prévisionnelle et nous avons proposé deux modèles permettant de caractériser l'erreur de prévision de façon plus fine que ce qui existait dans la littérature. Nous avons donc proposé deux types de modélisations : la modélisation mixte qui permet de combiner les erreurs de prévision absolue et relative, et la prise en compte de l'évolution de l'incertitude prévisionnelle en fonction de l'horizon de prévision. Nous avons également présenté une méthode permettant de déterminer les paramètres de ces modèles afin de pouvoir les utiliser facilement dans un contexte industriel. Nous avons appliqué ces deux modèles dans le cas des approvisionnements lointains de PSA et nous avons montré l'apport de ces modélisations sur la qualité de la caractérisation de l'erreur prévisionnelle.

Dans le dernier volet de ce travail, nous proposons une méthode de pilotage de flux basée sur les prévisions et les erreurs prévisionnelles. Cette méthode (notée HSS) qui permet de sécuriser les approvisionnements en fonction des erreurs de prévision passées a été appliquée pour l'approvisionnement des flux lointains de PSA. La comparaison de la méthode que nous proposons à la méthode PSA et aux modèles existants dans la littérature a mis en avant les bénéfices que pouvaient apporter notre méthode de gestion des stocks dans le cadre du Global Sourcing vis-à-vis de la littérature et de la méthode actuellement utilisée en permettant de baisser d'une façon significative les niveaux de stock tout en respectant un taux de service objectif.

En conclusion, cette étude nous a permis de mettre en évidence les liens qui existent entre la réalisation des prévisions et la gestion des approvisionnements dans le cadre du Global Sourcing. Cette vision globale de la problématique est l'un des apports principaux de la thèse. Un deuxième aspect qui nous paraît important est l'interaction permanente, dans le cadre de la Chaire Supply Chain avec nos partenaires industriels. Cette interaction nous a permis de s'assurer en permanence que les résultats développés dans ce travail étaient applicables au sein des entreprises.

B. Perspectives :

Le monde de la Supply Chain est aujourd'hui en perpétuelles évolutions. Nous avons ainsi pu voir, depuis le commencement de ce travail de thèse, émerger de nouvelles techniques dans le domaine des prévisions. Aujourd'hui, les systèmes experts sont devenus légion dans les systèmes de prévision même si leurs performances peuvent être critiquées. Plusieurs pistes de recherches peuvent être envisagées suite à notre travail sur les prévisions comme l'utilisation de ces nouvelles techniques ou l'étude des cas particuliers tels que la prévision de la demande pour des produits ayant très peu d'historique. La prise en compte de nouveaux facteurs externes est également intéressante. En effet, les promotions, publicités, l'effet météo etc. sont des axes de recherche aujourd'hui au cœur des préoccupations industrielles. Dans les travaux que nous avons menés avec les industriels, nous nous sommes alignés sur le système de prévision mis en place sans remettre en cause les différents paramètres d'agrégation (au niveau du produit, du pas de temps ou du maillon de la Supply Chain). Il serait intéressant d'étudier l'impact de ces agrégations sur le choix et la qualité de la méthode de prévision.

Les travaux que nous avons présentés et proposés au niveau du pilotage de flux dans le cadre des approvisionnements lointains présentent un certain nombre d'hypothèses qu'il serait intéressant de relâcher. En effet, le pilotage de flux étant un domaine de recherche très vaste, nous avons choisi de nous appuyer sur le cas particulier de notre partenaire industriel pour proposer un modèle adapté. La prise en compte d'autres incertitudes que celle liée à la variabilité commerciale dans un même modèle serait une suite logique. Il peut ainsi être important de prendre en considération l'incertitude sur le délai d'approvisionnement dans les problèmes d'approvisionnement lointain. Dans le cas des approvisionnements lointains, ceci peut impliquer que l'ordre de passage des commandes ne soit pas forcément le même que celui d'arrivées de ces commandes. Ce problème connu sous le nom de cross-over, est une problématique qui intéresse plusieurs chercheurs dans la gestion de stocks (voir par exemple (Robinson *et al.* 2001) et (Bradley & Robinson 2005)). L'incertitude sur la quantité livrée pourrait également être prise en compte ou encore des incertitudes plus spécifiques au Global Sourcing comme la variabilité des taux de change.

D'autres facteurs importants pour les industriels peuvent aussi être considérés comme le lissage des commandes. Dans ce sens, nous avons exploré un modèle inspiré du modèle de prévision par lissage exponentiel (Brown 1959). Le stock de sécurité dans ce modèle est calculé comme suit : $SSE_j = \gamma * SS_j + (1-\gamma) * SSE_{j-1}$ où SS_j est le stock de sécurité calculé sans lissage pour la période j et SSE_j est le stock de sécurité lissé de la période j . Cette méthode permet de lisser les variations au niveau du stock de sécurité. Le coefficient de lissage permet de modifier la variabilité acceptable du stock de sécurité. Les résultats obtenus par cette méthode sont moins bonnes que la méthode HSS, mais nous sommes convaincus que cette piste est prometteuse et nécessite d'être approfondie.

D'un point de vue plus théorique, la mise en perspective de ce travail sur les différents échelons de la Supply Chain pourrait être une autre piste de recherche. En effet, nous nous sommes limités à l'étude d'un système mono-étage. Dans le même ordre d'idée, la prise en compte de regroupements de commande avec un approvisionnement multi-produits ou multifournisseurs pourrait faire partie des élargissements du modèle proposé. On pourrait alors imaginer un système à deux ou trois niveaux de stock de sécurité qui agiraient sur le type de réapprovisionnement avec un transport maritime, routier ou aérien selon les risques de rupture.

Bibliographie

- Alguire, M.S., Frear, C.R. & Metcalf, L.E., 1994. An examination of the determinants of global sourcing strategy. *Journal of Business & Industrial Marketing*, 9(2), p.62–74.
- Alstrom, P. & Madsen, P., 1996. Tracking signals in inventory control systems A simulation study. *International journal of production economics*, 45(1-3), p.293–302.
- Arnold, U., 2000. Global Sourcing: an indispensable element in worldwide competition. *European Journal of Purchasing & Supply Management*, 6, p.14-28.
- Arnold, U., 1989. Global sourcing: an indispensable element in worldwide competition. *Management International Review*, p.14–28.
- Aviv, Y., 2002. Gaining benefits from joint forecasting and replenishment processes: The case of auto-correlated demand. *Manufacturing & Service Operations Management*, 4(1), p.55.
- Axsäter, S., 2006. *Inventory control*, Springer Verlag.
- Babai, M. Z., Syntetos, A.A., Dallery, Y. & Nikolopoulos, K. , 2009. Dynamic re-order point inventory control with lead-time uncertainty: analysis and empirical investigation.
- Babai, M. Z. & Dallery, Y., 2009. Dynamic versus static control policies in single stage production-inventory systems. *International Journal of Production Research*, 47, p.415-433.
- Babai, M. Z., 2005. Politiques de pilotage de flux dans les chaînes logistiques : impact de l'utilisation des prévisions sur la gestion de stocks. Available at: <http://tel.archives-ouvertes.fr/tel-00275292/>.
- Bello, D.C., Lohtia, R. & Sangtani, V., 2004. An institutional analysis of supply chain innovations in global marketing channels. *Industrial Marketing Management*, 33(1), p.57–64.
- Berkley, B.J., 1992. A review of the kanban production control research literature. *Production and Operations Management*, 1(4), p.393–411.
- Bermúdez, J.D., Segura, J.V. & Vercher, E., 2006. A decision support system methodology for forecasting of time series based on soft computing. *Computational statistics & data analysis*, 51(1), p.177–191.
- Biggs, J.R. & Champion, W.M., 1982. The effect and cost of forecast error bias for multiple-stage production-inventory systems. *Decision Sciences*, 13(4), p.570–584.
- Birou, L.M. & Fawcett, S.E., 1993. International purchasing: Benefits, requirements, and challenges. *Journal of Supply Chain Management*, 29(2), p.27–37.
- De Bodt, M.A. & Wassenhove, L.N., 1983. Cost increases due to demand uncertainty in MRP lot sizing. *Decision Sciences*, 14, p.345-362.

- Bourbonnais, R. & Usunier, J.-C., 2007. *Prévision des ventes: Théorie et pratique* 4^e éd. , Economica.
- Box, G.E.P., Jenkins, G.M. & Reinsel, G.C., 1976. *Time series analysis: forecasting and control*, Holden-day San Francisco.
- Boylan, J. E & Syntetos, A. A., 2010. Spare parts management: a review of forecasting research and extensions. *IMA Journal of Management Mathematics*, 21(3), p.227.
- Bozarth, C., Handfield, R. & Das, A., 1998. Stages of global sourcing strategy evolution: an exploratory study. *Journal of operations management*, 16(2-3), p.241–255.
- Bradley, J.R. & Robinson, L.W., 2005. Improved base-stock approximations for independent stochastic lead times with order crossover. *2005*, 7(4), p.319-329.
- Brown, R.G., 1959. *Statistical Forecasting for Inventory Control*, McGraw-Hill, New York.
- Buzacott, J.A., 1989. Queueing models of Kanban and MRP controlled production systems. *Engineering Costs and Production Economics*, 17(1-4), p.3-20.
- Buzacott, J.A. & Shanthikumar, J.G., 1994. Safety Stock versus Safety Time in MRP Controlled Production Systems. *Management Science*, 40(12), p.1678-1689.
- Buzacott, J.A. & Shanthikumar, J.G., 1993. *Stochastic models of manufacturing systems*, Prentice Hall Englewood Cliffs, NJ.
- Buzacott, J.A. & Shanthikumar, J.G., 1989. *Stochastic Models of Single Stage MRP-Controlled Production Systems*, Working Paper, University of Waterloo, Canada.
- Carter, J. & Narasimhan, R., 1990. Purchasing in the international marketplace: Implications for operations. *International journal of purchasing and materials management*, Summer, p.2-11.
- Chandra, C. & Grabis, J., 2005. Application of multi-steps forecasting for restraining the bullwhip effect and improving inventory performance under autoregressive demand. *European Journal of operational research*, 166(2), p.337–350.
- Chen, A., Hsu, C.H. & Blue, J., 2007. Demand planning approaches to aggregating and forecasting interrelated demands for safety stock and backup capacity planning. *International Journal of Production Research*, 45(10), p.2269–2294.
- Chen, F. *et al.*, 2000. Quantifying the bullwhip effect in a simple supply chain: The impact of forecasting, lead times, and information. *Management science*, p.436–443.
- Chitturi, P. *et al.*, 2010. Identification and classification of intermittent demand patterns. *International Journal of Productivity and Quality Management*, 6(3), p.304–317.
- Clark, A.J. & Scarf, H., 1960. Optimal policies for a multi-echelon inventory problem. *Management science*, 6(4), p.475–490.
- Cogger, K.O., 1973. Specification Analysis. *Journal of the American Statistical Association*, p.899-905.

- Cook, T.A., 2007. *Global sourcing logistics: how to manage risk and gain competitive advantage in a worldwide marketplace*, AMACOM Div American Mgmt Assn.
- Croston, J.D., 1972. Forecasting and Stock Control for Intermittent Demands. *Operational Research Quarterly (1970-1977)*, 23(3), p.289-303.
- Dallery, Y. & Liberopolous, G., 2000. Extended kanban control system: combining kanban and base stock. *IIE Transactions*, 32, p.369–386.
- Das, A. & Handfield, R.B., 1997. Just-in-time and logistics in global sourcing: an empirical study. *International Journal of Physical Distribution & Logistics Management*, 27(3/4), p.244–259.
- Das, S.K.&Abdel-Malek, L., 2003. Modeling the flexiility of order quantities and lead-times in supply chains. *International Journal of Production Economics*, 85(2), p.171–181.
- Davis, T., 1993. Effective supply chain management. *Sloan management review*, 34, p.35–35.
- Dolgui, A. & Prodhon, C., 2007. Supply planning under uncertainties in MRP environments: A state of the art. *Annual Reviews in Control*, 31(2), p.269–279.
- Dornier, P.P. *et al.*, 2008. *Global operations and logistics: Text and cases*, Wiley-India.
- Eaves, A.H.C. & Kingsman, B.G., 2004. Forecasting for the ordering and stock-holding of spare parts. *Journal of the Operational Research Society*, 55(4), p.431–437.
- Enns, S.T., 2002. MRP performance effects due to forecast bias and demand uncertainty. *European Journal of Operational Research*, 138(1), p.87–102.
- Ericsson, N.R. , B. of G. of the F.R.S., 2001. *Forecast uncertainty in economic modeling*, Board of Governors of the Federal Reserve System.
- Ettlie, J.E. & Sethuraman, K., 2002. Locus of supply and global manufacturing. *International Journal of Operations & Production Management*, 22(3), p.349–370.
- Fawcett, S.E., Birou, L.M. & Cofield, T.B., 1993. Supporting global operationw through logistics and purchasing. *International Journal of Physical Distribution & Logistics Management*, 23(4), p.3-11.
- Fildes, R. *et al.*, 2008. Forecasting and operational research: a review. *Journal of the Operational Research Society*, 59(9), p.1150–1172.
- Fleischmann, B., Meyr, H. & Wagner, M., 2002. *Supply Chain Management & Advanced Planning*. Dans Berlin: Springer.
- Flores, B.E., 1986. A pragmatic view of accuracy measurement in forecasting. *Omega*, 14(2), p.93–98.
- Flores, B.E., Olson, D.L. & Pearce, S.L., 1993. Use of Cost and accuracy measures in forecasting method selection: a physical distribution example. *International Journal of Production Research*, 31(1), p.139-160.
- Fraering, M. & Prasad, S., 1999. International sourcing and logistics: an integrated model.

- Logistics Information Management*, 12(6), p.451–460.
- Frear, C.R., Metcalf, L.E. & Alguire, M.S., 1992. Offshore sourcing: its nature and scope. *International journal of purchasing and materials management*, 28(5), p.2-11.
- Frein, Y., Di Mascolo, M. & Dallery, Y., 1995. On the design of generalized kanban control systems. *International Journal of Operations & Production Management*, 15(9), p.158–184.
- Fukuda, K., 2006. Time-Series Forecast Jointly Allowing the Unit-Root Detection and the Box–Cox Transformation. *Communications in Statistics—Simulation and Computation*®, 35(2), p.419–427.
- Galbraith, J.R., 1974. Organization design: An information processing view. *Interfaces*, 4(3), p.28–36.
- Ghobbar, A.A. & Friend, C.H., 2003. Evaluation of Forecasting methods for intermittent parts demand in the field of aviation: a predictive model. *Computer*, 30(14), p.2097-2114.
- Gicquel, C., Minoux, M. & Dallery, Y., 2008. Capacitated Lot Sizing models: a literature review. Open Access Article hal-00255830, Hyper Articles en Ligne.
- Golini, R. & Kalchschmidt, M., 2010. Moderating the impact of global sourcing on inventories through supply chain management. *International Journal of Production Economics*.
- Grasso, E.T. & Taylor, B.W., 1984. A Simulation-based Experimental Investigation of Supply\ Timing Uncertainty in MRP Systems. *International Journal of Production Research*, 22(3), p.485–497.
- Graves, S.C., 1999. A single-item inventory model for a nonstationary demand process. *Manufacturing & Service Operations Management*, 1(1), p.50–61.
- Graves, S.C., 1986. A tactical planning model for a job shop. *Operations Research*, p.522–533.
- Grogger, J., 2007. Markov forecasting methods for welfare caseloads. *Children and Youth Services Review*, 29(7), p.900–911.
- Gross, D. & Harris, C.M., 1973. Continuous-Review (s, S) Inventory Models with State-Dependent Leadtimes. *Management Science*, p.567–574.
- Guellue, R., 1996. On the value of information in dynamic production/inventory problems under forecast evolution. *Naval Research Logistics (NRL)*, 43(2), p.289–303.
- Gupta, A. & Maranas, C.D., 2003. Managing demand uncertainty in supply chain planning. *Computers & Chemical Engineering*, 27(8-9), p.1219–1227.
- Hadley, G. & Whitin, T.M., 1963. *Analysis of inventory systems*. 1963, Prentice-Hall, Englewood Cliffs, NJ.
- Handfield, R.B., 1994. US global sourcing: patterns of development. *International Journal of Operations & Production Management*, 14(6), p.40–51.

- Hautaniemi, P. & Pirttila, T., 1999. The choice of replenishment policies in an MRP environment. *International Journal of Production Economics*, 59(1-3), p.85–92.
- Heath, D.C. & Jackson, P.L., 1994. Modeling the evolution of demand forecasts with application to safety stock analysis in production/distribution systems. *IIE Transactions-Industrial Engineering Research and Development*, 26(3), p.17–30.
- Hong, J.-D. & Hayya, J.C., 1999. On integrated production-replenishment policies in single-stage manufacturing. *Computers & Operations Research*, 26(5), p.505-523.
- Hua, Z. & Zhang, B., 2006. A hybrid support vector machines and logistic regression approach for forecasting intermittent demand of spare parts. *Applied Mathematics and Computation*, 181(2), p.1035–1048.
- Humphreys, P., Mak, K.L. & Yeung, C.M., 1998. A just-in-time evaluation strategy for international procurement. *Supply Chain Management: An international Journal*, 3(4), p.175-186.
- Iglehart, D.L., 1964. The dynamic inventory problem with unknown demand distribution. *Management Science*, p.429–440.
- Jans, R. & Degraeve, Z., 2007. Meta-heuristics for dynamic lot sizing: A review and comparison of solution approaches. *European Journal of Operational Research*, 177(3), p.1855–1875.
- Johnston, F.R. & Boylan, John E., 1996. Forecasting for items with intermittent demand. *Journal of the Operational Research Society*, p.113-121.
- Kalapanidas, E. & Avouris, N., 2003. Feature selection for air quality forecasting: a genetic algorithm approach. *AI Communications*, 16(4), p.235–251.
- Kang, S., 1991. *An introduction of the use of feed forward neural networks for forecasting*. Ph. D. Thesis, Kent State University.
- Karlin, S., 1960. Dynamic inventory policy with varying stochastic demands. *Management Science*, p.231–258.
- Kimura, O. & Terada, H., 1981. Design and analysis of pull system, a method of multi-stage production control. *International Journal of Production Research*, 19, p.241–53.
- Kotabe, M. & Murray, J.Y., 1990. Linking product and process innovations and modes of international sourcing in global competition: A case of foreign multinational firms. *Journal of International Business Studies*, Vol. 21 (3). p.383–408.
- Kotabe, M. & Swan, K.S., 1994. Offshore sourcing: reaction, maturation, and consolidation of US multinationals. *Journal of International Business Studies*, Vol. 25 (1). p.115–140.
- Lai, F., Zhao, X. & Lee, T., 2006. Selecting forecasting model parameters in Material Requirement Planning systems. *International Journal of Internet and Enterprise Management*, 4(4), p.331–354.
- Lapide, L. 2006. Top-down & Bottom-up forecasting in S&OP. *The journal of business*, 1.

- Lawrence, M. *et al.*, 2006. Judgmental forecasting: A review of progress over the last 25 years. *International Journal of Forecasting*, 22(3), p.493–518.
- Lee, H.L., Padmanabhan, V. & Whang, S., 1997. Information distortion in a supply chain: the bullwhip effect. *Management science*, Vol. 43 (4). p.546–558.
- Lee, H.L., So, K.C. & Tang, C.S., 2000. The value of information sharing in a two-level supply chain. *Management science*, p.626–643.
- Lee, T.S. & Adam Jr, E.E., 1986. Forecasting error evaluation in material requirements planning (MRP) production-inventory systems. *Management Science*, p.1186–1205.
- Liang, W.Y. & Huang, C.C., 2006. Agent-based demand forecast in multi-echelon supply chain. *Decision Support Systems*, 42(1), p.390–407.
- Liu, M.L. & Sahinidis, N.V., 1997. Process planning in a fuzzy environment. *European Journal of Operational Research*, 100(1), p.142–169.
- Luna I.&Ballini R., 2011. Top-down strategies based on adaptive fuzzy rule-based systems for daily time series forecasting, *International Journal of Forecasting*, 27, p. 708–724
- MacCarthy, B.L. & Atthirawong, W., 2003. Factors affecting location decisions in international operations – a Delphi study. *International Journal of Operations & Production Management*, 23(7), p.794-818.
- Makridakis, S., 1986. The art and science of forecasting An assessment and future directions. *International Journal of Forecasting*, 2(1), p.15–39.
- Makridakis, S. *et al.*, 1982. The accuracy of extrapolation (time series) methods: Results of a forecasting competition. *Journal of Forecasting*, 1(2), p.111-153.
- Meijboom, B. & Vos, B., 1997. International Manufacturing and location decisions: Balancing configuration and coordination aspects. *International Journal of Operations & Production Management*, 17(8), p.790-805.
- Meixell, M.J. & Gargeya, V.B., 2005. Global supply chain design: A literature review and critique. *Transportation Research Part E: Logistics and Transportation Review*, 41(6), p.531–550.
- Min, H. & Galle, W., 1990. International purchasing strategies of multinational US firms. *International journal of purchasing and materials management*, 27(3), p.9-18.
- Minner, S., 2003. Multiple-supplier inventory models in supply chain management: A review. *International Journal of Production Economics*, 81, p.265–279.
- Monczka, R. M *et al.*, 2010. *Purchasing and supply chain management*, Cengage Learning EMEA.
- Monczka, Robert M. & Guinipero, L.C., 1984. International purchasing: characteristics and implementation. *International journal of purchasing and materials management*, 20, p.2-9.
- Monczka, Robert M. & Trent, R.J., 1992. Worldwide sourcing: Assessment and execution.

- International journal of purchasing and materials management*, p.9-19.
- Mula, J. *et al.*, 2006. Models for production planning under uncertainty: A review. *International Journal of Production Economics*, 103(1), p.271-285.
- Narasimhan, R. & Carter, J.R., 1990. Organisation, communication and co-ordination of international sourcing. *International Marketing Review*, 7(2).
- Nassimbeni, G., 2006. International sourcing: Empirical evidence from a sample of Italian firms. *International Journal of Production Economics*, 103(2), p.694–706.
- Orlicky, J.A., 1974. *Material requirements planning: the new way of life in production and inventory management*, McGraw-Hill, Inc.
- Plenert, G., 1999. Focusing material requirements planning (MRP) towards performance. *European Journal of Operational Research*, 119(1), p.91–99.
- Prasad, S. & Babbar, S., 2000. International operations management research. *Journal of Operations Management*, 18(2), p.209.
- Quintens, L., Pauwels, P. & Matthyssens, P., 2006. Global purchasing: State of the art and research directions. *Journal of purchasing and supply management*, 12(4), p.170–181.
- Raghunathan, S., 2001. Information sharing in a supply chain: A note on its value when demand is nonstationary. *Management Science*, p.605–610.
- Regattieri, A. *et al.*, 2005. Managing lumpy demand for aircraft spare parts. *Journal of Air Transport Management*, 11(6), p.426–431.
- Roberts, S. & Whybark, D.C., 1974. Adaptive forecasting techniques. *International Journal of Production Research*, 12(6), p.635-645.
- Robinson, L.W., Bradley, J.R. & Thomas, L.J., 2001. Consequences of Order Crossover Under Order-Up-To inventory Policies. , 3(3), p.175-188.
- Saarenketo, S., Puumalainen, K. & Kyläheiko, K., 2004. Dynamic knowledge-related learning processes in internationalizing high-tech SMEs. *International Journal of Production Economics*, 89(3), p.363-378.
- Sani, B. & Kingsman, B.G., 1997. Selecting the best periodic inventory control and demand forecasting methods for low demand items. *Journal of the Operational Research Society*, p.700–713.
- Sastri, T., Flores, B. & Valdes, J., 1989. Detecting points of change in time series. *Computers & Operations Research*, 16(3), p.271–293.
- Scarf, H., 1959. Bayes solutions of the statistical inventory problem. *The Annals of Mathematical Statistics*, 30(2), p.490–508.
- Schreuder, H. & Klaassen, J., 1984. Confidential revenue and profit forecasts by management and financial analysts: evidence from the Netherlands. *Accounting Review*, p.64–77.
- Shah, M. *et al.*, 2009. Improving the effectiveness of traditional demand planning systems.

- Shiskin, J., 1964. Les signaux indicateurs des recessions et des reprises. *Gauthiers-Villars*.
- Silver, E.A. & Peterson, R., 1985. Decision systems for inventory management and production planning.
- Simchi-Levi, D., Kaminsky, P. & Simchi-Levi, E., 2000. *Designing and Managing the Supply Chain*, Boston: McGraw-Hill Boston, MA.
- Simpson, N.C., 2001. Questioning the relative virtues of dynamic lot sizing rules. *Computers & Operations Research*, 28, p.899-9-4.
- Smith, M. & others, 1999. Item selection for global purchasing. *European Journal of Purchasing & Supply Management*, 5(3-4), p.117–127.
- Snyder, R., 2002. Forecasting sales of slow and fast moving inventories. *European Journal of Operational Research*, 140(3), p.684–699.
- Spekman, J., Spear, J. & Kamuff, J., 1999. Towards more effective sourcing and supplier management. *European Journal of Purchasing & Supply Management*, 5, p.103-116.
- Stadtler, H., 2005. Supply chain management and advanced planning—basics, overview and challenges. *European journal of operational research*, 163(3), p.575–588.
- Stadtler, H. & Kilger, C., 2005. *Supply chain management and advanced planning: concepts, models, software and case studies*, Springer Verlag.
- Stratton, R. & Warburton, R.D., 2006. Managing the trade-off implications of global supply. *International Journal of Production Economics*, 103(2), p.667–679.
- Sugimori, Y. *et al.*, 1977. Toyota production system and Kanban system: Materialization of just-in-time and respect-for-human system. *International journal of production research*.
- Swamidass, P.M., 1993. Import sourcing dynamics: An integrative perspective. *Journal of International Business Studies*, p.671–691.
- Sweeney, M.T., 1994. A methodology for the strategic management of international manufacturing and sourcing. *The international Journal of Logistics Management*, 5(1), p.55-65.
- Syntetos, A. A., Boylan, J. E. & Croston, J.D., 2004. On the categorization of demand patterns. *Journal of the Operational Research Society*, 56(5), p.495–503.
- Syntetos, A. A., Boylan, J. E. & Croston, J.D., 2005. On the Categorization of Demand Patterns. *Journal of the Operational Research Society*, p.495–503.
- Syntetos, A. A. & Boylan, J. E., 2001. On the bias of intermittent demand estimates. *International Journal of Production Economics*, 71(1-3), p.457–466.
- Syntetos, Aris A. & Boylan, John E., 2005. The accuracy of intermittent demand estimates. *International Journal of Forecasting*, 21(2), p.303-314.
- Tanwari, A.U. & Betts, J., 1999. Impact of forecasting on demand planning. *production*, 40,

p.31-35.

- Teunter, R. & Sani, B., 2009. On the bias of Croston's forecasting method. *European Journal of Operational Research*, 194(1), p.177–183.
- Toktay, L.B. & Wein, L.M., 2001. Analysis of a forecasting-production-inventory system with stationary demand. *Management Science*, p.1268–1281.
- Trent, R.J. & Monczka, Robert M., 2003. Understanding integrated global sourcing. *International Journal of Physical Distribution & Logistics Management*, 33(7), p.607-629.
- Tyagi, R., 2002. How to evaluate a demand planning and forecasting package. *Supply Chain Management Review*, p.43-56.
- Vapnik, V.N., 2000. *The nature of statistical learning theory*, Springer Verlag.
- Vickery, S.K., 1989. International sourcing: implications for just-in-time manufacturing. *Production and Inventory Management Journal*, 30(3), p.66-72.
- Vollmann, T.E., Berry, W.L. & Whybark, D.C., 2005. *Manufacturing planning and control systems for supply chain management*, McGraw-Hill Companies.
- Voudouris, C. *et al.*, 2006. ARMS: An automated resource management system for British Telecommunications plc. *European journal of operational research*, 171(3), p.951–961.
- Wallis, K.F., 2008. Forecast uncertainty, its representation and evaluation. *Econometric Forecasting and High-Frequency Data Analysis*, 13, p.1–51.
- Whybark, D.C. & Williams, J.G., 1976. Material requirements planning under uncertainty. *Decision Sciences*, 7(4), p.595–606.
- Willemain, T.R., Smart, C.N. & Schwarz, H.F., 2004. A new approach to forecasting intermittent demand for service parts inventories* 1. *International Journal of Forecasting*, 20(3), p.375–387.
- Willemain, T.R. *et al.*, 1994. Forecasting intermittent demand in manufacturing: a comparative evaluation of Croston's method. *International Journal of Forecasting*, 10(4), p.529–538.
- Williams, T.M., 1984. Special products and uncertainty in production/inventory systems* 1. *European Journal of Operational Research*, 15(1), p.46–54.
- Wilson, R.H., 1934. A scientific routine for stock control. *Harvard business review*, 13(1), p.116–129.
- Womack, J. & Jones, D.T., 1996. *Lean Thinking* Rawson Ass., New York.
- Wood, D.F., 2002. *International logistics*, AMACOM/American Management Association.
- Wright, D.J., 1986. Forecasting data published at irregular time intervals using an extension of Holt's method. *Management science*, p.499–510.
- Zhang, G. *et al.*, 1998. Forecasting with artificial neural networks: The state of the art.

International Journal of Forecasting, 14(1), p.25-62.

Zhang, G.P. & Qi, M., 2005. Neural network forecasting for seasonal and trend time series.
European journal of operational research, 160(2), p.501–514.

Zipkin, P.H., 2000. *Foundation of Inventory Management*, USA: McGraw-Hill.