

# *THESE*

Présentée et soutenue publiquement à

## *L'UNIVERSITE DES SCIENCES ET TECHNOLOGIES DE LILLE*

pour l'obtention du grade de

**DOCTEUR DE L'UNIVERSITE DE LILLE I**

*Discipline : Productique - Automatique et Informatique Industrielle*

par

**Sébastien THOMASSEY**

le 18 décembre 2002

*Titre :*

**METHODOLOGIE DE LA PREVISION DES VENTES APPLIQUEE A LA  
DISTRIBUTION TEXTILE**

### **JURY**

M. Jean-Marie CASTELAIN	Directeur de Recherche
Mlle Marie-Claude PORTMANN	Rapporteur
M. Gérard GOVAERT	Rapporteur
M. Michel HAPPIETTE	Co-directeur de Recherche
M. Antonio FIORDALISO	Examineur
Mme Anne-Marie JOLLY-DESODT	Examineur
M. Besoa RABENASOLO	Examineur
M. Noël DEWAELE	Invité

*A mes parents*

## Remerciements

Ce travail a été réalisé dans le cadre d'un projet dénommé AIDE, soutenu par le MINISTERE DE L'ECONOMIE, DES FINANCES ET DE L'INDUSTRIE, au sein du laboratoire de recherche GEMTEX (Génie des Matériaux TEXTiles) de l'ENSAIT (Ecole Nationale Supérieure des Arts et Industries Textiles) de Roubaix et de l'IFTH (Institut Français du Textile et de l'Habillement) de Villeneuve d'Ascq.

Je tiens à exprimer toute ma gratitude et mes plus vifs remerciements à :

Monsieur Jean-Marie Castelain, Professeur et directeur de l'ENSAIT, co-directeur de recherche, pour avoir dirigé ce travail de thèse et pour ses conseils et son soutien,

Monsieur Gérard Govaert, Professeur à l'Université Technologique de Compiègne et Mademoiselle Marie Claude Portmann, Professeur à l'Ecole de Mines de Nancy, pour avoir accepté d'être les rapporteurs de ces travaux,

Monsieur Michel Happiette, Maître de conférences à l'ENSAIT et co-directeur de recherche, pour ses conseils, ses encouragements, sa disponibilité et son dévouement,

Monsieur Antonio Fiordaliso, Docteur en mathématiques et coordinateur du Centre d'Etude de la Logique Floue et ses Applications (CELOFA) de la Faculté Polytechnique de Mons (Belgique), pour avoir accepté d'être examinateur de ces travaux,

Madame Anne-Marie Jolly, Professeur et directrice adjointe de l'ENSAIT, pour ses remarques et conseils et pour avoir accepté d'être examinatrice de ces travaux,

Monsieur Besoa Rabenasolo, Maître de conférences à l'ENSAIT, pour ses remarques et conseils et pour avoir accepté d'être examinateur de ces travaux,

Monsieur Noël Dewaele, Responsable de l'activité logistique de l'IFTH, pour ses conseils avisés, son soutien et sa participation au jury en temps qu'invité.

Je souhaite remercier Monsieur Bernard Deltète, directeur de la délégation régionale IFTH de Villeneuve d'Ascq, et tout son personnel qui m'ont généreusement accueilli au sein de leur entreprise durant ces 3 années, ainsi que tout le personnel du GEMTEX de l'ENSAIT qui ont contribué au bon déroulement de mon travail de recherche.

J'adresse également mes remerciements au personnel de la société Kiabi, et plus particulièrement à Messieurs Desuarte, Doucy, Costeur, Salé, Girard et Madame Reigner qui par le biais d'un partenariat, ont collaboré au développement de nos travaux.

Enfin, je remercie Monsieur Jacques Tellier, Chargé de mission à la Direction Textile/ Habillement/ Cuir/ Importations du Ministère de l'Economie, des Finances et de l'Industrie, pour avoir permis la concrétisation du projet AIDE.

---

# TABLE DES MATIERES

<b>INTRODUCTION GENERALE .....</b>	<b>11</b>
<b>CHAPITRE 1 - CONTEXTE TEXTILE .....</b>	<b>15</b>
<b>1.1 INTRODUCTION .....</b>	<b>15</b>
<b>1.2 PRESENTATION DU SECTEUR TEXTILE-HABILLEMENT- DISTRIBUTION (THD) .....</b>	<b>15</b>
1.2.1 MARCHE DU TEXTILE .....	15
1.2.2 FILIERE THD.....	17
1.2.2.1 <i>Présentation</i> .....	17
1.2.2.2 <i>Organisation</i> .....	18
1.2.2.2.1 Industries du textile et de l'habillement.....	18
1.2.2.2.2 Distribution textile.....	19
1.2.2.3 <i>Contexte de la prévision</i> .....	21
1.2.2.3.1 Rôle d'un système de prévision .....	21
1.2.2.3.2 Caractéristiques de la prévision.....	21
1.2.2.4 <i>Prévision du distributeur</i> .....	22
<b>1.3 CARACTERISTIQUES DE VENTE DES ARTICLES TEXTILES.....</b>	<b>23</b>
1.3.1 CODIFICATION .....	24
1.3.2 CYCLE DE VIE.....	24
1.3.3 SAISONNALITE DES VENTES .....	25
1.3.4 VARIABLES EXPLICATIVES .....	25
<b>1.4 CONCLUSION.....</b>	<b>29</b>

<b>CHAPITRE 2 - METHODOLOGIE DE PREVISION.....</b>	<b>31</b>
<b>2.1 INTRODUCTION.....</b>	<b>31</b>
<b>2.2 MISE EN ŒUVRE D'UN SYSTEME DE PREVISION .....</b>	<b>31</b>
<b>2.3 MODELES DE PREVISION DES SERIES TEMPORELLES.....</b>	<b>36</b>
2.3.1 PRINCIPE GENERAL.....	37
2.3.1.1 Notations .....	37
2.3.1.2 Réglage des paramètres .....	38
2.3.1.3 Elaboration d'un modèle .....	38
2.3.1.4 Evaluation de la qualité d'un modèle.....	40
2.3.2 MODELES CLASSIQUES .....	43
2.3.2.1 Méthodes de lissage .....	44
2.3.2.2 Méthodes basées sur les processus du type ARIMA.....	44
2.3.2.3 Autres méthodes .....	45
2.3.3 LIMITES DES MODELES CLASSIQUES .....	46
2.3.4 MODELES ISSUS DU "SOFT COMPUTING" .....	47
2.3.4.1 Modèles basés sur les techniques neuronales .....	47
2.3.4.1.1 RNA et les modèles de prévision .....	48
2.3.4.1.2 Avantages et inconvénients des RNA .....	49
2.3.4.2 Modèles basés sur les techniques floues .....	49
2.3.4.2.1 SIF et les modèles de prévision.....	50
2.3.4.2.2 Avantages et inconvénients des SIF .....	51
2.3.4.3 Modèles basés sur les algorithmes évolutionnistes.....	52
2.3.4.3.1 Algorithmes génétiques et modèles de prévision.....	52
2.3.4.3.2 Programmation génétique et modèles de prévision.....	52
2.3.4.3.3 Avantages et inconvénients des algorithmes évolutionnistes .....	53
2.3.4.4 Modèles basés sur les techniques hybrides .....	53
2.3.5 MODELES DE PREVISION DU MARCHE .....	54
<b>2.4 METHODES DE CLASSIFICATION.....</b>	<b>54</b>
2.4.1 PRINCIPE GENERAL.....	55
2.4.2 CLASSIFICATION HIERARCHIQUE ASCENDANTE .....	55
2.4.3 CLASSIFICATION FLOUE.....	56

2.4.4	CRITERES DE CLASSIFICATION .....	56
2.4.5	EVALUATION D'UNE PARTITION .....	57
<b>2.5</b>	<b>CONCLUSION.....</b>	<b>57</b>
<b>CHAPITRE 3 - PROPOSITION D'UN SYSTEME DE</b>		
<b>PREVISION .....</b>		
<b>3.1</b>	<b>INTRODUCTION.....</b>	<b>59</b>
<b>3.2</b>	<b>PREVISION A LA FAMILLE.....</b>	<b>61</b>
3.2.1	PREVISION MOYEN TERME A LA FAMILLE .....	62
3.2.1.1	<i>Modèle HFCCX.....</i>	62
3.2.1.1.1	Principe.....	62
3.2.1.1.2	Présentation du SIF .....	64
3.2.1.1.3	Variables explicatives et classes d'appartenance associées.....	65
3.2.1.1.4	Apprentissage et réglage du SIF.....	67
3.2.1.1.5	Variante neuronale : modèle HNCCX.....	69
3.2.1.1.6	Résumé des caractéristiques.....	70
3.2.1.2	<i>Modèle AHFCCX.....</i>	71
3.2.1.3	<i>Classification des familles.....</i>	73
3.2.1.3.1	Problématique.....	73
3.2.1.3.2	Propriétés de la stratégie proposée .....	73
3.2.1.4	<i>Conclusion de la prévision moyen terme à la famille.....</i>	74
3.2.2	PREVISION COURT TERME A LA FAMILLE .....	75
3.2.2.1	<i>Modèle SAMANN.....</i>	75
3.2.2.1.1	Structure du réseau de neurones.....	75
3.2.2.1.2	Entrées et sorties.....	76
3.2.2.1.3	Initialisation et apprentissage.....	77
3.2.2.1.4	Résumé des caractéristiques.....	77
3.2.2.2	<i>Modèle SAMANFIS.....</i>	77
3.2.2.2.1	Propriétés du SIF .....	77
3.2.2.2.2	Propriétés du réseau de neurones .....	78

3.2.2.3	<i>Conclusion de la prévision court terme à la famille</i> .....	79
3.2.3	CONCLUSION DE LA PREVISION A LA FAMILLE .....	79
<b>3.3</b>	<b>PREVISION A L'ARTICLE</b> .....	<b>80</b>
3.3.1	PREVISION MOYEN TERME A L'ARTICLE .....	80
3.3.1.1	<i>Modèle IDA</i> .....	81
3.3.1.1.1	Principe .....	81
3.3.1.1.2	Résumé des caractéristiques .....	82
3.3.1.2	<i>Modèle IDAC</i> .....	83
3.3.1.2.1	Principe .....	83
3.3.1.2.2	Caractéristiques de la classification .....	84
3.3.1.2.3	Résumé des caractéristiques .....	85
3.3.1.3	<i>Conclusion de la prévision moyen terme à l'article</i> .....	85
3.3.2	PREVISION COURT TERME A L'ARTICLE .....	86
3.3.3	CONCLUSION DE LA PREVISION A L'ARTICLE .....	86
<b>3.4</b>	<b>PREVISION AU COLORIS ET A LA TAILLE</b> .....	<b>87</b>
3.4.1	PREVISION AU COLORIS .....	87
3.4.2	PREVISION A LA TAILLE .....	87
3.4.3	CONCLUSION DE LA PREVISION AU COLORIS / TAILLE .....	88
<b>3.5</b>	<b>CONCLUSION</b> .....	<b>88</b>
<b>CHAPITRE 4 - EXPERIMENTATION DU SYSTEME DE</b>		
<b>PREVISION</b> .....		<b>90</b>
<b>4.1</b>	<b>INTRODUCTION</b> .....	<b>90</b>
<b>4.2</b>	<b>CARACTERISTIQUES DU JEU DE DONNEES</b> .....	<b>91</b>
4.2.1	DONNEES DE VENTES .....	91
4.2.1.1	<i>Ventes par famille</i> .....	91
4.2.1.2	<i>Ventes par article</i> .....	93
4.2.2	VARIABLES EXPLICATIVES .....	94
<b>4.3</b>	<b>MODELES DE PREVISION DE REFERENCE</b> .....	<b>96</b>

<b>4.4</b>	<b>PREVISION A LA FAMILLE.....</b>	<b>98</b>
4.4.1	PREVISION MOYEN TERME A LA FAMILLE .....	98
4.4.1.1	<i>Modèles HFCCX et HNCCX.....</i>	98
4.4.1.1.1	Présentation .....	98
4.4.1.1.2	Résultats .....	99
4.4.1.1.3	Analyse.....	101
4.4.1.2	<i>Modèle AHFCCX.....</i>	102
4.4.1.2.1	Présentation .....	102
4.4.1.2.2	Comparatif des modèles HFCCX et AHFCCX.....	103
4.4.1.2.3	Analyse de la sélection des règles d'inférence du modèle AHFCCX.....	104
4.4.1.2.4	Etude du modèle AHFCCX sur 322 familles.....	108
4.4.1.2.5	Apport de la classification.....	111
4.4.1.2.6	Apprentissage sur trois années d'historique .....	112
4.4.1.3	<i>Conclusion de la prévision moyen terme à la famille .....</i>	113
4.4.2	PREVISION COURT TERME A LA FAMILLE .....	114
4.4.2.1	<i>Présentation .....</i>	114
4.4.2.2	<i>Résultats .....</i>	114
4.4.2.3	<i>Analyse .....</i>	117
4.4.2.4	<i>Conclusion de la prévision court terme à la famille .....</i>	118
4.4.3	CONCLUSION DE LA PREVISION A LA FAMILLE.....	118
<b>4.5</b>	<b>PREVISION A L'ARTICLE.....</b>	<b>120</b>
4.5.1	PREVISION MOYEN TERME A L'ARTICLE .....	120
4.5.1.1	<i>Présentation .....</i>	120
4.5.1.2	<i>Résultats .....</i>	121
4.5.1.3	<i>Analyse .....</i>	123
4.5.1.4	<i>Conclusion de la prévision moyen terme à l'article.....</i>	123
4.5.2	PREVISION COURT TERME A L'ARTICLE .....	124
4.5.2.1	<i>Présentation .....</i>	124
4.5.2.2	<i>Résultats .....</i>	124
4.5.2.3	<i>Analyse .....</i>	125
4.5.2.4	<i>Conclusion de la prévision court terme à l'article.....</i>	125
<b>4.6</b>	<b>PREVISION TAILLE/COLORIS.....</b>	<b>125</b>

4.6.1	PRESENTATION .....	125
4.6.2	RESULTATS .....	126
4.6.3	ANALYSE.....	128
4.6.4	CONCLUSION DE LA PREVISION TAILLE / COLORIS .....	129
<b>4.7</b>	<b>CONCLUSION.....</b>	<b>129</b>
	 <b>CONCLUSION GENERALE.....</b>	 <b>132</b>
	 <b>REFERENCES BIBLIOGRAPHIQUES.....</b>	 <b>138</b>

## **Introduction générale**

Comme dans la plupart des domaines industriels, l'environnement très concurrentiel de la filière Textile-Habillement-Distribution (THD) imposent aux industriels une gestion rigoureuse de leur approvisionnement, production et distribution. La gestion de la chaîne d'approvisionnement, appelé couramment "Supply Chain Management" (SCM) (Lee, 1995), permet de prendre en compte tous ces processus depuis l'expression des besoins jusqu'à la livraison des produits finis. Ce concept utilise des outils intervenant à différentes phases et à divers endroits de la chaîne logistique : APS (Advanced Planning System), ERP (Entreprise Ressource Planning), MRP2 (Manufacturing Ressource Planning), DRP (Distribution Requirement Planning), CRM (Customer Relationship Management), EDI (Electronic Data Information),... et englobant différentes fonctions telles que les achats, les approvisionnements, la planification de production, la gestion de la demande, la gestion des stocks, le transport, le service client et les échanges d'informations. Mais, si toutes les méthodes citées précédemment permettent d'améliorer la réactivité de la filière THD, les nombreuses transformations nécessaires à la réalisation d'un article textile imposent des délais de fabrication toujours importants et peu compressibles. La mondialisation, qui provoque la dispersion des acteurs de la filière, ne favorise pas non plus la diminution de ces délais. Les industriels sont donc souvent amenés à anticiper la fabrication et à stocker les produits afin de répondre aux demandes des clients. L'objectif des distributeurs est de proposer le juste produit, au juste endroit et au juste prix, tout en recherchant le juste stock (stock minimal). Cette double contrainte "taux de service maximum / stock minimum" implique la mise en place d'un système performant de prévision des ventes. L'anticipation des demandes des consommateurs au niveau du distributeur permet alors de gérer au plus juste les approvisionnements et par conséquent la production des industries en amont de la filière. Ainsi, l'efficacité de l'optimisation de la chaîne d'approvisionnement dépend essentiellement de la précision des prévisions de ventes des produits finis (Sbouï, 2001)(Graves, 1998).

Cette étude a été effectuée dans le cadre d'un projet baptisé AIDE dont l'objectif est de proposer un outil global d'Aide à la Décision visant une amélioration de la compétitivité et de la performance des industries de la filière Textile Habillement Distribution (T/H/D). Ce projet réunit : l'Institut Français du Textile et de l'Habillement (IFTH), l'École Nationale Supérieure des Arts et Industries Textiles (ENSAIT) par l'intermédiaire de son

laboratoire de recherche GEMTEX et des industriels de la filière Textile-Habillement-Distribution.

Il consiste préalablement à définir, valider et mettre en œuvre une méthodologie pour la prévision de ventes d'articles textiles à destination des fabricants, quel que soit leur niveau dans la filière (1<sup>er</sup> volet du projet AIDE). Cette prévision permettra ensuite d'élaborer et d'optimiser la stratégie d'approvisionnement et de production de tous les acteurs de la filière (2<sup>ème</sup> volet du projet AIDE). Les algorithmes obtenus seront alors implémentés à travers un outil informatique qui pourra être complémentaire d'un système décisionnel propre au distributeur.

Ce projet fait suite également à des premiers travaux de recherche, menés au laboratoire GEMTEX, portant principalement sur des problèmes liés à la modélisation, la classification (Boussu, 1998) et la prévision (Vroman, 2000) au sein de la filière textile.

Pour répondre aux spécificités du marché textile, le système proposé doit principalement :

- réaliser sur un très grand nombre de références (de l'ordre de 15000 par an) des prévisions à des horizons différents (de un an à une semaine),
- utiliser des historiques courts (références non renouvelées et durée de vie très faible des articles d'un à deux mois),
- prendre en compte de nombreux facteurs, appelés variables explicatives, influençant les ventes (données météorologiques et calendaires, actions marketing,...),
- permettre l'intervention aisée du décideur.

La prévision est utilisée dans de nombreux domaines comme la finance, l'économie, la météorologie, la production d'énergie, la sociologie... Parmi les nombreux modèles de prévision développés, nous pouvons citer principalement les modèles heuristiques et statistiques (Armstrong, 2001). Les premiers sont basés sur l'exploitation des opinions ou intentions d'un groupe de personnes ou d'experts ; ils sont principalement employés dans le domaine du marketing. Les modèles statistiques exploitent les données historiques. Dans cette catégorie figurent la moyenne mobile, le lissage exponentiel, le modèle SARIMAX et ses variantes (ARMA, ARX, ...) utilisable avec la méthode de Box et Jenkins (Mélard, 1990)(Bourbonnais, 1992)(Lewandoski, 1983), ou encore les modèles non-linéaires classiques (GARCH, SETAR,...) (Tong, 1990)(De Gooijer, 1992). De nombreux logiciels disponibles sur le marché (*Walter's, Forecast Pro, Predicast, Autobox, Retek,...*) exploitent

de façon automatique ces modèles. Enfin, il est possible de combiner les méthodes intuitives et quantitatives, comme par exemple les systèmes experts (Collopy, 2001).

Cependant, les performances de ces modèles dépendent fortement du champ d'application, de l'expérience de l'utilisateur et de l'horizon de prévision (Dasgupta, 1994) (Vroman, 2000). Leur efficacité repose, en effet, sur la présence d'historiques suffisamment fiables et importants pour assurer une sélection correcte de la structure et un réglage efficace des paramètres adéquats. Le nombre important de références différentes et de facteurs influençant les ventes d'articles textiles qui ne sont parfois non contrôlés ni même identifiés (De Toni, 2000), implique l'utilisation de nouveaux modèles au détriment des modèles classiques. En effet, ces derniers sont souvent incapables de modéliser des séries temporelles comportant des historiques réduits.

Ainsi, ces dernières années, des méthodes issues du "soft computing" ont été largement utilisées pour la prévision. Les réseaux de neurones sont particulièrement exploités par les prévisionnistes (Zhang, 1998)(Yoo, 1999)(Wasserman, 1989)(White, 1992). Bien que l'apport de ces modèles par rapport aux modèles classiques semble mitigé dans certains contextes (Armstrong, 2001)(Hill, 1994)(Kuo, 2001), leur capacité à modéliser des relations non-linéaires et leur faculté d'apprentissage et d'adaptation en font des outils de prévision très performants. Les systèmes d'inférence flous, pouvant modéliser les connaissances humaines et étant facilement interprétables, sont également employés dans le domaine de la prévision (Fiordaliso, 1999)(Mastorocostas, 2000)(Klir, 1995) : ils sont notamment très intéressants pour quantifier l'influence des variables explicatives des séries temporelles (Kuo, 1999). Enfin, la combinaison de plusieurs techniques du "soft computing" (réseaux de neurones, logique floue et algorithmes génétiques) permet de réaliser des systèmes adaptatifs capables d'apprendre des relations complexes en milieu incertain (Kuo, 1998)(Van Lith, 2000). Cet ensemble de caractéristiques nous a amené à traiter les contraintes spécifiques au domaine textile, en appliquant les techniques du "soft computing" à notre système de prévision des ventes d'articles.

Le premier chapitre rappelle le contexte du domaine textile. La connaissance de l'environnement de la prévision est très importante afin de prendre en compte toutes les exigences et tous les besoins liés au champ d'application. Nous nous intéressons aux caractéristiques de la filière THD, présentons les spécificités et les exigences de la distribution, et analysons le comportement de ventes des articles textiles.

Le second chapitre aborde la problématique de la prévision. Après un bref rappel des méthodes de prévisions existantes, nous nous attachons plus précisément aux modèles classiques de prévision de séries temporelles qui serviront de modèles de références. Puis, nous présentons les méthodes issues du "soft computing". Nous distinguons les techniques neuronales, floues et évolutionnistes, et abordons les possibilités offertes par ces outils, notamment en terme d'apprentissage et de modélisation. Nous établissons ensuite un état des travaux sur la prévision, réalisés à l'aide de ces techniques. Enfin, sont présentés quelques logiciels de prévision disponibles sur le marché.

Le troisième chapitre propose un système de prévision de ventes répondant à la filière textile. Il est composé de six modèles. Les deux premiers modèles réalisent des prévisions à moyen terme (une saison) et court terme (une semaine) sur des données de ventes agrégées en famille d'articles. Le modèle de prévision à moyen terme est basé sur le traitement de variables explicatives par un Système d'Inférence Flou (SIF). Le modèle de prévision à court terme se décline en différentes versions (neuronale ou floue) dont le principe commun est de réactualiser les prévisions élaborées à moyen terme en fonction des ventes réelles des dernières semaines. L'agrégation des données, appliquée en amont de ces deux premiers modèles, permet d'obtenir des historiques exploitables. Le troisième modèle reposant sur une technique de répartition permet d'obtenir des prévisions par article. Une classification quantitative positionnée en amont de ce dernier modèle est également envisagée pour améliorer la précision de la prévision. Le quatrième modèle aborde la prévision des ventes à court terme au niveau article. Son principe est identique à celui appliqué au niveau famille. Les cinquième et sixième modèles qui concernent les prévisions à la taille et au coloris, sont basés sur la notion de répartition des prévisions au niveau article.

Le quatrième chapitre développe les applications de nos modèles sur une base de données réelle provenant d'un important distributeur de prêt-à-porter français, "Kiabi". Cette base est constituée des historiques de ventes de 40000 références réparties sur trois ans. Après avoir décrit ces historiques et les variables explicatives choisies, nous comparons les résultats de nos modèles avec ceux des modèles classiques.

Enfin, l'analyse des expérimentations et des résultats permet de suggérer des perspectives de développement.

# Chapitre 1

## Contexte textile

### 1.1 Introduction

Notre objectif est de réaliser pour la filière textile un modèle de prévision des ventes exploitable par le distributeur.

De nombreux travaux réalisés sur la prévision des ventes donnent des résultats plus ou moins satisfaisants dans des domaines divers tels que l'agro-alimentaire (Allen, 1994) ou la circulation automobile (Smith, 2002). Ces études permettent une première approche de notre problème, mais tout système prévisionnel performant est généralement spécifique au domaine d'application visé (Dasgupta, 1994).

La filière Textile-Habillement-Distribution (THD) est très complexe et très diversifiée en terme de contraintes organisationnelles et de caractéristiques de ventes. Ainsi, il est fort probable qu'un modèle de prévision adapté au marché textile, puisse être applicable à d'autres domaines au contexte semblable ou à des processus de vente plus simples.

Nous présentons dans ce chapitre le fonctionnement et les propriétés de la filière THD et plus spécifiquement de la distribution. Nous développons ensuite les particularités de ventes des articles textiles.

### 1.2 Présentation du secteur Textile-Habillement-Distribution (THD)

Nous présentons dans cette section, l'aspect économique du marché du textile mondial et français, la composition et le fonctionnement de la filière THD, et également le concept de prévision des ventes.

#### 1.2.1 Marché du textile

Dans le domaine très large du textile, trois marchés prédominent : l'habillement, le textile de maison et les textiles techniques. En dix ans, le commerce mondial de ces marchés a progressé en volume de 58 % pour atteindre 334 milliards de dollars en 1999 (source : OMC 2000). Il est globalement prévu à la hausse pour la période allant jusque

2005 (source : IFM/CTCOE, 2000). Mais, devant la forte croissance de ces échanges, divers obstacles sont apparus très gênants tels que les droits de douanes, les systèmes tarifaires dissuasifs, les contraintes d'étiquetage, les normalisations excessives, etc... Ainsi, différentes associations d'entreprises textiles basées sur les notions de proximité géographique et de réactivité sont apparues, créant alors de nouveaux espaces commerciaux tels l'ALENA aux USA, l'ASEAN ou le SAARC en Asie et l'Euro-méditerranéen en Europe et au Maghreb.

Le marché français (figure 1.1) est particulièrement soumis à diverses contraintes qui pèsent sur la compétitivité du textile : la mise en place des 35 heures, la hausse des coûts énergétiques et de matières premières, la résurgence des fragilités structurelles au sein des économies émergentes (volatilité des monnaies asiatiques, crise financière et monétaire en Turquie,...) et enfin l'important ralentissement de la croissance économique aux USA (accentué depuis le 11 septembre 2001) qui a partiellement et indirectement désorganisé l'ensemble des marchés mondiaux. Le textile français est également soumis à une dépendance extérieure de plus en plus forte imposée par la forte importation des produits confectionnés à faible coût. Cependant, malgré ces difficultés, le secteur textile reste l'un des piliers de l'économie française. Deuxième employeur industriel derrière l'automobile, il contribue puissamment à "vasculariser" l'espace territorial au travers de très nombreux établissements de production, de transformation et de distribution (source UIT 2002).

Afin de répondre aux objectifs fixés pour l'horizon 2005, année de la libéralisation des marchés textiles mondiaux : 15,25 milliards d'euros d'exportation, recrutement de 10000 jeunes demandeurs d'emploi, augmentation de 30 % de l'investissement de formation (source UIT 2002), le secteur textile doit continuer à développer ses points forts : les industries spécialisées à haut contenu d'innovation et de création, la mode haut de gamme et de luxe, les nouveaux textiles techniques, les technologies et logistiques avancées qui requièrent des ressources humaines à fort potentiel de compétences et le travail en réseau avec système d'intégration des marques. Enfin, la concurrence oblige chacun des acteurs de la filière, notamment les producteurs, à définir des facteurs gagnants de différenciation spécifiques : créativité, réactivité, proximité, marketing, qualité, connaissance du client, service.

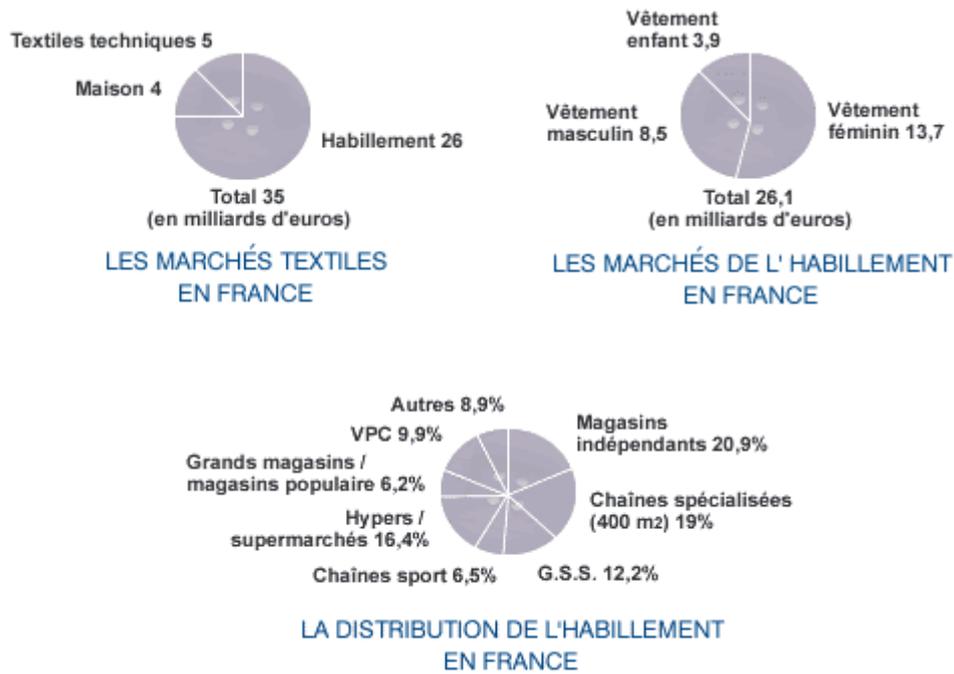


Figure 1.1. Chiffres des marchés THD en France en 1998 (source : UIT 2001)

## 1.2.2 Filière THD

### 1.2.2.1 Présentation

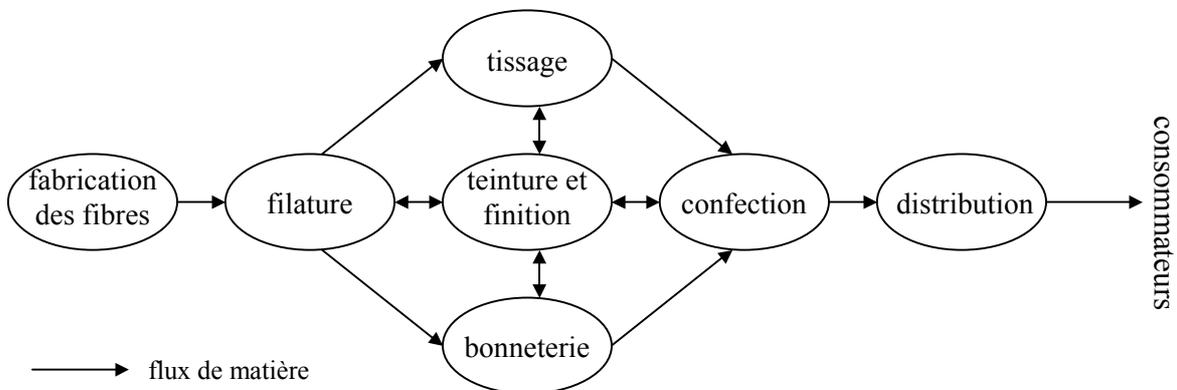


Figure 1.2. Flux de matière dans la filière textile

La filière THD regroupe tous les métiers intervenant dans la conception, la fabrication et la distribution d'un article textile. Ces métiers peuvent être réalisés partiellement ou totalement au sein d'une même entreprise (par exemple une entreprise peut réaliser le tricotage et la confection de ses produits). La fabrication d'un produit fini peut suivre différents parcours à travers la filière en fonction de ses caractéristiques (par exemple, une chemise peut être réalisée à partir de fils tissés puis teints, ou inversement à partir de fils

teints puis tissés). La figure 1.2 représente un exemple de possibilités de flux matières de la filière textile.

Les principales étapes de la filière sont :

- la fabrication et récolte des fibres : le fabricant produit le filament artificiel (viscose,...) ou synthétique (polyester, polyamide,...), et récolte la fibre naturelle (laine, coton, soie,...).
- la filature : le filateur conçoit le fil ou filé à partir des fibres.
- le tissage : le tisseur réalise le tissu à partir des bobines de fils.
- la bonneterie (ou tricotage) : le bonnetier crée le tricot à partir des bobines de fils.
- la teinture et finition : le teinturier apporte la coloration, l'impression ou l'apprêt sur la bobine de fil, le tissu ou le tricot.
- la confection : le confectionneur découpe et assemble des tissus ou tricots pour élaborer un produit fini.
- la distribution : le distributeur vend l'article fini au consommateur dans des magasins en intégrant généralement la création des articles ainsi que toute la logistique de mise en œuvre pour la vente des produits finis (planification, stockage, livraison,...).

Enfin, le consommateur, acteur primordial de la filière (figure 1.2) devenant de plus en plus exigeant et versatile, impose un couplage de plus en plus important des prévisions des ventes et de la gestion des approvisionnements.

### **1.2.2.2 Organisation**

#### *1.2.2.2.1 Industries du textile et de l'habillement*

Afin de rester compétitives dans un environnement international très concurrentiel, les industries textiles (filature, tissage, bonneterie, teinturerie,...) ont été amenées à se moderniser.

Les avancées technologiques dans le domaine de l'automatisation ont permis d'accroître la productivité et l'adaptabilité tout en réduisant les coûts. Cependant, le coût de la main d'œuvre étant un élément essentiel pour les acteurs de la filière textile, et particulièrement la confection, ceux-ci se sont délocalisés vers les marchés internationaux.

Parallèlement, les derniers confectionneurs français performants, pour augmenter leur compétitivité, favorisent la production de petites séries de références plutôt haut de gamme en circuit court. Ils représentent ainsi les clients privilégiés des distributeurs pour les réapprovisionnements avec délai réduit des articles aux critères de qualité élevés.

1.2.2.2.2 *Distribution textile*

Afin de répondre aux exigences du consommateur et faire face à la concurrence, le distributeur doit s'appuyer sur une organisation efficace de sa filière. Pour réduire les coûts de fabrication, le distributeur s'oriente vers des fournisseurs de plus en plus lointains (Maghreb, Europe de l'Est et plus récemment Asie, Amérique du sud). Basée en partie sur l'existence de plates formes de stockage internationales, nationales, et régionales permettant d'alimenter un nombre croissant de magasins de vente, la gestion partagée des approvisionnements devient alors plus complexe.

Ces vingt dernières années, le développement de nouveaux outils, regroupés sous l'appellation Supply Chain Management (SCM), a permis une amélioration de la gestion et du suivi de la production et des approvisionnements. L'objectif actuel du distributeur est d'optimiser la planification et la synchronisation des flux informationnels et matières tout au long de la filière.

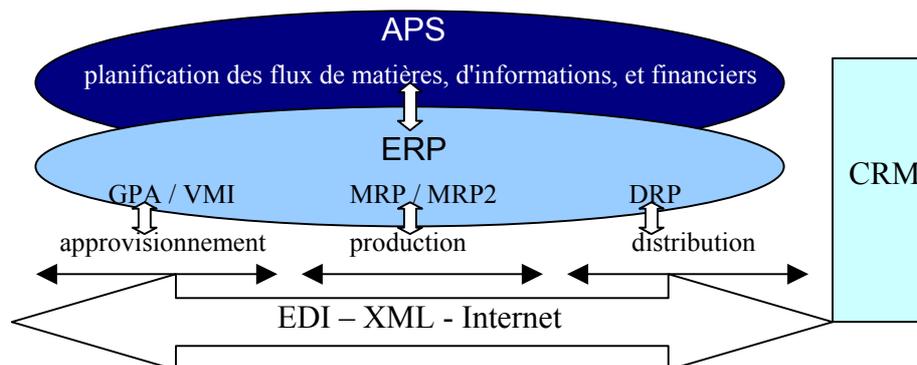


Figure 1.3. Relations entre quelques outils de la SCM pour la chaîne logistique

Le concept de SCM est constitué de plusieurs procédés réalisant diverses tâches de la chaîne logistique. Nous pouvons citer les principaux outils suivants (figure 1.3) :

- APS (Advanced Planning System) planifie et synchronise l'ensemble des flux (de matières, d'informations et financiers) de la chaîne logistique,
- ERP (Entreprise Ressource Planning) intègre dans l'entreprise différents processus tels la gestion comptable et financière, le contrôle de gestion, la gestion de production (basée généralement sur le concept de MRP), la gestion de maintenance, la gestion des achats et des stocks, l'administration des ventes, la logistique de distribution (souvent fondée sur le concept de DRP) ou encore les ressources humaines,

- GPA (Gestion Partagé des Approvisionnements) et VMI (Vendor Managed Inventory) permettent une approche des approvisionnements sécurisés, continus, optimisés et pilotés par le fournisseur,
- MRP2 (Manufacturing Resource Planning) planifie l'ensemble de la production et des ressources.
- DRP (Distribution Requirement Planning) gère les flux depuis la demande jusqu'aux approvisionnements des produits finis,
- CRM (Customer Relationship Management) améliore les relations avec les clients,
- EDI (Electronic Data Information), XML (eXtended Mark-up Langage) et Internet optimisent les échanges d'informations entre les acteurs de la chaîne d'approvisionnement,

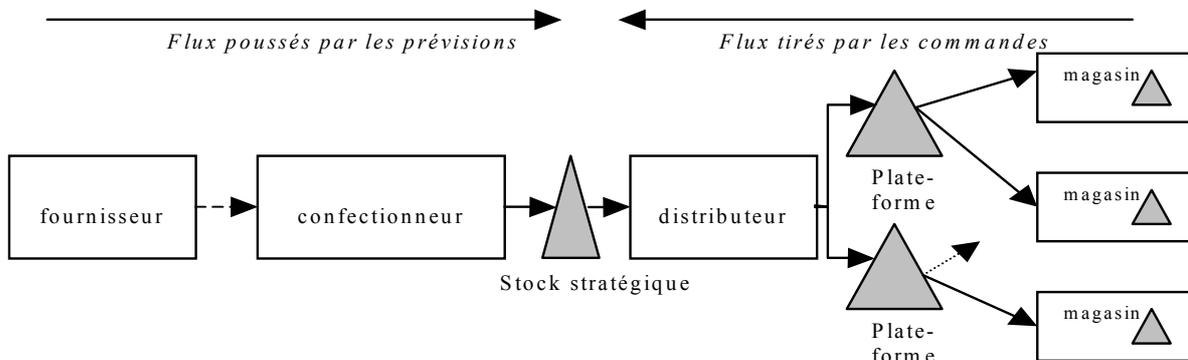


Figure 1.4. Stock stratégique et flux matière

Néanmoins, si ces outils doivent permettre une amélioration de la gestion des flux à travers la filière et un meilleur ajustement du niveau des stocks, la spécificité du contexte textile les rend insuffisant en terme de réactivité. En effet, les produits sont trop nombreux et variés, et leur délai d'obtention (environ 3 mois) trop important en comparaison de la durée de vie réduite des modèles (6 semaines en moyenne). Il est alors actuellement nécessaire d'introduire un ou des stocks stratégiques (figure 1.4) dont la position dans la filière et la taille, sont fonction des délais d'approvisionnement et de mise en rayon des produits, mais également des prévisions de la demande du consommateur. En amont du stock stratégique, les flux matières sont poussés par les prévisions estimées par le distributeur, et en aval, les flux matières sont tirés par les commandes du consommateur. La difficulté, pour le distributeur, est de déterminer le meilleur équilibre des

approvisionnement afin d'éviter les ruptures créées par une prévision pessimiste, mais également d'éviter les sur-stocks, favorisés par une prévision optimiste.

### **1.2.2.3 Contexte de la prévision**

Afin d'évaluer au plus juste la taille des stocks, un système de prévision paraît donc nécessaire. Ainsi, nous nous intéressons à la prévision décidée par le distributeur pour chacun des acteurs de la filière afin de pouvoir analyser et caractériser au plus juste le comportement des ventes. Le confectionneur, par exemple, établit sa production principalement à partir de prévisions estimées par le distributeur, ajustées par la suite par les commandes fermes. Cependant, en raison des aléas de production des fournisseurs et des demandes des clients, l'évaluation de la prévision est différente selon la situation de l'entreprise dans la filière.

#### *1.2.2.3.1 Rôle d'un système de prévision*

La prévision est nécessaire dans la mise en œuvre des procédures de la gestion de la chaîne d'approvisionnement, définies précédemment. Ainsi, les décideurs sont capables en s'appuyant sur des prédictions fiables d'optimiser l'emploi des ressources humaines et matérielles et d'ajuster au mieux la production et les stocks. Une mauvaise estimation des ventes génère un sur-stock ou une rupture qui implique pour les deux cas, une baisse de la marge bénéficiaire pour chacun des acteurs de la filière.

Au niveau commercial, l'analyse des ventes est également très importante. En effet, les actions promotionnelles et les campagnes de publicité doivent être judicieusement positionnées dans la saison.

Aussi, un système de prévision qui intègre les relations entre les ventes et les variables "marketing" (section 1.3.4) peut devenir un outil puissant d'information et d'aide à la décision du service commercial de l'entreprise.

#### *1.2.2.3.2 Caractéristiques de la prévision*

- **Implantation géographique**

Les ventes d'articles textiles sont très sensibles à la situation géographique du magasin. Les sociétés possédant un réseau de distribution très large, doivent établir des prévisions différentes pour chaque magasin. Cependant, les études réalisées dans nos travaux ne prennent en compte que les données nationales.

- Périodicité des données

Les prévisions textiles sont effectuées généralement sur des données hebdomadaires. Le distributeur maîtrise assez précisément la répartition des ventes sur les jours de la semaine (les ventes sont généralement plus importantes le samedi et le mercredi). Les données au mois sont trop agrégées pour permettre une analyse fine du comportement d'achat du consommateur.

- Horizons de prévision

La prise de décision résultant des prévisions des ventes d'articles textiles doit être envisagée dans des délais suffisants en terme de fabrication et de transport. Le contexte requiert plusieurs horizons de prévision. Compte tenu du planning de production (figure 1.5), les décideurs ont besoin de connaître à moyen terme (un an) les estimations des ventes d'articles de la saison suivante afin de passer les commandes fournisseurs. Ils ont également la nécessité de planifier à court terme (une à trois semaines) les éventuels réapprovisionnements (réassorts) avant le lancement en fabrication. Ils peuvent alors réorganiser les commandes et les livraisons au plus juste avec leurs entrepôts et leurs différents magasins.

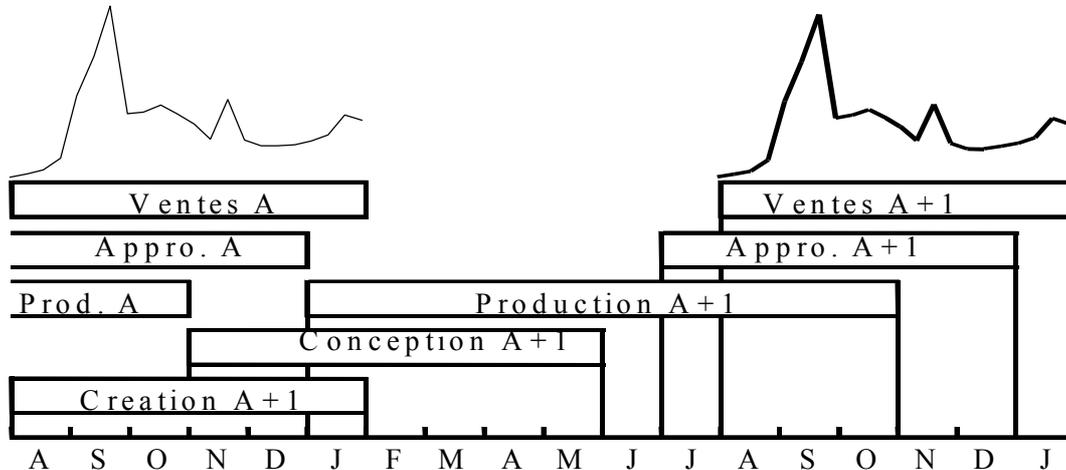


Figure 1.5. *Planning de production d'un article textile de la collection Automne-Hiver*

#### 1.2.2.4 Prévision du distributeur

Les modèles de prévisions classiques présents sur le marché sont généralement peu adaptés au contexte textile (chapitre 2). En effet, ils sont soit dépassés par les perturbations des données de ventes ou soit trop complexes à mettre en œuvre.

Ainsi, le distributeur élabore des méthodes de prévisions personnalisées basées généralement sur les estimations intuitives de ces experts. Nous proposons de décrire le principe d'une méthode actuellement utilisée chez certains distributeurs.

- **Prévision à moyen terme**

Le nombre très important de références contraint les prévisionnistes de la distribution à agréger les données de ventes au niveau famille ou rayon (section 1.3.1). Ces experts élaborent à partir de la ou des deux dernières saisons, les courbes de vie de la famille ou du rayon, qui permettent de calculer pour chaque période un indice de vente "IV".

Cet indice est réajusté intuitivement par le prévisionniste en fonction de variables explicatives considérées (section 1.3.4).

Le profil de chaque nouvel article de la saison future est alors établi à partir des IV de la famille correspondante. La quantité correspondante est ensuite estimée à partir des historiques, des objectifs et des budgets disponibles.

Une telle méthode permet une première prévision. Cependant, l'influence des variables explicatives reste trop souvent quantifiée approximativement.

- **Prévision à court terme**

La prévision à court terme d'un article est calculée à partir de la prévision à moyen terme réajustée en fonction des ventes et des prévisions des  $n$  dernières semaines ( $n$  généralement compris entre 3 et 5).

Cette méthode permet ainsi de corriger une prévision à moyen terme globalement trop optimiste ou pessimiste, mais n'est pas adaptée lorsque les ventes sont très perturbées.

### **1.3 Caractéristiques de vente des articles textiles**

Dans cette section, nous définissons les spécificités relatives aux articles textiles et aux ventes correspondantes.

### 1.3.1 Codification

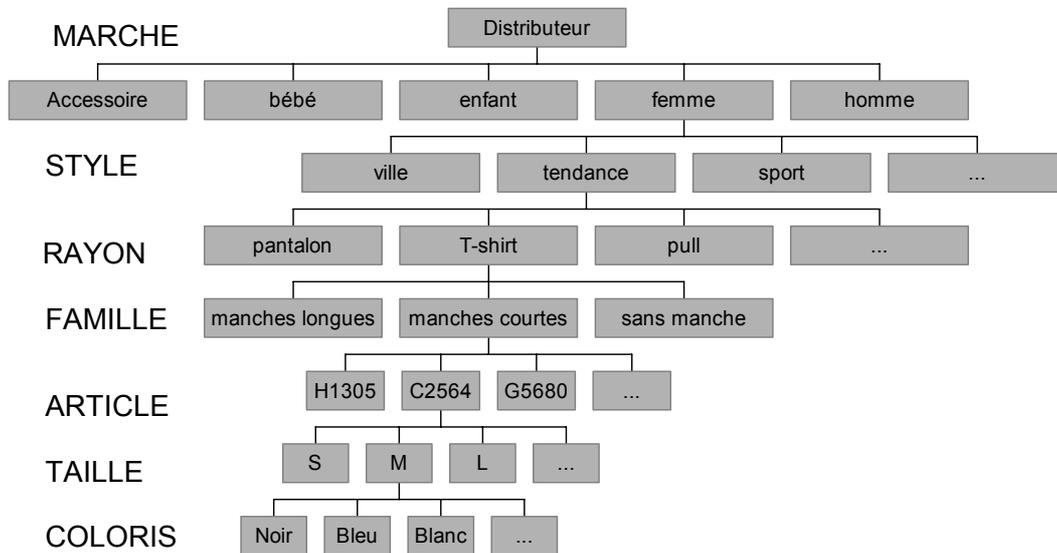


Figure 1.6. Exemple de codification des articles textiles

Compte tenu des nombreuses déclinaisons en taille et coloris, le nombre de références article traité par le distributeur est généralement très important (de l'ordre de 15000 par an). Ainsi, il devient très difficile d'exploiter les historiques de chaque référence d'autant plus que celles-ci possèdent des durées de vie très réduites (environ 6 semaines) rarement renouvelées d'une saison à l'autre (10 % en moyenne d'articles permanents). L'agrégation des ventes en famille d'articles est alors nécessaire. La difficulté réside dans le choix du niveau d'agrégation et des critères de regroupement. Si des méthodes de classification avec des critères quantitatifs ou qualitatifs peuvent être envisagées (chapitre 3), le distributeur élabore généralement une codification ou classification commerciale (figure 1.6) permettant d'assembler les articles ayant les mêmes caractéristiques en terme de style.

### 1.3.2 Cycle de vie

Le cycle de vie d'un produit décrit l'évolution des ventes depuis le lancement jusqu'à l'arrêt de la distribution de l'article considéré. On remarque quatre phases (Fenneteau, 1998) : l'introduction (ou lancement), la croissance, la maturité et le déclin. Les modèles de cycle de vie théorique les plus rencontrés sont caractérisés par une croissance rapide et un déclin lent, correspondant à la courbe représentée en figure 1.7.

Cependant, on distingue différents comportements selon le type d'articles :

- les articles basiques sont renouvelés chaque année (exemple : T-shirt simple) ou sont vendus toute l'année (exemple : jeans),
- les articles mode sont vendus de façon ponctuelle et ne sont en général pas réapprovisionnés ; les prévisions sont alors élaborées globalement et, pour certains articles, déterminées à partir du budget achat restant du distributeur.
- les articles phares sont des références renouvelées mais avec de légères modifications du style ; ces articles qui suivent les tendances de la mode en terme de couleur, de coupe ou de matière, sont distribués lors de nombreuses collections (jusqu'à 6 collections par an).

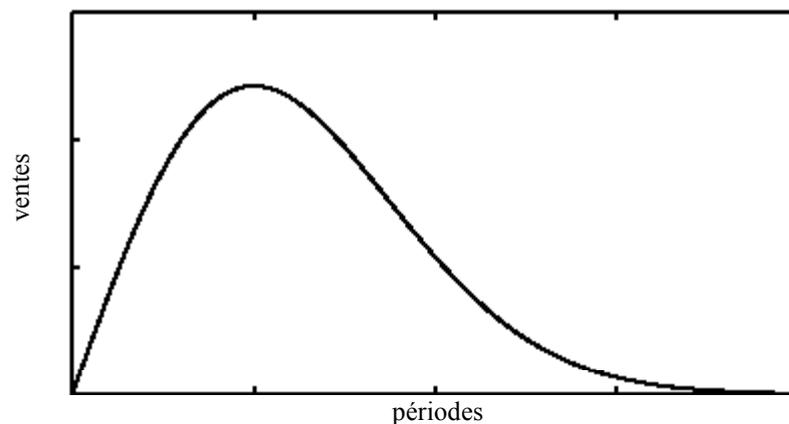


Figure 1.7. Cycle de vie théorique d'un article textile

### 1.3.3 Saisonnalité des ventes

La notion de saisonnalité est différente de celle de cycle de vie des produits. En effet, si le cycle de vie décrit l'évolution de la demande au cours de la distribution du produit, la saisonnalité représente la variation des ventes au cours de l'année ou de la saison. Certains articles, tels que les maillots de bain ou les pulls, sont plus sensibles aux facteurs saisonniers que d'autres comme les jeans ou les blouses de travail. La saisonnalité dépend également des caractéristiques du produit et du rythme des collections.

D'autres phénomènes, tels que les périodes de vacances, les variations de température, ou les périodes de promotions qui peuvent être interprétés comme facteurs saisonniers, sont considérés comme variables explicatives.

### 1.3.4 Variables explicatives

Le nombre très important de références et la durée de vie réduite des articles rendent plus difficiles les opérations de stockage et de traitement des données. Ces contraintes sont

d'autant plus importantes que le marché textile est fortement perturbé par d'innombrables facteurs qui influencent les ventes et donnent un caractère souvent incertain au marché. Ces facteurs appelés variables explicatives, qui sont souvent non contrôlés ni même connus (De Toni, 2000), rendent complexes la constitution d'une liste exhaustive et la quantification de leur influence.

Cependant, nous pouvons établir, à partir des connaissances des experts en marketing de la distribution, une classification de ces variables explicatives (figure 1.8).

Ces variables sont de deux types (Lewandowski, 1983) :

- les variables endogènes contrôlées par le distributeur telles que les périodes de promotion ; si le distributeur ne peut quantifier avec maîtrise leur influence, il peut intervenir sur leur existence ou leur période,
- les variables exogènes indépendantes du distributeur, telles les variations climatiques. Néanmoins, ce dernier peut parfois les anticiper, telles les périodes de vacances.

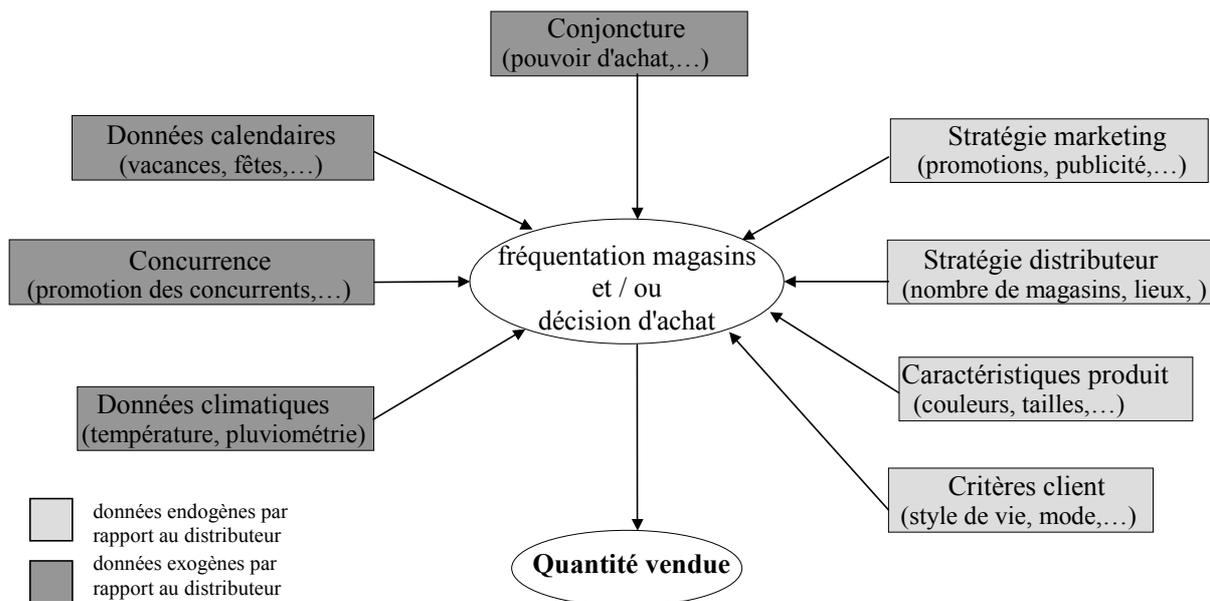


Figure 1.8. Différentes catégories de variables explicatives

Parmi ces variables, nous pouvons différencier les facteurs quantitatifs et qualitatifs. Les variables telles que le prix ou la température sont dites quantitatives, alors que le coloris ou la tendance de la mode sont dites qualitatives. Ces dernières sont plus difficilement exploitables par un système de prévision classique.

Nous pouvons séparer également les variables influençant la fréquentation des magasins de celles assurant la décision d'achat du consommateur (Little, 1998). Le trafic

magasin est lié essentiellement aux facteurs tels la publicité dans les médias pour des produits d'appel. La décision d'achat peut être favorisée par des variables telles que les promotions (avec ou sans baisse de prix). Certaines variables explicatives influencent les deux notions précédentes (périodes de fêtes, soldes, météorologie,...).

Ces facteurs peuvent être aussi différenciés selon leur influence sur les ventes. Certains, comme les données conjoncturelles, affectent la quantité totale des ventes. D'autres, comme les promotions ponctuelles, ne perturbent que l'allure des courbes de ventes (figure 1.9).

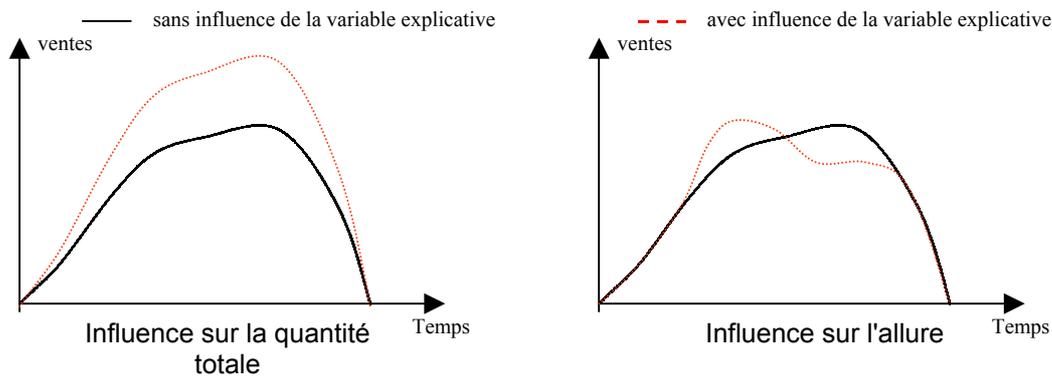


Figure 1.9. Différents types d'influences des variables explicatives

Suite à toutes les remarques précédentes sur les variables explicatives, nous pouvons principalement identifier les différentes catégories suivantes (figure 1.8) :

- les données météorologiques (température, pluviométrie,...) sont très influentes sur les ventes d'articles textiles. Cependant, elles ne sont pas maîtrisables ou trop incertaines et les horizons des prévisions météorologiques sont trop courts (une semaine maximum) pour être exploités dans notre contexte.
- la concurrence devient de plus en plus forte dans l'environnement textile et constitue donc un facteur important de l'évolution des ventes. Les distributeurs ont généralement accès aux volumes, chiffres d'affaires et parts de marché de leurs concurrents par l'intermédiaire d'organismes telles que le SECODIP, l'INSEE ou le CTCOE. Néanmoins, certains facteurs comme l'image de marque (Gupta, 1996) ou les campagnes de publicité des concurrents sont difficilement intégrables dans un système de prévision.
- les données calendaires, telles que les périodes de vacances, la rentrée des classes ou les jours de fêtes, produisent souvent des variations significatives des ventes.

Ces variables sont en général connues suffisamment à l'avance pour être prises en compte par les prévisions.

- la stratégie marketing regroupe les promotions liées au produit avec baisse de prix, les mises en avant du produit sans baisse de prix ou encore les actions publicitaires pour le distributeur ou pour des produits d'appel. Ces facteurs sont maîtrisés par le distributeur et peuvent ainsi être intégrés au système de prévision.
- la stratégie du distributeur est traduite par le mode de distribution (grande surface, magasins spécialisés,...), le nombre de magasins du réseau, les emplacements des magasins (centre ville, zones commerciale, ...), les techniques de "merchandising" (Bultez, 1995)(Desmet, 1998),etc... ; le décideur doit prendre en considération les évolutions de ces facteurs dans la prévision.
- les caractéristiques du produit sont les nombres de tailles et coloris disponibles, la matière utilisée, l'aspect et le toucher. Mais, l'influence de ces variables est également difficile à quantifier.
- les critères d'achats du client sont souvent subjectifs et délicats à exploiter. Cependant, ils font l'objet de nombreuses études dans le domaine de la sociologie, la psychologie ou le marketing. Parmi les facteurs d'achats du consommateur, figurent la motivation (Maslow, 1970), le niveau de vie (Malinvaud, 1983) et la catégorie socio-professionnelle (Herpin, 1986).
- l'environnement conjoncturel (pouvoir d'achat, taux de chômage, indice des prix à la consommation,...) ne semble pas avoir une influence aussi significative mais peut agir sur le volume total de la consommation.

Finalement, nous pouvons noter les remarques essentielles suivantes :

- l'influence des variables explicatives est importante dans l'environnement textile et les plus pertinentes d'entre elles doivent être prises en compte par le système de prévision,
- la liste des variables explicatives ne peut être établie de façon exhaustive,
- l'influence de chacune de ces variables sur les ventes est d'autant plus difficile à évaluer qu'elle n'est pas constante dans le temps,
- l'interdépendance de ces variables risque de rendre impossible l'interprétation de leur influence et également de complexifier (pour l'expert) le modèle de prévision,

- toutes les variables explicatives ne sont pas toujours disponibles (par exemple : historique des promotions incomplet, concurrence,...) ou prévisibles (données climatiques),
- l'une des plus grandes difficultés est l'acquisition et l'interprétation de données fiables (par exemple : historique des ventes d'un produit avec ouverture et/ou fermeture de magasins non enregistrées) et cohérentes (par exemple : données climatiques journalières, historique des ventes mensuelles).

## 1.4 Conclusion

Dans ce chapitre, nous avons défini les caractéristiques du marché textile, la connaissance des spécificités du contexte étant indispensable pour l'élaboration d'un système de prévision.

Les contraintes des méthodes de fabrication et d'approvisionnement des produits finis impliquent pour le distributeur la nécessité de prévoir la demande du consommateur afin de mieux synchroniser les flux de matières et d'informations tout au long de la chaîne textile. Cette stratégie requiert la détermination de prévisions à différents horizons : moyen terme (une saison) et court terme (quelques semaines) pour chacun des acteurs de la filière.

Les caractéristiques des articles nécessitent également l'agrégation des données afin d'obtenir des historiques exploitables. La difficulté de cette procédure, qui peut être basée sur une codification commerciale ou une classification des produits, est alors de déterminer un niveau d'agrégation suffisamment fin pour être utilisable par le distributeur.

Compte tenu du comportement des ventes, le modèle de prévision doit enfin considérer:

- la forte influence de la saisonnalité,
- les variables explicatives significatives, disponibles et connues,
- le caractère incertain de l'environnement textile.

Ainsi, la définition de ces différents critères permet d'adapter la structure et les outils mathématiques à la construction de notre système de prévision.

La figure 1.10 ci-dessous propose une première démarche de l'intégration globale d'un tel système au sein de la filière textile. La structure envisagée est constituée de deux stratégies de prévision (à différents niveaux d'agrégation des ventes) en fonction de l'horizon. La première stratégie a pour objectif d'établir des prévisions à moyen terme à partir des ventes des saisons historiques et des variables explicatives considérées. La

seconde stratégie permet de calculer les prévisions à court terme en fonction des ventes des saisons historiques, des dernières ventes et des prévisions précédentes calculées à moyen terme.

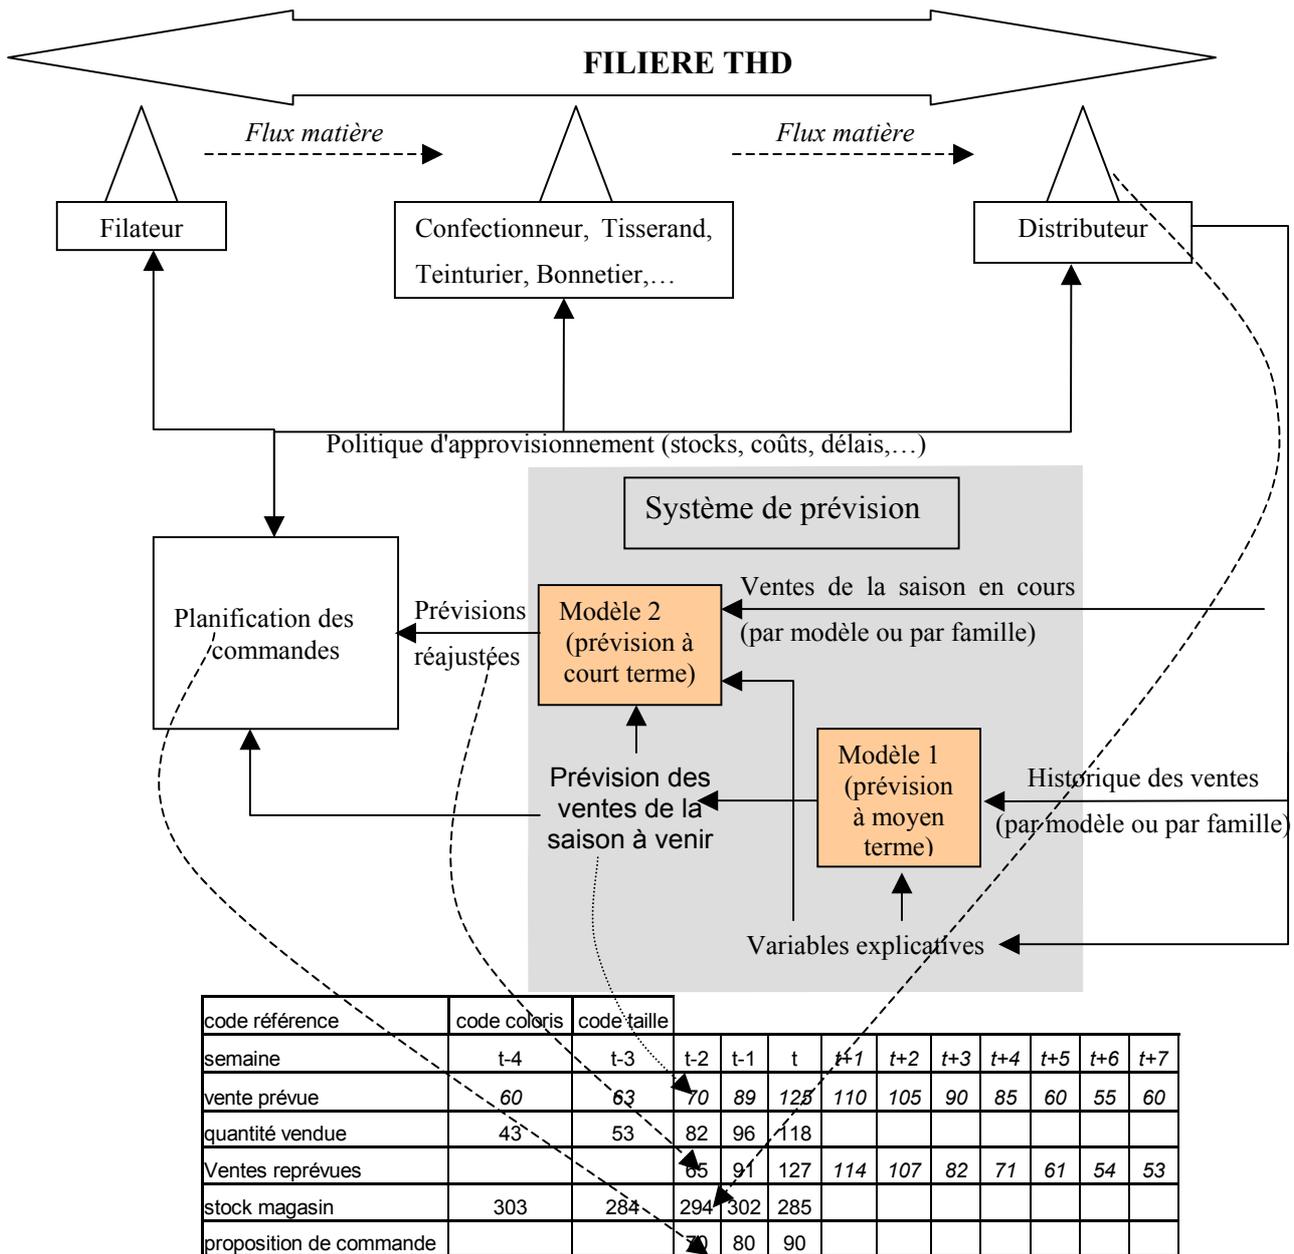


Figure 1.10. Schéma d'intégration globale du système de prévision proposé au sein de la filière textile

## Chapitre 2

### Méthodologie de prévision

#### 2.1 Introduction

Afin de définir les caractéristiques d'un système de prévision adapté à notre environnement, nous avons décrit, précédemment, les contraintes et objectifs imposés par les spécificités de la filière textile. Nous abordons dans ce chapitre les méthodes et les modèles permettant d'élaborer cet outil de prévision.

Nous présentons les différentes étapes nécessaires à la mise en œuvre d'un système de prévision, depuis la définition du problème jusqu'à l'utilisation de la prévision comme aide à la décision. Nous établissons un bref état de l'art des méthodes de prévision existantes.

Ensuite, nous nous intéressons plus particulièrement aux modèles classiques de prévision de séries temporelles. Aussi, nous envisageons les modèles statistiques classiques et leurs limites dans le contexte textile et les comparons avec les nouveaux modèles proposés.

Puis, nous analysons la contribution des méthodes du "soft computing" à l'élaboration de nos modèles de prévision et présentons quelques logiciels de prévision distribués sur le marché.

Enfin, nous décrivons quelques méthodes de classification, qui peuvent être d'un apport indispensable à l'amélioration des modèles de prévision.

#### 2.2 Mise en œuvre d'un système de prévision

La mise en place d'un système de prévision exploitable par les décideurs, implique la réalisation de plusieurs étapes (figure 2.1).

Dans cette section, nous rappelons les points les plus importants de chacune de ces étapes.

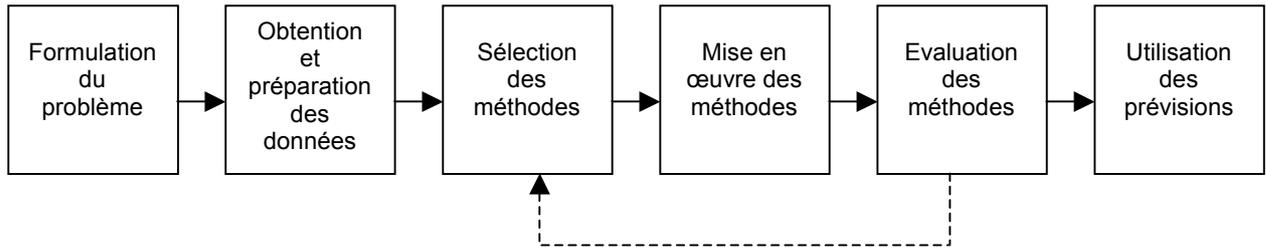


Figure 2.1. Etapes de conception d'un système de prévision

- *Formulation du problème*

Le but est de spécifier clairement les objectifs à atteindre par le système à réaliser. Ainsi, les décideurs doivent déterminer les différentes caractéristiques des prévisions, comme par exemple l'horizon ou le niveau d'agrégation des données. Il est également nécessaire de définir les variables explicatives affectant les ventes ; une étude préalable, avec consultation d'un ou plusieurs experts, doit permettre de choisir les variables explicatives disponibles les plus significatives (Makridakis, 1996). Une connaissance complète et fiable du domaine de prévision permet alors d'améliorer la précision des résultats (Edmundson, 1988)(Sanders, 1992).

- *Obtention et préparation des données*

L'utilisation d'historiques longs et fiables est évidemment recommandée pour établir un système performant. Cependant, l'environnement très versatile de la mode textile permet rarement d'obtenir une telle requête. L'acquisition de données qualitatives issues d'experts est également délicate dans la mesure où ces informations peuvent être involontairement biaisées (Armstrong, 2001b).

Avant toute exploitation, les données doivent subir quelques traitements. Les points aberrants peuvent être ainsi ajustés et les données manquantes complétées (Armstrong, 2001c). Enfin, lorsque les séries sont intermittentes ou trop courtes, il est possible de les agréger afin d'obtenir des historiques exploitables (Willemain, 1994). Une classification qualitative et/ou quantitative en amont de la prévision peut ainsi être envisagée et espérer une amélioration de la précision de la prévision (Armstrong, 1985, chapitre 9).

- *Sélection d'une(des) méthode(s)*

Aucune méthode de prévision n'est adaptée à tous les problèmes. Chacune possède ses propres caractéristiques et contraintes d'application particulières. L'objectif est de choisir un ou plusieurs modèles appropriés au type de données disponibles, au niveau de la connaissance du domaine et aux caractéristiques des prévisions voulues. Une large gamme de méthodes est à la disposition des prévisionnistes. On distingue principalement deux

catégories (figure 2.2)(Armstrong, 2001) : les méthodes subjectives, qui utilisent les intuitions ou les connaissances de l'homme, et les méthodes statistiques, basées sur l'analyse des données quantitatives.

La méthode dite de jeu de rôle (Armstrong, 2001h), prévoit les décisions des personnes ou groupes de personnes impliqués dans un conflit tel que les stratégies militaires.

Les méthodes d'intention (Armstrong, 2000)(Morwitz, 2001), anticipent le propre comportement des individus dans différentes situations. Cette méthode est appliquée particulièrement en marketing pour connaître les comportements des consommateurs lors du lancement d'un nouveau produit.

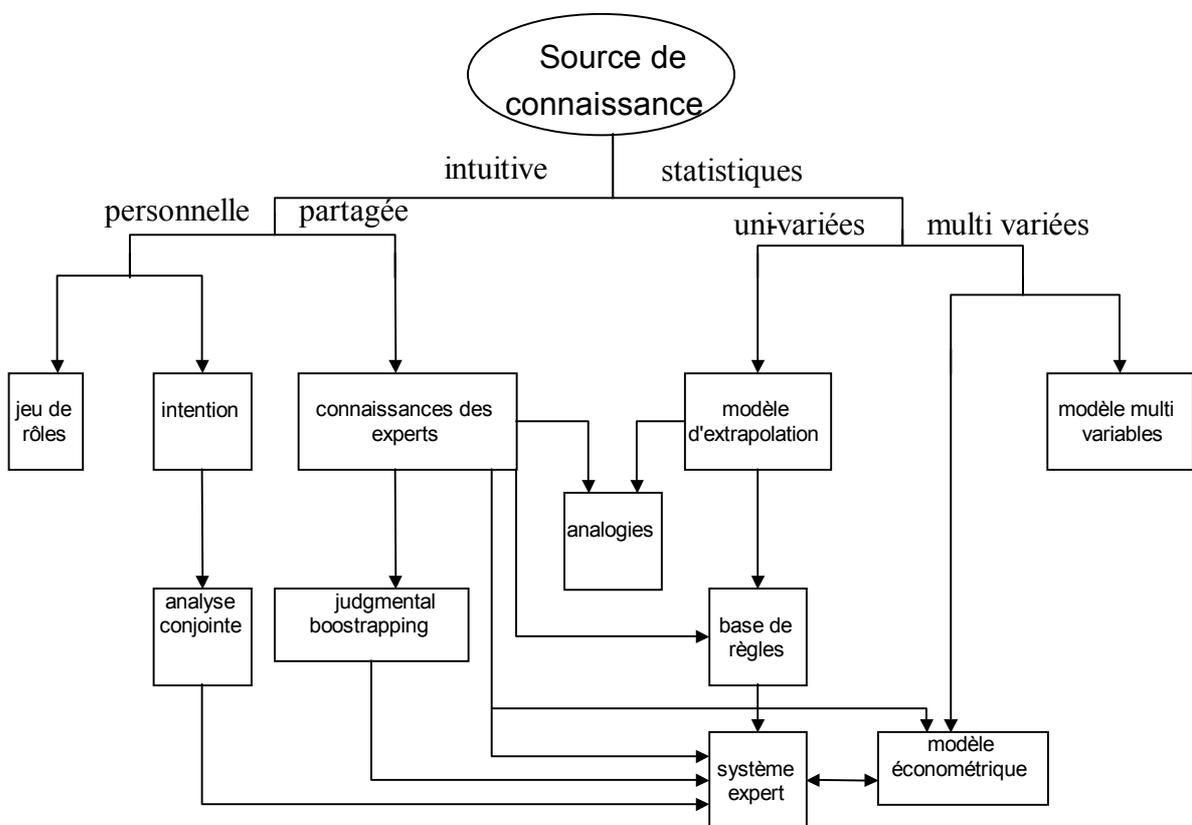


Figure 2.2. Relation entre les différentes méthodes de prévision

L'analyse conjointe (Wittink, 2000)(Cattin, 1982) permet d'examiner l'influence des caractéristiques d'une situation sur les intentions. Elle permet par exemple d'étudier les relations entre les décisions d'achat du consommateur et les propriétés d'un produit (prix, couleurs,...).

Parmi les méthodes intuitives, les plus courantes sont basées sur l'opinion des experts. Cette méthodologie permet de réaliser à moindre coût des prévisions lorsque les données sont inexistantes, incomplètes ou trop complexes à exploiter. A cet effet, la technique

Delphi (Linstone, 1975)(Rowe, 1999) est particulièrement appréciée pour obtenir et combiner de façon structurée l'avis de plusieurs experts.

La méthode nommée "judgmental bootstrapping" (Armstrong, 2001i)(Camerer, 1981) traduit les informations utilisées par les prévisionnistes en un modèle quantitatif.

La méthode des analogies peut être également abordée dans des contextes nouveaux (Duncan, 2001)(Sayrs, 1989). La procédure consiste en l'extrapolation des résultats de situations similaires en associant les approches statistiques et intuitives.

Les méthodes quantitatives utilisent les valeurs historiques d'une (méthode uni variée) ou plusieurs (méthode multi variée) séries pour prédire les valeurs futures de la même ou d'une autre série. On distingue essentiellement les modèles par extrapolation classique, du type ARIMA (Box, 1969) ou lissage exponentiel (Brown, 1959) par exemple, ou parfois plus complexes tels les techniques neuronales (White, 1992).

Les prévisions avec des modèles à base de règles (Adya, 2001)(Collopy, 1992) permettent d'intégrer les connaissances des experts aux modèles statistiques. Ces méthodes sont performantes lorsque le contexte de prévision est prépondérant.

Les systèmes experts (Smith, 1996)(Dijkstra, 1998) tentent de reproduire les procédures prévisionnelles réalisées par les experts. Ils possèdent des caractéristiques à la fois similaires aux modèles économétriques, aux systèmes à base de règles et aux méthodes par "judgmental bootstrapping".

La résolution de problèmes nécessitant l'intégration de plusieurs variables peut être envisagée par les modèles fondés uniquement sur des données quantitatives (Geriner, 1991) ou par les modèles économétriques (Allen, 2001)(Clement, 1999). Ces derniers autorisent la combinaison d'informations subjectives et de données statistiques.

La sélection d'une méthode est une tâche délicate et peut être résumée globalement par un arbre de décision (Armstrong, 2001d) (figure 2.3).

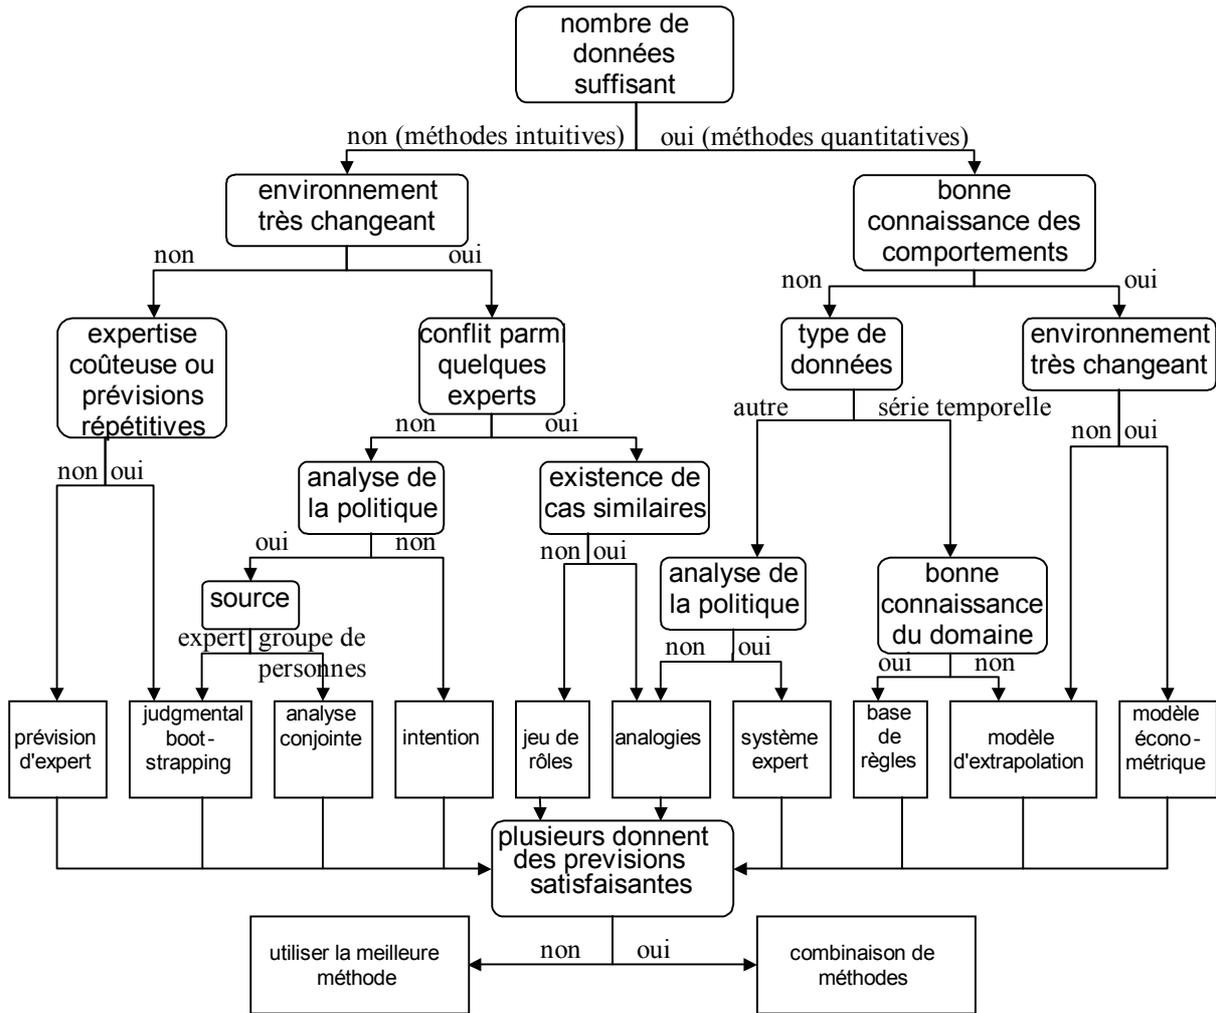


Figure 2.3. Arbre de sélection des méthodes de prévision

Les industriels sélectionnent couramment les méthodes intuitives (figure 2.3) notamment en raison de leurs résultats acceptables, de leur facilité d'application, de leur prise en compte aisée de l'expérience des experts et de la difficulté de mise en œuvre de méthodes plus mathématiques (obtention des données, réglage des paramètres, ...) (Sanders, 1992b)(Sanders, 1994)(Winklhofer, 1996). Pour des études plus scientifiques, les méthodes quantitatives sont, habituellement, préférées aux méthodes qualitatives, notamment parce qu'elles exploitent plus efficacement les informations contenues dans les données (Allen, 2001)(Armstrong, 2001d)(Stewart, 2001). Cependant, lorsque aucune donnée historique n'existe, les méthodes intuitives sont les plus adaptées (Armstrong, 2001d). Pour faciliter l'interprétation et réduire les coûts, les modèles les plus simples utilisant le moins de variables possibles avec des relations compréhensibles sont généralement plus avantageux que les modèles complexes (Makridakis, 1982)(Witt, 1995).

Enfin, la compréhension d'un modèle (Yokum, 1995) et l'horizon de prévision (Armstrong, 2001e) sont également des critères de sélection très importants pour les décideurs.

- *Mise en œuvre de la (des) méthode(s)*

Une bonne connaissance du domaine de prévision est également préconisée, même pour l'application de modèles statistiques (Armstrong, 2001e). La consultation de plusieurs experts peut apporter une plus grande diversité d'informations bénéfique à la prévision (Batchelor, 1995). Au cours de l'utilisation des modèles, les paramètres doivent être réactualisés le plus fréquemment possible en fonction des nouvelles données (Fildes, 1998). La combinaison de plusieurs méthodes est également souvent préconisée afin d'améliorer la précision de la prévision (Bourbonnais, 1992)(Armstrong, 2001f).

- *Evaluation de la (des) méthode(s)*

Afin de quantifier la performance d'un modèle, il est nécessaire d'utiliser un critère basé en général sur l'évaluation quantitative de la précision (section 2.3.1.4), mais aussi sur la fiabilité de la prévision (Armstrong, 2001g). Les données utilisées pour réaliser cette tâche doivent être, si possible, réelles et les plus proches possibles du champ d'application. Il peut s'avérer également très utile pour les décideurs de calculer les intervalles de confiance de la prévision. Cependant, cela nécessite un certain nombre d'observations supplémentaires (Makridakis, 1989).

- *Utilisation des prévisions comme outil d'aide à la décision*

Afin d'obtenir des prévisions compréhensibles, celles-ci doivent être présentées de façon simple et complète. Les intervalles de confiance sont également très utiles lorsqu'une prise de décision est difficile à obtenir. L'utilisation de graphiques est également souvent préférable à une table de données.

## **2.3 Modèles de prévision des séries temporelles**

Les modèles de prévision des séries temporelles apparaissent particulièrement intéressants dans le contexte de la filière textile (chapitre 1). Ils sont basés sur l'analyse des valeurs historiques de la série considérée et éventuellement sur les variables explicatives passées et futures.

Nous abordons dans cette section, le principe de fonctionnement et les différents critères d'élaboration de ces modèles, ainsi que leurs limites notamment dans le contexte textile. Nous analysons ensuite les apports des outils issus du soft computing et présentons les principaux logiciels de prévision disponibles sur le marché.

### 2.3.1 Principe général

Avant de définir les critères d'élaboration du modèle, il est nécessaire de formaliser le problème.

#### 2.3.1.1 Notations

Soit une série temporelle  $\{x_t\}_{t \in \mathbb{N}}$  à valeur dans  $\mathfrak{R}$ . La modélisation de la série  $\{x_t\}_{t \in \mathbb{N}}$  par l'application  $f$  peut être traduite par la relation suivante :

$$x_{t+1} = f(\theta, X_t^p, U_{t+1}^d, E_t^q) + \varepsilon_{t+1}$$

où

$$X_t^p = (x_{t-p+1}, \dots, x_t)$$

$$E_t^q = (\varepsilon_{t-q+1}, \dots, \varepsilon_t)$$

$$U_{t+1}^{d,n} = \begin{pmatrix} u_{t+1}^1 \cdot \dots \cdot u_{t+2-d}^1 \\ \vdots \\ u_{t+1}^n \cdot \dots \cdot u_{t+2-d}^n \end{pmatrix}$$

avec

- $x_t$  valeur de la série à l'instant  $t$
- $\varepsilon_t$  bruit aléatoire indépendant et identiquement distribué de moyenne nulle et de variance finie à l'instant  $t$
- $\theta$  vecteur des paramètres du modèle
- $u_t^i$  valeur de la  $i^{\text{ème}}$  variable explicative à l'instant  $t$
- $n$  nombre de variables explicatives considérées
- $p$  et  $q$  retard de l'information représentant la longueur de l'historique considéré
- $d$  retard de l'information des variables explicatives

La prévision s'obtient alors par la relation suivante :

$$\hat{x}_{t+1} = f(\hat{\theta}, X_t^p, U_{t+1}^{d,n}, E_t^q) = x_{t+1} + e_{t+1}$$

avec

- $\hat{x}_{t+1}$  valeur de la prévision de  $x_{t+1}$  réalisée à l'instant  $t$
- $\hat{\theta}$  vecteur des paramètres estimé du modèle de la série considérée
- $e_{t+1}$  erreur de la prévision à l'instant  $t+1$  par rapport à la valeur réelle

L'application  $f$  peut modéliser des séries stationnaires ou non, linéaires ou non. Si le modèle est purement extrapolatif (il n'utilise que les données historiques et non les variables explicatives), la matrice  $U_{t+1}^{d,n}$  n'existe pas.

Les modèles déterministes, dont les plus connus sont les modèles chaotiques (Casdagli, 1989)(Farber, 1987)(Farmer, 1988)(Weeks, 1997), sont des modèles sans aléas ( $\varepsilon_t = 0, \forall t$ ) et sont appliqués de façon marginale. Les modèles stochastiques, pour lesquels les aléas de la série étudiée sont apparentés à une variable aléatoire suivant une loi de probabilité, sont basés sur l'analyse statistique des données.

### 2.3.1.2 Réglage des paramètres

L'objectif est de déterminer les paramètres  $\hat{\theta}$  de  $f$  afin de modéliser au plus juste la série  $\{x_t\}_{t \in \mathbb{N}}$ . L'apprentissage est réalisé grâce à un jeu de données historiques qui doit être le plus représentatif possible de la série étudiée. Si le nombre de données disponibles est suffisant, un second jeu, indépendant du jeu d'apprentissage, peut être exploité pour valider les paramètres obtenus. En général, les paramètres sont estimés par minimisation de la fonction de coût suivante :

$$J(\hat{\theta}) = \frac{1}{N} \sum_{t=1}^N L(e_t(\hat{\theta}))$$

avec

$N$  taille du jeu de données d'apprentissage

$L$  fonction réelle continue

$e_t(\hat{\theta})$  erreur de prévision  $x_t - f(\hat{\theta}, X_{t-1}^p, U_t^{d,n}, E_{t-1}^q)$

Ce problème est généralement résolu à l'aide des méthodes du gradient (Battiti, 1992). Les paramètres étant correctement réglés, la fonction peut déterminer la prévision des valeurs de la série sur les périodes futures.

### 2.3.1.3 Elaboration d'un modèle

Les critères d'élaboration d'un modèle comprennent l'analyse statistique, la classification des données et les capacités de robustesse, de généralisation, d'automatisation de l'apprentissage et de prise en compte des variables explicatives. La qualité du modèle est également un critère très important et fait l'objet de la section suivante (section 2.3.1.4).

- *Analyse statistique des données*

L'étude dite des corrélogrammes est une analyse statistique très courante des séries temporelles. Elle consiste à calculer et examiner les coefficients d'autocorrélation  $\rho_k$  et

d'autocorrélation partiels  $\pi_k$  d'ordre  $k$ , qui mesurent la corrélation entre les variables  $x_t$  et  $x_{t+k}$  par les deux relations suivantes :

$$\rho_k = \frac{\gamma_k}{\gamma_0} \text{ avec } \gamma_k = \text{cov}(x_t, x_{t+k}) = E[(y_t - m)(y_{t+k} - m)]$$

$$\pi_k = \frac{\begin{vmatrix} 1 & \rho_1 & \dots & \rho_{k-2} & \rho_1 \\ \rho_1 & 1 & \dots & \rho_{k-3} & \rho_2 \\ \dots & \dots & \dots & \dots & \dots \\ \rho_{k-1} & \rho_{k-2} & \dots & \rho_1 & \rho_k \end{vmatrix}}{\begin{vmatrix} 1 & \rho_1 & \dots & \rho_{k-2} & \rho_{k-1} \\ \rho_1 & 1 & \dots & \rho_{k-3} & \rho_{k-2} \\ \dots & \dots & \dots & \dots & \dots \\ \rho_{k-1} & \rho_{k-2} & \dots & \rho_1 & 1 \end{vmatrix}} \text{ avec } \pi_1 = \rho_1$$

L'analyse graphique de ces coefficients permet de détecter l'éventuelle tendance et saisonnalité des processus étudiés, ainsi que l'ordre d'un modèle du type Auto-Régressif (AR), Moyenne Mobile (MA) ou ARMA (section 2.3.2.2). Enfin, en appliquant cette analyse aux résidus d'un modèle de prévision, il est possible de vérifier le traitement correct de toutes les informations contenues dans la série. Toutes ces procédures sont exploitées dans la méthode de Box & Jenkins (Box, 1969). Néanmoins, une telle démarche nécessite une grande méthodologie et une expérience de l'opérateur.

- *Classification*

Lorsque les références sont nombreuses, non renouvelées et réparties sur plusieurs niveaux d'agrégation, la classification peut s'avérer très avantageuse, notamment dans le domaine textile (Boussu, 1996)(Happiette, 1996). Positionnée en amont de la prévision, elle simplifie généralement le problème de prévision. La classification (section 2.4) peut prendre en compte des critères qualitatifs (type de produit, couleur,...) et/ou quantitatifs (profil de vente, prix, ...).

- *Robustesse*

La robustesse d'un modèle est sa capacité à ne pas être altérée par des données marquantes ou aberrantes. Dans notre contexte, le nombre important de facteurs non maîtrisés et perturbant fortement les ventes tels la météorologie ou les effets de mode, implique une utilisation de modèles robustes.

- *Généralisation*

La généralisation du modèle est essentiellement liée à la pertinence des données et à la méthode d'apprentissage utilisées. Cette notion est très importante dans le domaine textile de par le grand nombre de références à traiter.

- *Automatisation*

L'application d'un modèle de prévision sur une large gamme de références, fortement influencées par de nombreux facteurs, est difficilement réalisable avec les procédures nécessitant l'intervention d'experts (Geriner, 1991). Le modèle doit alors être capable d'apprendre et de s'adapter automatiquement aux caractéristiques des données historiques. Généralement, l'automatisation des modélisations et prévisions de séries aboutit à des résultats aussi précis que ceux obtenus par l'intervention d'experts (Adya, 2001)(Vokurka, 1996).

- *Variables explicatives*

La prise en compte de variables explicatives est essentielle dans certains contextes tels la distribution textile. Cependant, ces variables ne sont pas toujours connues. Lorsqu'elles sont identifiées mais mal maîtrisées ou difficiles à prédire, il est souvent préférable de ne pas les inclure dans le modèle afin de ne pas détériorer la précision de la prévision (Ashley, 1983). Cependant, le choix de données pertinentes reste un élément primordial pour l'élaboration du modèle de prévision (Glaser, 1954)(Dua, 1995)(Vere, 1995)(Stock, 1996)(Church, 1996)(Kauppi, 1996).

### 2.3.1.4 Evaluation de la qualité d'un modèle

Afin de quantifier et de comparer les performances des modèles, plusieurs critères d'évaluation existent. La précision de la prévision, c'est à dire la mesure de l'erreur, est la plus souvent quantifiée pour déterminer l'efficacité d'un modèle, mais d'autres tests peuvent être également effectués comme l'analyse du biais, le calcul des intervalles de confiance ou encore la prise en compte de la complexité du modèle.

La formulation des expressions définissant chacun des critères nécessite les notations spécifiques suivantes :

$x_t$	valeur de la série à l'instant $t$ ,
$N$	nombre de périodes dans une série,
$S$	nombre de séries,
$m$	nombre de paramètres du modèle,
$\hat{x}_{M,t}$	valeur de la prévision de $x_t$ du modèle $M$ ,
$e_{M,t}$	erreur de prévision à l'instant $t$ du modèle $M$ : $e_{M,t} = \hat{x}_{M,t} - x_t$
$e_{MA,t}$	erreur de prévision à l'instant $t$ du modèle Marche Aléatoire (MA)
	$(\hat{x}_{MA,t+1} = x_t + \varepsilon_t)$

$px_t$  prix de vente d'un produit

- *Présentation des critères de précision*

Le choix d'un critère de mesure de l'erreur de prévision qui peut être très influent lors d'une comparaison entre plusieurs modèles, dépend essentiellement de son utilisation. Nous ne décrivons, dans cette section, que les critères utilisés pour nos travaux.

- Root Mean Square Error (*RMSE*) :

$$RMSE(M) = \sqrt{\frac{1}{N} \sum_{t=1}^N e_{M,t}^2}$$

Ce critère sanctionne fortement les écarts importants de prévision. Il est exprimé dans les même unités que la série étudiée. Le critère *RMSE* ou sa variante *MSE* ( $= RMSE^2$ ), est très souvent appliqué, et pourtant il fait l'objet de nombreuses critiques notamment pour la forte pénalisation d'erreurs ponctuelles et pour la difficulté à comparer des modèles sur plusieurs séries (Armstrong, 1995)(Armstrong, 1992)(Thompson, 1990)(Fildes, 1988). Néanmoins, si ce critère n'est pas recommandé pour effectuer des comparaisons sur un jeu de données, sa grande sensibilité permet de l'utiliser comme fonction de coût au cours de l'apprentissage des modèles (Chatfield, 1988).

- Normalized Mean Square Error (*NMSE*) :

$$NMSE(M) = \frac{\sum_{t=1}^N e_{M,t}^2}{\sum_{t=1}^N (x_t - \bar{x})^2}$$

avec  $\bar{x}$  la moyenne estimée de la série sur la période considérée. Ce critère, sans unité, permet de comparer les performances d'un modèle sur diverses séries avec des échelles différentes.

- Absolute Percentage Error (*APE*), Mean Absolute Percentage Error (*MAPE*) et Median Absolute Percentage Error (*MdAPE*).

$$APE_t(M) = \left| \frac{e_{M,t}}{x_t} \right|$$

$$MAPE(M) = \frac{1}{N} \sum_{t=1}^N APE_t(M)$$

$MdAPE(M)$  = valeur médiane des  $APE_t(M)$  classés par ordre croissant des  $S$  séries considérées.

Le critère *MAPE* détermine le pourcentage d'erreur de prévision par rapport à la valeur réelle. Son évaluation nécessite qu'aucune des valeurs de la série ne soit nulle. Ce critère a l'inconvénient d'être légèrement biaisé en faveur de prévisions faibles (Armstrong, 2001g). Ainsi, des variantes dont l'utilisation reste marginale ont été développées comme le critère *UMAPE* (*Unbiased MAPE*) (Makridakis, 1993).

Le critère *MdAPE*, faiblement sensible aux points aberrants, peut être utilisé pour comparer des modèles sur un grand nombre de séries (Armstrong, 1992).

- critère de complexité : Schwarz Bayesian Information Criterion (*SBIC*).

$$SBIC(M) = N \cdot \ln \left( \frac{1}{N} \sum_{t=1}^N e_{M,t}^2 \right) + m \cdot \ln(N)$$

Ce critère pénalise à la fois l'erreur de prévision et le nombre de paramètres du modèle. A précision égale, il est avantageux pour sélectionner les modèles les plus simples. Le critère *SBIC* (Schwarz, 1978) pénalise plus fortement les structures aux nombreux paramètres et permet la sélection d'un modèle moins complexe que le critère *AIC* (Akaike Information Criterion) (Akaike, 1974) également couramment utilisé.

- critère spécifique : Erreur Absolue en Chiffres d'Affaires (*EACA*).

$$EACA(M) = \frac{1}{N} \sum_{t=1}^N |e_{M,t}| p x_t$$

Ce critère, défini pour les besoins de notre travail, est très important pour interpréter les performances en chiffres d'affaires d'un modèle de prévision de ventes.

D'autres critères, adaptés à différents contextes, existent tels :

- le critère *RAE*, qui permet d'évaluer la prévision d'un modèle par rapport au modèle marche aléatoire. Il est similaire au critère Theil (Bliemel, 1973).
- le critère *GMRAE*, qui possède une bonne sensibilité et peut être employé pour le réglage des paramètres des modèles (Armstrong, 1992).
- le critère *MdRAE*, qui est conseillé pour la comparaison de plusieurs modèles sur un faible nombre de séries (Armstrong, 1992).

Pour chacun des critères définis ci-dessus, plus sa valeur est faible, meilleure est la précision du modèle.

- *Choix des critères*

Afin de comparer sur un nombre important de séries les différents modèles, nous avons choisi d'utiliser le critère *MdAPE* pour quantifier leur performance.

Néanmoins, nous retiendrons également le critère *RMSE* pour sa forte sensibilité, son utilisation courante, ses facultés d'interprétation et sa facilité de mise en œuvre, ainsi que le critère *EACA* pour son interprétation réaliste dans le milieu industriel. Enfin, une combinaison des critères *RMSE* et *SBIC* a permis aussi d'élaborer un compromis entre la précision et la complexité du modèle.

- *Intervalle de prévision*

Les intervalles de prévision sont des valeurs nécessaires pour l'utilisation des résultats. En effet, ils ont beaucoup d'influence sur la prise de décision. Dans le contexte de vente textile, un intervalle de prévision important implique généralement un stock de sécurité élevé. Des formules théoriques permettent de calculer des intervalles pour différents modèles (Chatfield, 1993)(Chatfield, 1996)(Lewandowsky, 1983)(Heskes, 1997).

Cependant, malgré leur importance, les intervalles de prévision restent peu utilisés par les décideurs (Dalrymple, 1987). En effet, si certaines études permettent de les calculer pour les modèles de régression ou ARIMA (Chatfield, 1993), ils sont difficiles ou impossibles à évaluer essentiellement pour les modèles économétriques et modèles multivariés qui contiennent beaucoup d'équations ou traitent des relations non-linéaires. Dans tous les cas, lorsque des experts interviennent pendant la procédure de prévision, en particulier pour corriger l'influence des variables explicatives, le calcul des intervalles de prévision devient complexe (Chatfield, 2001).

- *Biais*

Le biais est une erreur systématique qui dévie toujours dans la même direction par rapport à la valeur réelle. Il est particulièrement mis en valeur avec les méthodes intuitives (Morwitz, 2001). En effet, ces méthodes ont montré, précisément, qu'un fort biais positif affecte les prévisions de vente de nouveaux produits (Tull, 1967) (Tyebjee, 1987). Enfin, diverses procédures ont été envisagées pour détecter (Geurts, 1994) ou réduire (Fischhoff, 1982) ce biais.

### **2.3.2 Modèles classiques**

Parmi les nombreux modèles de prévision de séries temporelles qui ont été développés, la plupart possèdent des propriétés linéaires. Ces méthodes peuvent être classées en deux grandes catégories : les méthodes de lissage et celles basées sur les processus ARIMA.

D'autres catégories, moins courantes, peuvent être proposées : les modèles avec variables explicatives, les modèles non-linéaires classiques, les modèles de prévision de nouveaux produits ou encore les modèles basés sur les cycles de vie des produits.

### 2.3.2.1 Méthodes de lissage

- *Lissage exponentiel* (Brown, 1959)

$$\hat{x}_{t+1} = \alpha x_t + (1 - \alpha) \hat{x}_t, \text{ avec } \alpha \in [0,1] \text{ coefficient de lissage.}$$

En fonction du coefficient  $\alpha$ , le modèle prend plus ou moins en compte la dernière valeur de la série.

- *Modèle de Holt-Winters avec saisonnalité* (Winters, 1960)

$$M_t = \alpha [x_t - S_t] + (1 - \alpha) M_{t-p}$$

$$T_t = \delta [S_t - S_{t-1}] + (1 - \delta) T_{t-1}$$

$$S_t = \gamma [x_t - M_{t-p}] + (1 - \gamma) [S_{t-1} + T_{t-1}]$$

$$x_{t+h} = S_t + h T_t + M_{t+h} \text{ (saisonnalité additionnelle)}$$

$$x_{t+h} = S_t (h T_t + M_{t+h}) \text{ (saisonnalité multiplicative)}$$

avec

$\alpha$  coefficient de lissage de la moyenne,

$\delta$  coefficient de lissage de la tendance,

$\gamma$  coefficient de lissage de la saisonnalité.

Ce modèle est très répandu dans les logiciels du marché. Il décompose la série en trois composantes : moyenne, tendance et saisonnalité.

### 2.3.2.2 Méthodes basées sur les processus du type ARIMA

- *Modèle ARMA(P,Q)*

$$\Phi_p(B)x_t = \Theta_q(B)\varepsilon_t$$

avec

$B$  opérateur retard :  $B^n x_t = x_{t-n}$

$\Phi_p(B)$  polynôme auto régressif d'ordre  $P$  en  $B$  :  $\Phi_p(B)x_t = (1 - \phi_1 B - \dots - \phi_p B^p)x_t$

$\Theta_q(B)$  polynôme moyenne mobile d'ordre  $Q$  en  $B$  :

$$\Theta_q(B)\varepsilon_t = (1 - \vartheta_1 B - \dots - \vartheta_q B^q)\varepsilon_t$$

Ce modèle combine les processus auto-régressif (AR) et moyenne mobile (MA). Il peut être utilisé lorsque la série est stationnaire, sans saisonnalité et possède des caractéristiques linéaires.

- *Modèle SARIMA(P,D,Q,S)*

Lorsque la série possède des composantes de tendance et de saisonnalité, on applique le modèle SARIMA(P,D,Q,S) :

$$\Phi_p \nabla^D \nabla_n^S (B) x_t = \Theta_q (B) \varepsilon_t$$

avec

$\nabla^D = (1 - B)^D$  opérateur différenciation d'ordre  $D$  permettant de rendre la série stationnaire,

$\nabla_n^S = (1 - B^n)^S$  opérateur différenciation de périodicité  $n$  et d'ordre  $S$  permettant de rendre la série non saisonnière.

- *Méthode de Box & Jenkins* (Box, 1969)

La méthode de Box & Jenkins met en œuvre un modèle basé sur un processus SARIMA.

Elle est constituée de différentes phases :

- correction des données historiques des valeurs aberrantes et manquantes,
- obtention d'une série stationnaire et non saisonnière par les opérateurs  $\nabla^D$  et  $\nabla_n^S$ ,
- détermination des ordres des processus AR et MA par l'analyse des corrélogrammes
- estimation des paramètres du modèle obtenu,
- validation de ce dernier modèle par l'analyse des résidus.

### 2.3.2.3 Autres méthodes

Nous décrivons ensuite les principales autres méthodes classiques adaptables éventuellement à notre environnement.

- *Modèles classiques non-linéaires*

Les modèles EAR (Ozaki, 1978), SETAR (Tong, 1980), STAR (Chan, 1986), STR (Granger, 1992), ARCH (Engle, 1982), GARCH (Bollerslev, 1986), BL (Tong, 1990), prennent en compte des propriétés non-linéaires des séries étudiées (De Gooijer, 1992). Il existe également des combinaisons de ces méthodes : ARMA-ARCH (Engle, 1982), BL-ARCH (Weiss, 1986), TAR-ARCH (Gouriéroux, 1990).

- *Modèles classiques avec variables explicatives*

Les modèles de régression dynamique (Pankratz, 1991)(Del Moral, 1997), ARMAX, VAR ou VARMA (Abadir, 1999)(Gilbert, 1995) assurent le traitement de séries multivariées.

- *Modèles divers*

D'autres modèles de prévision de séries temporelles ont été exploités dans des contextes plus restreints comme les modèles de diffusion de Bass (Bass, 1969), de Massy (Massy, 1969), de Eskin (Eskin, 1973), de Gompertz (Geurts, 1994), et du Market Screen (Geurts, 1975), les modèles de régression du type Logit et Probit (Jones, 1980) et la fonction Gamma (Pagny, 1971)(Brockhoff, 1967).

### **2.3.3 Limites des modèles classiques**

Les différentes méthodes classiques décrites précédemment ont été appliquées avec succès dans un ou plusieurs domaines particuliers. Cependant, ces modèles montrent leurs limites lorsqu'ils sont exécutés sur des historiques réduits fortement bruités et influencés par des variables explicatives non parfaitement maîtrisées (Kuo, 2001).

Les méthodes basées sur le lissage, notamment le modèle de Holt-Winters, sont relativement simples à mettre en œuvre et faciles à interpréter. Cependant, leur structure linéaire qui ne prend pas en compte les variables explicatives, ne permet pas de modéliser les séries fortement perturbées.

La méthode de Box & Jenkins permettant d'exploiter les modèles du type ARIMA, est considérée comme la méthode linéaire la plus complète (Gottardi, 1994). Néanmoins, son utilisation nécessite des historiques importants (30 à 70 périodes). L'analyse statistique des historiques qui requiert une certaine expérience de l'opérateur, est également rendue très difficile lorsque de nombreuses variables explicatives affectent les données.

Les modèles du type ARMAX prennent en compte les variables explicatives, mais leur structure linéaire ne permet pas de modéliser les relations non-linéaires rencontrées lors de l'analyse des données de ventes. Les modèles de régression non-linéaires classiques ou dynamiques sont pénalisés par le choix compliqué des régresseurs à appréhender et par le réglage délicat des paramètres sur des historiques réduits.

L'identification délicate de la structure et l'estimation complexe des paramètres rendent compliquées la pratique des modèles non-linéaires classiques.

Les modèles de diffusion, recherchés notamment pour la prévision de nouveaux produits, sont également difficiles à mettre en œuvre.

Ainsi, les limites des modèles classiques incitent à utiliser d'autres méthodologies. La première démarche pratiquée par de nombreux logiciels du marché, est d'effectuer une

sélection automatique de la méthode la plus appropriée en fonction du contexte. La seconde possibilité est de combiner plusieurs méthodes (Armstrong, 2001f).

Enfin, il est peut être également envisageable d'exploiter des outils issus du "soft computing" qui sont adaptés au contexte incertain et complexe du textile.

### **2.3.4 Modèles issus du "soft computing"**

Afin d'améliorer les médiocres résultats des méthodes statistiques traditionnelles obtenus dans des contextes incertains et perturbés, les nouveaux outils du "soft computing" ont été développés. Ceux-ci peuvent être caractérisés par la définition suivante: " le soft computing est un ensemble de techniques dont l'objectif est d'exploiter la tolérance de l'imprécision et de l'incertitude afin de construire des systèmes interprétables, robustes et peu coûteux " (Zadeh, 1994). Constitué essentiellement de la logique floue, des techniques neuronales, des algorithmes évolutionnistes et du raisonnement probabiliste (Zadeh, 1996), le soft computing joue un rôle de plus en plus important dans de nombreuses applications. Le principe de ces outils est fondé sur le fonctionnement du cerveau humain (techniques neuronales ou logique floue) ou sur des lois établies dans la nature (algorithmes évolutionnistes). De nombreuses études ont montré l'efficacité de ces nouvelles techniques dans plusieurs domaines comme l'automatisme (Jamshidi, 2001)(Zilouchian, 2001)(Calado, 2001)(Suzuki, 2001)(Runkler, 2000), l'ordonnancement (Portmann, 1996) (Alexandre, 1997)(Janiak, 1998), le Data Mining (Sivanandam, 2001)(Cundari, 2001)(Sumathi, 2000), la chimie (Johnson, 2001)(Nikraves, 2001)(Cundari, 2000), la médecine (Mitra, 2000)(Behloul, 2001)(Johnson, 2001b), la géotechnique (Tagliaferri, 2001) et diverses autres industries (Dote, 2001)(Sette, 2000)(Tse, 2000). Cependant, le soft computing n'est pas la solution générale à toutes les applications, mais peut apporter un complément intéressant aux méthodes traditionnelles.

Dans la section suivante, nous présentons les différentes utilisations des techniques issues du soft computing pour la conception de modèles de prévision. Nous établissons ensuite les avantages et inconvénients de ces méthodes.

#### **2.3.4.1 Modèles basés sur les techniques neuronales**

Un réseau de neurones artificiel (RNA) ou réseau connexionniste est un système de calcul inspiré du fonctionnement de certains mécanismes neuro-physiologiques du cerveau humain (Kartalopoulos, 1996). Il est constitué d'unités élémentaires qui sont reliées entre

elles par des connexions pondérées. Un RNA est un assemblage de neurones formels ou perceptrons, présenté sous forme de réseau (Haykin, 1994)(Simpson, 1996)(Thiria, 1997).

Les RNA sont notamment reconnus pour leur faculté de modélisation de séries aux structures complexes et leur capacité d'apprentissage des relations non-linéaires entre des entrées et des sorties d'un système de type boîte noire (Patterson, 1996). En effet, certains auteurs ont montré que ces systèmes sont des approximateurs universels (Sjöberg, 1995)(Hornik, 1989) ; ceci implique que toute fonction continue, en tout cas sur un domaine compact, peut être approchée par un RNA. Ainsi, ces outils se révèlent très avantageux pour réaliser des modèles de prévision de séries temporelles telles les ventes d'articles textiles.

#### **2.3.4.1.1 RNA et les modèles de prévision**

- *Domaines d'application*

Depuis Lapedes et Farber (Lapedes, 1987), de nombreuses études sur les problèmes de prévision ont exploité les RNA :

- les séries temporelles chaotiques déterministes (Poli, 1994)(Chan, 1994), étudiées en particulier par les physiciens,
- les séries ionosphériques dont les caractéristiques sont non-linéaires, non-stationnaires et non gaussiennes (Cottrell, 1995)(Fessant, 1995),
- la finance (Azoff, 1994)(Gately, 1996) et l'économie (Hansen, 1997)(Chiang, 1996) pour prévoir les faillites (Wilson, 1994)(Fletcher, 1993) ou les taux de change (Wu, 1995)(Kuan, 1995),
- les consommations électriques (Yao, 2000)(Nasr, 2002) pour lesquelles la prise en compte de variables exogènes comme la température ou les jours fériés est essentielle,
- les divers problèmes naturels comme la quantité d'ozone dans l'air (Ruiz-Suarez, 1995), la pollution (Pelliccioni, 2000), le débit des rivières (Atiya, 1999)(Abrahart, 2000), les séismes (De Falco, 2000), les courants aériens (Turkkan, 1995), ou les problèmes de société comme le trafic de passagers de compagnies aériennes (Nam, 1997)(Faraway, 1998) et la circulation automobile (Kirby, 1997)(Smith, 2002),
- les ventes de produits finis (Ansuji, 1996)(Randhawa, 1996)(Vroman, 2000).

La M-Competition (Makridakis, 1982) ou la compétition de Santa Fe (Weigend, 1993) compare également les RNA avec d'autres modèles de prévision sur des séries aux

caractéristiques variées. Cependant, les résultats de ces travaux sont mitigés et dépendent fortement des caractéristiques des séries considérées (linéarité, stationnarité, saisonnalité, etc...), de la longueur des historiques, de l'horizon de prévision ou encore de la prise en compte des variables explicatives (Remus, 2001).

- *Caractéristiques*

L'utilisation d'un RNA nécessite la définition de plusieurs caractéristiques : le nombre de couches cachées et de neurones, le nombre de neurones de sortie, les fonctions d'activation, la procédure d'apprentissage et le traitement préalable des données (Zhang, 1998).

Les modèles connexionnistes envisagés pour la prévision de vente possèdent généralement au maximum deux couches cachées, des fonctions d'activation sigmoïdales sur les couches cachées et linéaires sur la couche de sortie, un algorithme d'apprentissage du type rétro-propagation du gradient (Rumelhart, 1986) et/ou basé sur les méthodes de quasi-Newton (Patterson, 1996) utilisant les critères *RMSE* ou *MAPE* pour évaluer la performance du réseau. La principale difficulté est de construire un RNA possédant suffisamment de couches et de neurones pour permettre de modéliser les informations contenues dans les données, mais également d'éviter les problèmes de sur apprentissage ("overfitting") induits par des systèmes trop complexes.

#### 2.3.4.1.2 *Avantages et inconvénients des RNA*

- *Avantages*

Les points forts des RNA sont :

- leur grande capacité de modélisation des séries à la structure non linéaire, même lorsqu' aucune connaissance du système n'existe,
- la diversité et la facilité de mise en œuvre des techniques d'apprentissage automatique des paramètres du réseau,

- *Inconvénients*

Les limites des RNA sont leur difficulté :

- de fonctionner avec des historiques courts et/ou contenant des données imprécises et incertaines, en raison du grand nombre de paramètres du modèle,
- d'intégrer les connaissances des experts,
- à les interpréter.

### 2.3.4.2 Modèles basés sur les techniques floues

Inspirée du raisonnement humain, la logique floue, dont les fondements ont été formulés par Zadeh (Zadeh, 1965), permet le traitement des connaissances ou données incertaines, imprécises ou incomplètes. La mise en œuvre de cette technique s'effectue à travers un Système d'Inférence Flou (SIF) composé généralement de trois modules :

- une interface de fuzzification qui permet de transformer une valeur d'entrée numérique en valeur floue,
- un moteur d'inférence constitué de règles d'inférence du type "si – alors", issues de connaissances ou extraites des données d'apprentissage,
- une interface de défuzzification permettant d'obtenir les valeurs numériques des résultats des règles d'inférences.

La capacité des SIF à modéliser les relations complexes entre les séries, comme par exemple l'influence des promotions sur les ventes (Kuo, 2001), par l'intermédiaire de connaissances d'experts ou de techniques d'apprentissage automatique, peut s'avérer avantageuse pour la réalisation de modèles de prévision.

#### 2.3.4.2.1 SIF et les modèles de prévision

- *Domaines d'application*

Les techniques floues peuvent être facilement associées aux méthodes classiques de prévision. L'application des SIF comme modèle de prévision a été possible dans de nombreuses études portant sur des domaines comme l'agriculture (Saruwatari, 1995), la physique (Han, 1999), la consommation d'énergie (Ranaweera, 1996), les ventes (Sakai, 1999), et selon diverses méthodes : utilisation directe du SIF (Sullivan, 1994)(Mori, 1996)(Hlebcar, 2001)(Chow, 1997)(Toly Chen, 1999)( Mastorocostas, 2001), modèle de régression floue (Hong, 2001), combinaison floue de modèles de régression (Fiordaliso, 1998a et 1999), modèle ARIMA flou (Tseng, 2001) et ARMAX flou (Yang, 1998), système expert flou (Hsu, 1992).

- *Caractéristiques*

La construction d'un SIF demande la définition des procédures suivantes :

- un jeu de règles d'inférence,
- des classes d'appartenance des entrées et sorties, ainsi que les fonctions d'appartenance correspondantes,
- des opérateurs flous.

Si les "connaissances" du système sont maîtrisées correctement, la sélection des règles et/ou le réglage des paramètres peut être envisagé par un expert. Cependant, il est souvent difficile d'obtenir des connaissances robustes (Jang, 1992). Il est alors conseillé de réaliser l'apprentissage du SIF à partir des couples entrées - sorties connus. Le choix de la méthode est fonction du type de paramètres à optimiser. On peut considérer trois types de paramètres qui peuvent être traités différemment (Pokorny, 1997)(Nelles, 1996) :

- apprentissage de la structure : le but est de sélectionner le jeu de règles le plus performant ; les algorithmes génétiques (Bersini, 1992), la méthode de Abe (Abe, 1995) ou l'algorithme décremental de Fiordaliso (Fiordaliso, 1996, 1998b) peuvent être par exemple abordés,
- apprentissage des fonctions d'appartenance d'entrée : une optimisation par algorithme génétique (Fathi, 1994) (Karr, 1991), par calcul du gradient (Gorrini, 1995) ou par une méthode d'apprentissage par renforcement (Lin, 1994) peut être justifiée,
- apprentissage des fonctions d'appartenance de sortie : lorsque les fonctions d'appartenance de sortie sont des constantes ou des fonctions linéaires (méthode de Takagi - Sugeno : Takagi, 1985), une simple optimisation linéaire par la méthode des moindres carrés (OLS) peut être proposée (Fiordaliso, 1999).

Dans tous les cas, il est conseillé de limiter le nombre de classes d'appartenance et de définir des fonctions d'appartenance simples du type triangulaire, trapézoïdale ou gaussienne.

#### **2.3.4.2.2      *Avantages et inconvénients des SIF***

- *Avantages*

Les points forts des SIF sont leur capacité à :

- traiter les données imprécises et incertaines,
- modéliser les connaissances humaines à partir de règles linguistiques interprétables,
- prendre en compte les relations non-linéaires,
- réaliser l'apprentissage du système à partir des données historiques.

- *Inconvénients*

Les limites des SIF sont leur difficulté à envisager :

- une méthode générale construisant un système flou à partir des connaissances des experts,

- des méthodes d'apprentissage aussi simples que les RNA.

### **2.3.4.3 Modèles basés sur les algorithmes évolutionnistes**

Les algorithmes évolutionnistes sont basés sur la théorie de la sélection naturelle de Darwin (Goldberg, 1989). Deux techniques se distinguent principalement : les algorithmes génétiques (AG) (Holland, 1975)(Goldberg, 1989) et la programmation génétique (PG) (Alto, 1989).

#### **2.3.4.3.1 Algorithmes génétiques et modèles de prévision**

Les solutions apportées par les Algorithmes Génétiques (AG) sont codées sous la forme de "chromosomes". L'algorithme élabore par itérations une population de chromosomes par l'intermédiaire d'opérateurs tels que la reproduction, la recombinaison (crossover) et la mutation. A chaque boucle, la performance de l'ensemble des chromosomes est quantifiée par une fonction d'évaluation (fonction fitness). La probabilité de sélectionner un chromosome pour générer la population suivante est fonction de la qualité de celui-ci en terme de fitness.

Les AG sont de puissants outils d'optimisation de fonctions complexes. Pour approcher la solution globale, ils explorent de vastes espaces de solutions en évitant de converger dans des optima locaux.

Les algorithmes génétiques peuvent être directement appliqués pour la prévision de séries temporelles chaotiques (Szpiro, 1997). Cependant, ce sont des outils essentiellement utilisés pour l'apprentissage et l'optimisation des modèles de prévision. Les modèles obtenus sont des modèles hybrides du type génético-flou ou neuro-génétique (section 2.3.4.4.)

#### **2.3.4.3.2 Programmation génétique et modèles de prévision**

La Programmation Génétique (PG) utilise les mêmes principes que les AG. Les chromosomes se présentent sous forme d'arbres composés de fonctions élémentaires, un arbre correspondant à une fonction. La procédure assure une évolution des chromosomes de façon identique aux AG dans le but d'obtenir la fonction désirée. La PG peut être exploitée pour la modélisation et la prévision des séries temporelles (Oakley, 1994)(Howard, 1995)(Hiden, 1997)(Dracopoulos, 1997) ou pour l'apprentissage des règles d'un SIF (Alba, 1996)(Bastian, 2000)( Yaowen, 2000).

#### 2.3.4.3 *Avantages et inconvénients des algorithmes évolutionnistes*

Les algorithmes évolutionnistes apportent des possibilités intéressantes pour les problèmes complexes d'optimisation. Ils s'associent facilement aux techniques floues et neuronales pour donner des systèmes optimum.

Cependant, leur mise en œuvre (codage, taille de la population, réglage des probabilités de crossover et mutation, ...) n'est pas toujours aisée et leur convergence reste difficile à mettre en évidence en milieu incertain (Rudolph, 1994).

#### 2.3.4.4 **Modèles basés sur les techniques hybrides**

Ces modèles possèdent la capacité de modélisation et d'adaptation des réseaux de neurones, la facilité d'interprétation et d'intégration des connaissances des systèmes d'inférences flous et la puissance d'optimisation des algorithmes génétiques.

La combinaison des réseaux neuronaux et des systèmes d'inférences flous, appelée technique neuro-floue, est la plus utilisée pour la construction de systèmes de prévision. De nombreux modèles hybrides ont été appliqués (Liang, 2002)(Chang, 2001)(Hongbin, 2002)(Mastorocostas, 2000b)(Choudhury, 2001).

Diverses particularités sont offertes :

- les méthodes ANFIS (Jang, 1993) et FUN (Sulzberger, 1993) permettent de modéliser un SIF par un RNA afin de pouvoir utiliser les techniques d'apprentissage de ce dernier,
- les modèles ART-flou (Carpenter, 1991) et FALCON-ART (Lin, 1997) exploitent les capacités d'apprentissage des RNA uniquement pour le réglage des paramètres du SIF, les règles d'inférences étant extraites par d'autres méthodes,
- le système de prévision de vente IANN (Integration ANN) (Kuo, 1998 et 1999) intègre l'effet des promotions par un modèle neuro-flou facilement interprétable et réalise sans promotion la prévision des ventes par un RNA,
- les réseaux de neurones "fuzzyfiés" (Ishibuchi, 1993 et 2001) sont basés sur un RNA dont les poids et les valeurs de biais sont flous.

D'autres hybridations sont également possibles comme les techniques génético-floue (Ju, 1997)(Koehl, 1998)(Na, 1998)(Wu, 1999)(Arslan, 2001), neuro-génétique (Mangeas, 1997)(Ciuca, 1998)(Petridis, 1998)(Ku, 1999)(Yu, 2001) ou encore génético-neuro-floue (Farag, 1998)(Aliev, 2001)(Kuo, 2001). L'algorithme génétique optimise pour chacun des cas, les paramètres ou la structure du SIF ou du RNA.

### 2.3.5 Modèles de prévision du marché

De nombreux logiciels du marché permettent d'appliquer certaines méthodes de prévision en proposant une large gamme de modèles. L'opérateur peut alors choisir un modèle particulier s'il est suffisamment expérimenté, ou laisser le logiciel sélectionner la méthode la plus appropriée selon différents tests statistiques. Les modèles classiques du type ARIMA avec méthode de Box & Jenkins, lissage exponentiel, et régressions sont les plus fréquemment rencontrés : Autobox ([www.autobox.com](http://www.autobox.com)), Forecast Pro ([www.forecastpro.com](http://www.forecastpro.com)), SmartForecasts ([www.smartcorp.com](http://www.smartcorp.com)), TsMetrix ([www.rer.com](http://www.rer.com)). Néanmoins, un nombre croissant de sociétés proposent des produits dotés de techniques neuronales : NeuroShell Predictor et Professional Time Series ([wardsystems.com](http://wardsystems.com)), SPSS Neural Connection ([www.spss.com](http://www.spss.com)), Retek ([www.retek.com](http://www.retek.com)). La tendance est également à l'élaboration de logiciels intégrés qui prennent en compte la prévision et la gestion des stocks et approvisionnements : Optimate ([www.d3s.com](http://www.d3s.com)), Skep Solutions ([www.dys.com](http://www.dys.com)), Demand Solutions ([www.DemandSolutions.com](http://www.DemandSolutions.com)), Predicast ([www.aperia.fr](http://www.aperia.fr)), Walters ([www.bskwalters.com](http://www.bskwalters.com)).

Afin d'orienter le choix des clients à travers la multitude de produits proposés, de nombreux tests et comparatifs sont disponibles dans la littérature (Zimmerman, 1997)(Ord, 1996)(Seiter, 1998)(Stewart, 1998)(Diebold, 1996)(McCullough, 1998)(Stuart, 1997) et sur Internet : OR/MS Survey (<http://www.lionhrtpub.com/software-surveys.shtml>), Institute for Forecasting Education ([www.forecastingeducation.com](http://www.forecastingeducation.com)).

La référence commerciale utilisée pour nos comparatifs est le logiciel Forecast Pro de la société BFS, utilisé dans de nombreuses sociétés (plus de 15000 exemplaires vendus) aux domaines d'activité très variés. Notre choix s'est justifié principalement par ses différentes possibilités de méthodes de prévision offertes, sa facilité d'utilisation et son prix compétitif. Ce produit propose les modèles suivants : moyenne mobile, lissage exponentiel, Box & Jenkins, régression dynamique, Census X11. Le modèle qui peut être sélectionné par l'opérateur ou par le logiciel peut traiter automatiquement une centaine de séries temporelles univariés.

## 2.4 Méthodes de classification

Dans notre contexte textile où le nombre de références est très important, nous envisageons d'appliquer différentes stratégies de classification pour améliorer à plusieurs niveaux notre système de prévision.

### 2.4.1 Principe général

Le principe de base des différentes méthodes de classification est de former, à partir d'individus, des groupes ou classes qui soient les plus homogènes possibles. L'homogénéité, définie à partir d'un critère de classification et d'une notion de distance (plus la distance entre deux éléments est faible, plus ils se ressemblent), implique que les éléments d'une même classe sont très similaires (notion de compacité et de distance intra-classe), tandis que ceux appartenant à des groupes distincts sont très dissemblables (notion de séparabilité et de distance inter-classes).

De nombreux algorithmes ont été développés (Celeux, 1989), principalement à partir d'une partition binaire des éléments telle la classification hiérarchique ascendante (Rham, 1980)(Kam, 1985) mais également autour d'une partition floue des données telle la technique des "fuzzy c-mean" (Bezdek, 1981)(Dunn, 1974). Nous proposons de décrire succinctement ces deux types d'algorithmes.

### 2.4.2 Classification hiérarchique ascendante

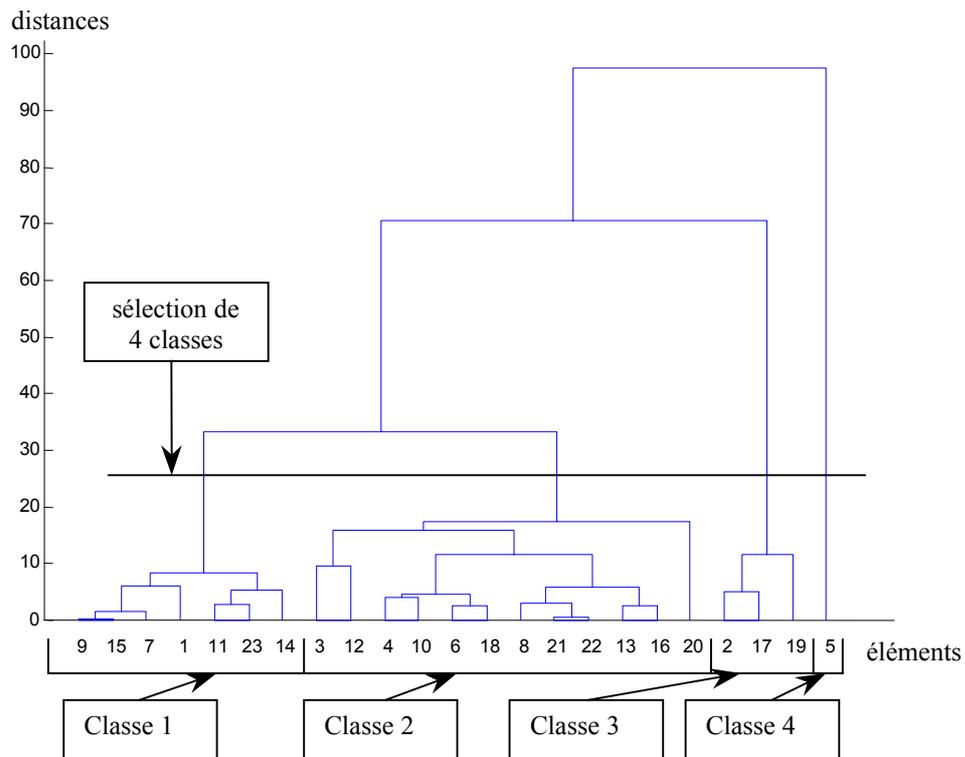


Figure 2.4. Exemple d'arbre d'une classification hiérarchique ascendante

L'algorithme appliqué pour une classification hiérarchique peut être fondé sur la procédure des "voisins réciproques". Son principe est basé sur une agrégation, à chaque

étape, des paires éléments ou classes les plus proches issues de l'itération précédente. Ce processus, qui se poursuit jusqu'au regroupement de la totalité des éléments dans une même classe, peut être visualisé graphiquement par un arbre (figure 2.4). L'utilisateur doit alors choisir, à l'aide d'un critère de validité, parmi les partitions créées, celle qui lui paraît la plus adéquate en "coupant" horizontalement les branches de l'arbre généré.

Le principe inverse peut être appliqué en partant d'une classe composée de la totalité des éléments et qui sera partitionnée au fur et à mesure des itérations (méthode descendante).

### 2.4.3 Classification floue

Contrairement à la classification hiérarchique où l'appartenance d'un élément à une classe est binaire, le processus basé sur la théorie floue affecte chaque individu à toutes les classes selon des degrés d'appartenance différents. L'algorithme de référence "fuzzy c-means", a particulièrement donné lieu à diverses extensions telles les algorithmes des distances adaptatives de Gustafson et Kessel (Gustafson, 1979) et "fuzzy maximum likelihood estimates" (Gath, 1989), ou encore les procédures "fuzzy linear varieties" (Bezdek, 1981a) et "fuzzy c-elliptotypes" (Bezdek, 1981b). Ces divers algorithmes minimisent une fonction objectif qui prend en compte les distances intra et inter-classes afin d'optimiser la répartition des éléments en fonction du nombre de classes souhaité.

### 2.4.4 Critères de classification

Les critères de classification sont basés sur les caractéristiques, qualitatives ou quantitatives, des éléments considérés. La codification des articles textiles, établie par le distributeur (section 1.3.1, figure 1.6), représente une classification fondée selon des critères commerciaux et de style des articles. D'autres possibilités peuvent être envisagées pour les ventes textiles telles que le profil de vente, le prix, le style, la couleur, la coupe, ou encore la matière du modèle. En général, la principale difficulté est la disponibilité des données notamment qualitatives (style, matière, ...).

Afin de comparer les critères des différents éléments, il est nécessaire de définir une distance, telle la distance euclidienne, la distance de Mahalanobis ou la distance de Ward. Par souci d'interprétation et de simplicité de mise en œuvre, nous avons sélectionné la distance euclidienne dont la relation est la suivante:

$$d(a,b)^2 = \sum_{j=1}^G (a(j) - b(j))^2$$

avec :

$a(j)$  et  $b(j)$   $j^{\text{ème}}$  coordonnée des éléments  $a$  et  $b$

$G$  dimension des éléments  $a$  et  $b$

### 2.4.5 Evaluation d'une partition

La performance d'une classification peut s'évaluer en terme de perte d'informations en fonction du nombre de classes générées. Ce nombre peut être calculé par l'intermédiaire d'un critère d'optimisation permettant de quantifier les notions de compacité et de séparabilité.

Le critère de validité de Xie (Xie, 1995) est particulièrement appliqué. Nous proposons également de définir un critère spécifique à notre problème. Les caractéristiques de ces critères sont abordés au chapitre 3 dans les sections 3.2.1.3.2 et 3.3.1.2.2.

## 2.5 Conclusion

Le choix d'un modèle de prévision dépend essentiellement du contexte applicatif. La taille (durée) des historiques, la connaissance du domaine et des variables explicatives, l'horizon de prévision et les contraintes de temps de calcul sont des facteurs importants pour l'élaboration d'un système de prévision.

Afin de répondre à notre objectif, les performances des modèles classiques sont très limitées pour prévoir sur deux horizons différents (court terme : 1 à 3 semaines et moyen terme : une saison à une année) des séries incertaines avec des historiques très courts (références fréquemment renouvelées) et perturbés par des variables explicatives souvent difficilement identifiables et indénombrables.

Les outils issus du soft computing, qui sont de plus en plus justifiés dans de nombreuses applications, semblent ouvrir de nouvelles possibilités de construction simple des modèles de prévision et mieux répondre à notre problème. Les réseaux de neurones artificiels possèdent des capacités d'apprentissage et de modélisation des relations non-linéaires, même avec des données perturbées. Les systèmes d'inférences flous permettent plus facilement d'intégrer les connaissances des experts et les données imprécises. Ils sont également très performants lorsque les relations caractérisant les données peuvent être modélisées sous la forme de règles linguistiques. Les algorithmes génétiques apportent principalement des solutions aux problèmes d'optimisation complexes. Enfin, la combinaison de ces techniques aboutit souvent à des systèmes hybrides aux caractéristiques très intéressantes pour notre contexte.

Nous proposons ainsi, dans le chapitre suivant, une nouvelle méthode de prévision composée de modèles basés sur ces outils et prenant en compte les contraintes à la fois très complexes et singulières de la filière textile définies dans le chapitre 1.

## Chapitre 3

### Proposition d'un système de prévision

#### 3.1 Introduction

Dans ce chapitre, nous développons un système de prévision de vente d'articles exploitable par la filière THD mais pouvant également être adapté totalement ou partiellement à d'autres domaines au contexte semblable.

Ce système doit répondre aux nombreuses spécificités du marché textile (chapitre 1), dont les principales contraintes sont les suivantes :

- établir des prévisions à moyen terme afin d'estimer les ventes un an à l'avance,
- réajuster les prévisions à moyen terme en fonction des dernières ventes pour re-planifier les approvisionnements (réassorts),
- évaluer les ventes à différents niveaux de la codification en agrégeant éventuellement les données par des techniques de classification et obtenir une base d'apprentissage exploitable,
- traiter l'influence des variables explicatives les plus significatives.

Les méthodes, basées sur les techniques du "soft computing", couplées aux connaissances des experts, doivent permettre la conception de ce système. En effet, les outils tels que les réseaux de neurones, la logique floue ou les algorithmes génétiques permettent d'assurer :

- la modélisation des structures et des relations non-linéaires de séries temporelles,
- le traitement de données incertaines ou incomplètes,
- l'apprentissage et l'optimisation de procédures à partir d'historiques et/ou de connaissances d'experts.

Ainsi, nous proposons pour le distributeur textile, un système global composé de plusieurs modèles basés sur les techniques du "soft computing", permettant de calculer des prévisions à différents niveaux d'agrégation et selon deux horizons (moyen et court terme), comme nous l'avons évoqué au chapitre 1.

Ce système est constitué de trois modules, hiérarchisés et dépendants, calculant les prévisions à court et moyen terme respectivement au niveau famille, article et taille/coloris (figure 3.1).

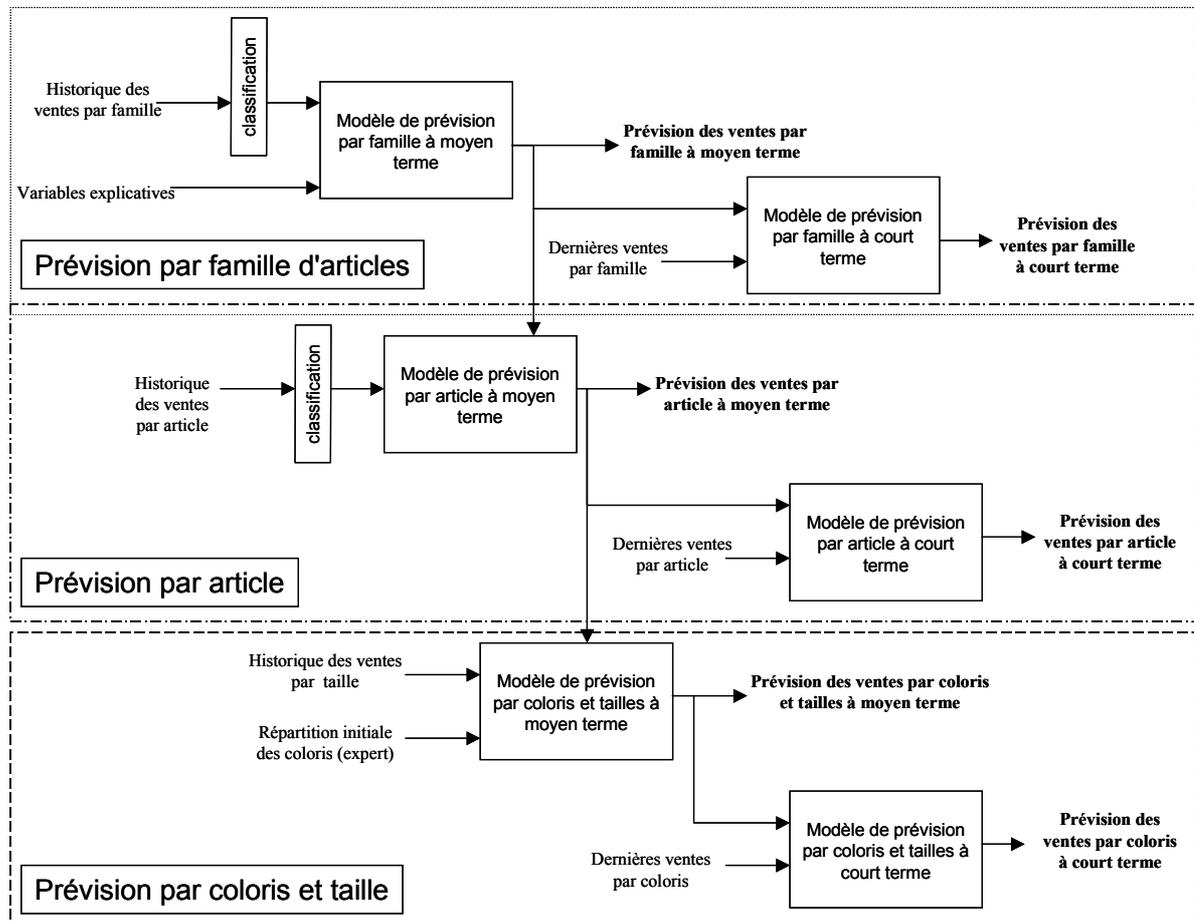


Figure 3.1. Système global de prévision

Le système de prévision par famille s'appuie sur des historiques d'un minimum de deux saisons et intègre l'influence de variables explicatives. Les relations entre les ventes et les variables explicatives, généralement très complexes, nécessitent de nombreuses données historiques. Afin de constituer une base d'apprentissage plus importante, une classification des familles est ainsi envisagée en amont de la prévision.

Les historiques des articles, qui ne sont généralement pas renouvelés et dont la durée de vie est réduite (6 à 12 semaines), sont inexistantes dans la base de données. Les relations entre les références, lors du changement de collection, sont le plus souvent également non disponibles. Ainsi, la prévision par article est plus la délicate. Elle s'appuie principalement sur la répartition des prévisions de la famille considérée. Les profils de vie des articles futurs sont élaborés à partir des historiques de vente préalablement classifiés.

Enfin, l'estimation des ventes au niveau coloris est également complexe, la mode impliquant des couleurs généralement différentes à chaque nouvelle saison. Ainsi, nous envisageons une répartition des ventes sur les différents coloris, estimée initialement par un expert, puis réajustée en fonction des dernières ventes. A l'inverse, la répartition des ventes sur les différentes tailles n'évoluant pas significativement au cours des saisons, la prévision au niveau des tailles est basée sur sa répartition historique.

Dans la section suivante, nous décrivons les modèles traitant les ventes à la famille (Thomassey, 2002a et b). Puis, nous présentons les méthodes élaborant les prévisions par article. Enfin, dans la dernière section, nous proposons une procédure d'estimation des ventes des articles par coloris et par taille.

### **3.2 Prévision à la famille**

Compte tenu du grand nombre d'articles non renouvelés, de leur durée de vie très réduite, et de l'exploitation possible des informations contenues dans les historiques, l'agrégation des ventes est envisagée. La prévision des ventes des familles d'articles permet d'obtenir des données à un niveau d'agrégation relativement fin (par exemple : T-shirt manches courtes femme) et possédant des historiques complets sur plusieurs saisons. Ainsi, l'apprentissage de la structure et des paramètres des systèmes en est facilité.

Les premiers modèles (HFCCX, HNCCX et AHFCCX) décrits dans cette section réalisent des prévisions à moyen terme à partir d'un minimum de deux saisons d'historiques. Ces modèles, basés sur les connaissances des experts en terme de traitement des variables explicatives, sont déclinés en diverses évolutions : neuronales, floues ou génétiques, et peuvent nécessiter également l'intervention d'un expert ou être totalement automatiques.

Afin d'améliorer l'apprentissage des modèles précédents, une classification des familles en fonction de leur profil de vente est envisagée en amont de la prévision. Cette méthode permet de regrouper les familles possédant un comportement de vente proche. Ainsi, l'apprentissage des modèles est exécuté sur l'historique des familles de chaque classe et non plus sur l'historique de chaque famille.

Les modèles SAMANN et SAMANFIS présentés ensuite, sont adaptés à la prévision à court terme. Ils exploitent les avantages des procédures neuronale (SAMANN) et neuro-flou (SAMANFIS) afin de réajuster les prévisions calculées à moyen terme à partir des dernières ventes de la saison en cours.

### 3.2.1 Prévision moyen terme à la famille

#### 3.2.1.1 Modèle HFCCX

Le modèle HFCCX (Hybrid Forecasting model with Corrective Coefficient of eXplanatory variables influence) (Thomassey, 2001)(Thomassey, 2002a) concerne la prévision à moyen terme des ventes par famille d'articles. Sa structure hybride permet de prendre en compte les caractéristiques saisonnières des ventes et de traiter l'influence des variables explicatives. Cette dernière est quantifiée par l'intermédiaire d'un Système d'Inférence Flou (SIF) qui modélise les connaissances d'un expert.

Nous présentons le principe général de ce modèle. Puis, nous décrivons plus spécifiquement le SIF utilisé et proposons ensuite deux techniques d'apprentissage de la structure et les paramètres du SIF. Enfin, nous envisageons une alternative neuronale.

##### 3.2.1.1.1 Principe

Les modèles statistiques classiques étant peu adaptés au contexte de la filière textile, les prévisions de nombreux distributeurs sont élaborées intuitivement par des experts (section 1.2.2.4). Ces derniers prennent en compte les ventes de la dernière ou des deux dernières saisons ainsi que certaines variables telles que les opérations promotionnelles, les vacances et les jours fériés. Cependant, une telle méthode présente les deux principaux inconvénients suivants :

- une grande expérience de l'opérateur est nécessaire,
- le nombre de variables considérées par l'expert est limité en raison d'une complication rapide de la quantification de l'influence de chacune.

Le principe général du modèle HFCCX, qui s'inspire de la méthodologie des experts, est constitué des trois étapes suivantes :

- extraction de l'influence des variables explicatives des historiques de ventes,
- calcul de la prévision de l'allure (saisonnalité) des ventes de la saison future en exploitant une méthode classique,
- ré-affectation de l'influence des variables explicatives futures sur la prévision des ventes obtenue précédemment.

Ces trois étapes sont exécutées selon la stratégie ci-dessous (figures 3.2 et 3.3) :

- le modèle CI estime l'influence des variables explicatives en calculant les coefficients correcteurs d'influence suivants :  $CX_i(t)=CI(U_i^1(t),\dots,U_i^n(t))$ ,  $\forall t \in \{1,2,\dots,p\}$  et  $\forall i \in \{1,2,\dots,A\}$  (relation 1). L'apprentissage du modèle nécessite

l'intervention d'un expert qui doit préalablement extraire l'influence des variables explicatives des ventes historiques. En effet, celui-ci élabore les courbes corrigées de l'influence des variables explicatives ( $Xexp'_1, \dots, Xexp'_A$ ) qui permettent au modèle de quantifier l'influence de ces dernières.

- le modèle RI retire des historiques de vente, l'influence des variables explicatives ( $U_i^{d,n}$ ) à partir des coefficients de correction précédents  $CX_i$  calculés par le modèle CI. On obtient alors les ventes historiques corrigées de l'influence des variables explicatives ( $X'_1, \dots, X'_A$ ) telles que :

$$X'_i(t) = RI(X_i(t), CX_i(t)) = X_i(t) \cdot (1 + CX_i(t)), \forall t \in \{1, 2, \dots, p\}.$$

- le modèle MP calcule, à partir des ventes indépendantes des variables explicatives ( $X'_1, \dots, X'_A$ ), la prévision des ventes corrigées de la saison future  $\hat{X}_{A+1}'$ . La moyenne des saisonnalités est utilisée comme méthode de prévision. Il est également possible d'utiliser une autre méthode classique de prévision basée sur la saisonnalité, mais nous avons choisi la méthode la plus simple afin de montrer l'influence significative des variables explicatives sur l'amélioration de la prévision et nous avons cherché à ne pas ajuster de paramètres supplémentaires. Ainsi, la quantité totale sur année est estimée à partir des années précédentes ou par l'expert (quantité exprimée en fonction d'objectifs de vente ou financier).
- l'influence des variables explicatives de la saison à venir ( $U_{A+1}^{d,n}$ ) est appliquée à la prévision  $\hat{X}_{A+1}'$  par l'intermédiaire du modèle  $RI^{-1}$  ; on obtient alors la prévision des ventes suivantes pour la saison future :  $\hat{X}_{A+1}(t) = RI^{-1}(\hat{X}_{A+1}', CX_{A+1}(t))$ ,  $\forall t \in \{1, 2, \dots, p\}$ .

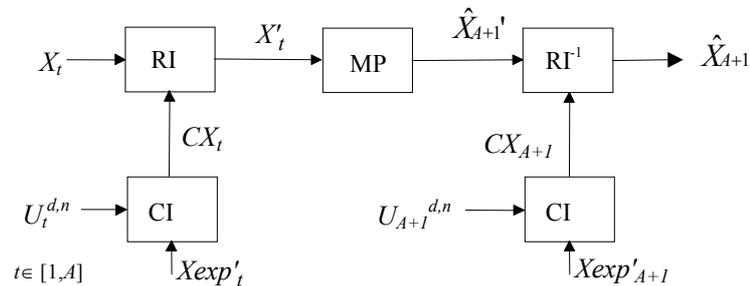


Figure 3.2. Principe du modèle HFCCX

Ainsi, l'objectif du modèle CI (Correcteur d'Influence) est de remplacer l'opérateur humain en quantifiant l'influence des variables explicatives. Compte tenu du caractère incertain des données de ventes textiles, notre choix s'est porté vers un Système d'Inférence Flou (SIF). En effet, la théorie floue est très utile pour modéliser les connaissances

humaines et l'influence des variables explicatives, et le SIF est tolérant dans le cas de données imprécises (section 2.3.4.2).

Enfin, l'utilisation d'un modèle flou traitant séparément les variables explicatives rend toujours possible son apprentissage en réduisant le nombre de paramètres à optimiser.

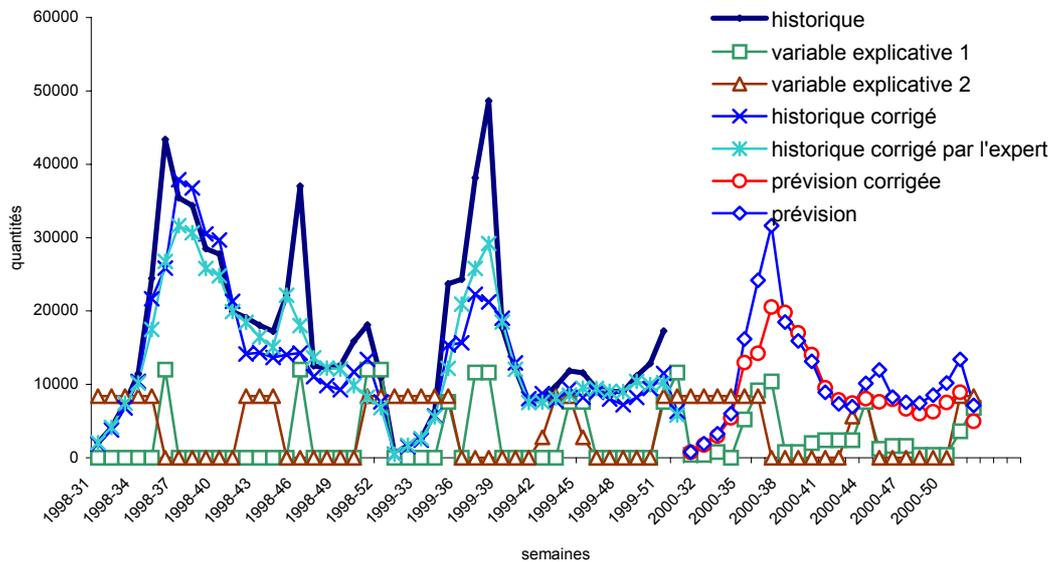


Figure 3.3. Interprétation graphique du modèle HFCCX pour 2 années d'historique

### 3.2.1.1.2 Présentation du SIF

Le SIF choisi est du type Takagi-Sugeno (Sugeno, 1985)(Takagi, 1995). Il présente l'avantage d'être plus adapté aux techniques d'apprentissage et d'optimisation (Van Lith, 2000) que le modèle de type Mamdani (Mamdani, 1975).

Les entrées sont constituées des variables explicatives décrites en section 4.2.2 et la sortie caractérise le coefficient correcteur d'influence des variables explicatives. Afin de ne pas augmenter le nombre de paramètres à optimiser, le nombre de sous-ensembles flous est limité et les fonctions d'appartenance restent simples.

La structure du SIF présentée figure 3.4 nécessite l'introduction des nouvelles variables suivantes :

- $B_i = \{B_{i,1}, \dots, B_{i,n_i}\}$  ensemble flou associé à la  $i^{\text{ème}}$  variable d'entrée  $U_t^{d,i}$  ( $t \in [1, A]$  et  $i \in [1, n]$ ) et composé de  $n_i$  sous-ensembles flous (classes d'appartenance)
- $\mu_i = \{\mu_{i,1}, \dots, \mu_{i,n_i}\}$  ensemble des fonctions d'appartenance associé à l'ensemble flou  $B_i$
- $m$  nombre de règles d'inférence

$R_j$   $j^{\text{ième}}$  règle d'inférence ( $j \in [1, m]$ )  
 $C = \{C_1, \dots, C_m\}$  ensemble flou de sortie composé de  $m$  sous-ensembles flous  
 $P^r = \{P_1^r, \dots, P_m^r\}$  ensemble des fonctions d'appartenance associé à l'ensemble flou  $C$  ( $P_j^r =$  polynôme de degré  $r$ )

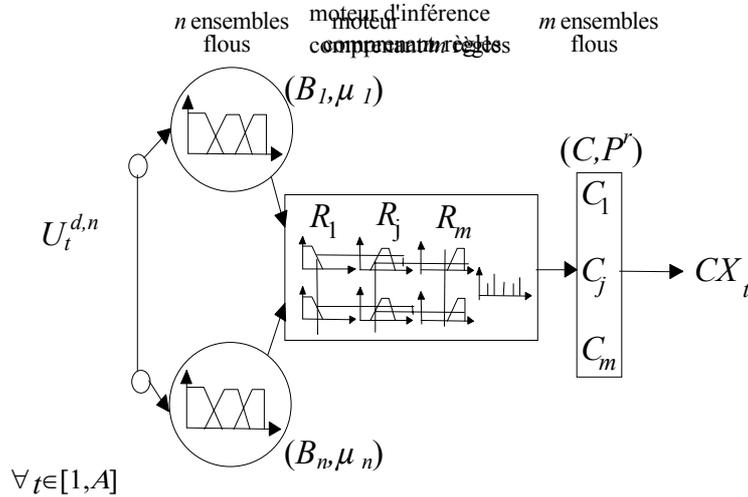


Figure 3.4. Fonction CI du modèle HFCCX

Le moteur d'inférence est composé de  $m = \prod_{i=1}^n ni$  règles ainsi que des opérateurs d'implication et d'agrégation (opérateurs flous).

La  $j^{\text{ième}}$  règle s'exprime comme suit :

Si  $U_t^{d,1}$  est  $B_{1,k1}$  et ... et  $U_t^{d,n}$  est  $B_{n,kn}$ , alors  $CX_t$  est  $C_j$

avec  $ki \in [1, ni], \forall i \in [1, n]$  et  $j \in [1, m]$

### 3.2.1.1.3 Variables explicatives et classes d'appartenance associées

- *Sélection des variables explicatives*

Le choix des variables explicatives est très important et a été décidé après plusieurs réunions avec des professionnels de la distribution. En effet, il est nécessaire de considérer un nombre suffisant de variables afin de modéliser le plus précisément possible le comportement des ventes tout en sachant qu'un excès peut détériorer la prévision. Ainsi, nous sélectionnons préalablement, les deux variables les plus pertinentes selon les experts : le prix et les périodes de vacances scolaires (ou données calendaires). En effet, le prix est un argument très important dans la décision d'achat du client et les vacances sont généralement responsables d'une hausse de la fréquentation des magasins. Les données

météorologiques sont également très influentes mais elles ne peuvent être actuellement connues de façon fiables suffisamment tôt.

Afin de contrôler correctement l'information de la variable vacances, deux données complémentaires sont prises en compte. La localisation des début et fin des vacances (par exemple le début des vacances de Noël et la fin des vacances d'été) qui génèrent généralement des fluctuations importantes des ventes, nécessite l'introduction d'une donnée supplémentaire caractérisant la variable vacances avec un retard d'une semaine. Ce retard permet ainsi de détecter le changement d'état lié aux vacances. Les ventes sont également influencées différemment selon le type de vacances (Toussaint, Noël, fin d'année scolaire). En effet, une baisse de prix n'a pas le même impact suivant la période (une promotion en pleine rentrée de septembre ou juste avant Noël est plus efficace qu'au milieu de la saison). Ainsi, la période caractérise la quatrième variable de notre modèle.

Ces variables sont codées sous la forme d'indices (section 4.2.2) nommés  $P_x$ ,  $Vac$ ,  $Vac-I$  et  $Per$  et correspondant respectivement aux variables prix, vacances, vacances de la semaine précédente et période, pour être ensuite traitées par le modèle.

- *Classes et fonctions d'appartenance associées aux variables explicatives*

Le nombre de classes d'appartenance choisi pour les indices  $P_x$ ,  $Vac$  et  $Vac-I$  est de deux. L'indice de période nécessite cinq ensembles afin de caractériser les différentes vacances scolaires et traiter la totalité des cas rencontrés pendant l'année.

Les deux ensembles flous caractérisant l'indice  $P_x$  sont :

- $A_1$  = prix normal
- $A_2$  = prix promotionnel

Les deux ensembles flous caractérisant les indices  $Vac$  et  $Vac-I$  sont :

- $B_1$  et  $C_1$  = aucune zone en vacances
- $B_2$  et  $C_2$  = 3 zones en vacances

Les cinq ensembles flous caractérisant l'indice de période sont :

- $D_1$  = période d'hiver
- $D_2$  = période de Pâques
- $D_3$  = période de d'été
- $D_4$  = période de Toussaint
- $D_5$  = période de Noël

Les fonctions d'appartenance associées à ces classes d'appartenance sont de type trapèze (figure 3.5).

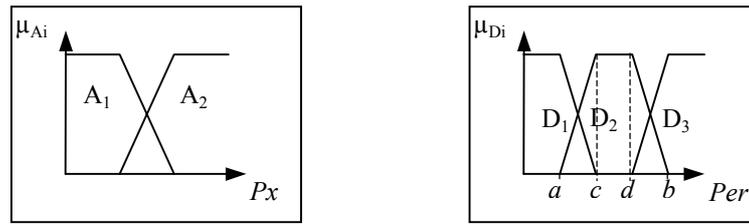


Figure 3.5. Fonctions d'appartenance des indices prix et période

Le degré d'appartenance de l'entrée  $X$  à la classe d'appartenance  $M$ , caractérisé par la fonction trapèze  $\mu_M$ , est donné par la relation suivante :

$$\mu_M(X,a,b,c,d) = \max\left(\min\left(\frac{X-a}{b-a}, 1, \frac{d-X}{d-c}\right), 0\right), \text{ où } a \text{ et } b \text{ sont les paramètres de la}$$

base du trapèze et,  $c$  et  $d$  sont les paramètres du sommet du trapèze ( $b > d > c > a$ ).

On remarque que le jeu de règles initial (avant apprentissage) associé à ces entrées et

ensembles flous est constitué de  $m = \prod_{i=1}^4 n_i = 2 \times 2 \times 2 \times 5 = 40$  règles.

#### 3.2.1.1.4 Apprentissage et réglage du SIF

L'apprentissage du système flou nécessite trois types différents de réglages (l'un structurel et les deux autres paramétriques) (section 2.3.4.2.1). Deux procédures ont été abordées : la première est basée sur une méthode neuro-floue, la seconde utilise le principe des algorithmes génétiques.

- Méthode ANFIS

La méthode neuro-floue ANFIS (Adaptative Neural Fuzzy Inference System) a été introduite par Jang (Jang, 1993). Elle est basée sur la technique d'apprentissage neuro – adaptative. Pour un jeu de données d'entrées/sortie (caractérisé par les variables explicatives  $U_i^{d,n}$  et les historiques corrigés par les experts  $Xexp'$ ), les paramètres des fonctions d'appartenance d'un modèle flou sont réglés en utilisant l'algorithme de rétro-propagation combiné avec la méthode des moindres carrés. Ce système flou est traduit par un réseau neuronal dont les paramètres des nœuds caractérisent les paramètres du modèle flou (section 3.2.2.2).

Cette méthode permet ainsi de régler, de façon automatique, les paramètres des fonctions d'appartenance du SIF. Cependant, aucun réglage structurel du système d'inférence n'est effectué.

- Méthode basée sur les algorithmes génétiques

Cette stratégie, basée sur un algorithme génétique, sélectionne les règles qui apportent une bonne précision, et optimise les fonctions d'appartenance d'entrée et de sortie de chaque règle par la méthode des moindres carrés.

Lorsque le nombre d'entrées devient supérieur à trois, plusieurs problèmes apparaissent : le nombre de paramètres à optimiser est important, l'interprétation des règles devient très difficile et certaines règles peuvent nuire à la performance du système (Nelles, 1996)(Zadeh, 1996). La structure du modèle doit également être relativement petite afin d'éviter les problèmes de sur apprentissage ("overfitting") (Fiordaliso, 1998b) : un modèle ayant trop de paramètres s'adapte très bien à un échantillon de données, mais donne de faibles résultats pour des données hors de cet échantillon ; une sélection des règles devient alors nécessaire. Le nombre de combinaisons de règles différentes à partir du jeu complet

de  $m$  règles est alors égal à  $\sum_{i=1}^m C_m^i = 2^m - 1$ .

L'espace des solutions devient donc rapidement très important. Les algorithmes génétiques se révèlent alors comme des outils adaptés à ce type de problème (section 2.3.4.3). En effet, ils permettent d'explorer un grand nombre de solutions mais sans assurer une détermination de l'optimum global dans un temps fini.

Enfin, le problème de la sélection des règles peut être facilement formulé par des caractères binaires. Pour notre application, chaque chromosome est une chaîne de  $m$  nombres binaires qui traduit un jeu de règles (figure 3.6), permettant de calculer une prévision. Quand le gène  $i$  d'un chromosome est égal à "1", alors la règle  $i$  est sélectionnée. Inversement, lorsque ce gène est égal à "0", la règle n'est pas sélectionnée.

règle n°	1	2	3	4	...	m-1	m
gène	0	1	1	0	...	1	0

Figure 3.6. Exemple de chromosome

A chaque itération de la procédure génétique, l'évaluation de la fonction fitness est évaluée comme suit :

- chacun des chromosomes est décodé en un jeu de règles,
- pour chaque jeu de règles, une optimisation par la méthode des moindres carrés détermine les fonctions d'appartenance d'entrées et de sortie : un SIF est alors obtenu pour chaque chromosome,

- pour chaque SIF, l'historique corrigé des variables explicatives  $X'_i$  est calculé,
- la fonction fitness correspond à un critère  $J$  évaluant l'erreur entre l'historique corrigé par l'expert  $X_{exp}'_i$  et celui donné par le SIF. On peut remarquer que plus la valeur de la fonction fitness est faible, plus le chromosome est performant.

Le critère  $J$  est choisi afin de trouver un compromis entre les écarts avec les valeurs cibles et le nombre de règles du SIF. Ainsi, la formule du critère retenu est la suivante :

$$J = RMSE + K \cdot SBIC$$

où  $K$  est une constante permettant à l'opérateur d'ajuster le  $SBIC$  par rapport au  $RMSE$  en fonction des données. Nous avons choisi ce critère afin d'accentuer l'importance du critère  $RMSE$ , le critère  $SBIC$  considérant déjà dans sa formule le critère  $RMSE$  mais avec une pondération trop faible.

L'optimisation des fonctions d'appartenance des variables d'entrées et de sortie par la méthode des moindres carrés de chaque jeu de règles augmente considérablement le temps de calcul, mais assure une convergence plus rapide (Nelles, 1996)(Van Lith, 2000).

Une autre stratégie consiste à coder les constantes des fonctions d'appartenance de sortie dans le chromosome mais elle entraîne la perte de la dépendance linéaire entre la sortie et les règles.

Cette méthode réalise ainsi un réglage structurel et paramétrique du SIF. Le nombre de règles obtenu est optimisé selon un critère combinant précision et complexité. Cependant, cette technique requiert des temps de calcul relativement importants (8 à 12 heures par famille d'articles).

#### 3.2.1.1.5 Variante neuronale : modèle HNCCX

Le modèle HNCCX (Hybrid forecasting model with Neural Corrective Coefficient of eXplanatory variables influence) (Vroman, 2000)(Thomassey, 2001) correspond à une variante neuronale du modèle HFCCX développée parallèlement lors d'une thèse au laboratoire GEMTEX (Vroman, 2001). Le principe de fonctionnement du modèle HNCCX est donc identique à son homologue flou (section 3.2.1.1.1). Le SIF correspondant au correcteur d'influence CI est remplacé par un réseau de neurone artificiel à propagation directe (figure 3.7).

Si un SIF est recommandé pour modéliser l'influence des variables explicatives des ventes et les connaissances des prévisionnistes (Kuo, 1998), les procédures d'apprentissage

d'un réseau neuronal demeurent généralement plus simples et plus rapides à mettre en œuvre.

La structure du modèle, comme pour la version floue, doit rester simple afin de ne pas augmenter le nombre de paramètres à optimiser. Ainsi, le réseau de neurones du modèle HNCCX est composé d'une seule couche cachée, constituée de quatre neurones.

Les fonctions d'activation sont du type sigmoïdale pour la couche cachée et linéaire pour le neurone de la couche de sortie.

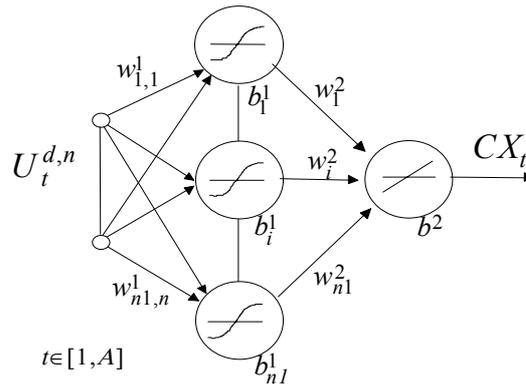


Figure 3.7. Fonction CI du modèle HNCCX

L'initialisation des paramètres du réseau (les poids  $w_{j,i}^h$  des connexions entre les neurones  $i$  de la couche  $h$  et les neurones  $j$  de la couche  $h+1$ , et les biais  $b_i^h$  associés aux neurones  $i$  de la couche  $h$ ) est réalisée par la procédure de Nguyen et Widrow (Nguyen, 1990) et adaptée par Demuth et Beale (Demuth, 1994).

L'apprentissage des paramètres est basé sur la méthode "one step secant algorithm" (Battiti, 1992). Cette procédure est un compromis entre la méthode de BFGS et la procédure du gradient conjugué (Haykin, 1994)(Demuth, 1994)(Patterson, 1996)(Kartalopoulos, 1996) en terme de capacité de mémorisation, de calcul et de convergence.

Enfin, la méthode de SSM (Statistical Stepwise Method) (Cottrell, 1995)(Mangeas, 1994) permet de réduire la complexité du modèle pendant l'apprentissage.

### 3.2.1.1.6 Résumé des caractéristiques

Ces deux modèles permettent d'évaluer les prévisions des ventes de familles d'articles à moyen terme par traitement des variables explicatives. Ils permettent également de prendre en compte les connaissances des prévisionnistes. Cependant, pour une application sur de nombreuses références, l'automatisation du processus s'avère nécessaire.

Le modèle basé sur un SIF (HFCCX) autorise une interprétation de son fonctionnement par l'intermédiaire des règles d'inférences. Néanmoins, les techniques d'apprentissage peuvent paraître longues à mettre en œuvre et à exécuter, notamment pour la méthode génétique.

Le modèle neuronal (HNCCX), bien que très concurrent de la technique floue (modèle HFCCX) en terme de résultats (section 4.4.1.1), possède l'inconvénient d'être difficilement interprétable.

Ainsi, nous envisageons d'exploiter, pour l'évolution automatique du modèle, la solution floue.

### 3.2.1.2 Modèle AHFCCX

Le modèle HFCCX est basé sur la modélisation de l'influence des variables explicatives à partir des connaissances des experts. Cette méthode qui automatise partiellement le travail intuitif du prévisionniste, présente plusieurs inconvénients :

- l'intervention des experts manque parfois de fiabilité (Stewart, 2001), notamment lorsque les relations entre les variables explicatives et les ventes sont nombreuses, complexes, et parfois biaisées (Poulton, 1989)(Tyebjee, 1987),
- les opérations manuelles peuvent se montrer très fastidieuses et délicates avec un nombre important de séries (Geriner, 1991), imposé par le contexte textile.

Ainsi, une automatisation totale de la procédure, nommée AHFCCX (Automatic HFCCX) (Thomassey, 2002b), est nécessaire afin d'appliquer notre modèle à une très large gamme de produits (de l'ordre de 300 familles pour notre application).

Le principe général du modèle AHFCCX (figure 3.8) est identique à celui du modèle HFCCX. La différence principale réside dans l'évaluation de la performance du modèle lors de la phase d'apprentissage. En effet, sans un historique corrigé de l'influence des variables explicatives par l'expert ( $X_{exp}'_t$ ), il n'est plus possible d'évaluer directement la pertinence de l'historique corrigé ( $X'_t$ ) calculée par le système.

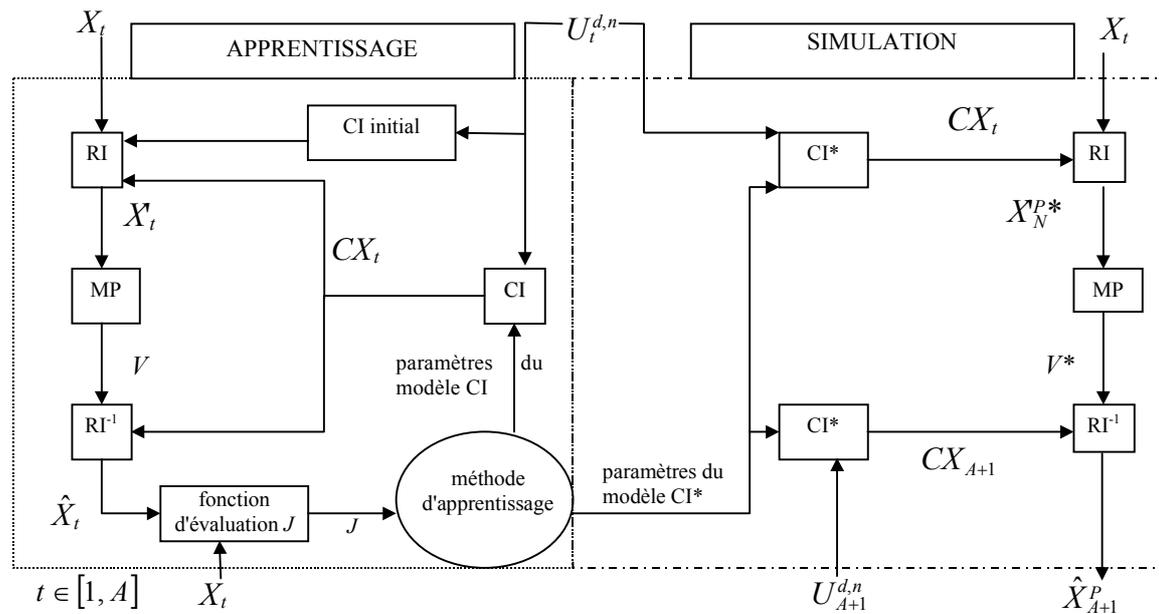


Figure 3.8. Principe du modèle AHFCCX

La méthode élaborée est la suivante :

- le modèle CI initial permet de déterminer une courbe de vie moyenne  $V$  qui est élaborée à partir des ventes sans influence des variables explicatives,
- le système calcule les prévisions des ventes sur les saisons historiques, à partir de la courbe de vie précédente et des variables explicatives historiques,
- le critère  $J$  (section 3.2.1.1.4) est alors estimé à partir de ces prévisions et des ventes historiques,
- le processus d'apprentissage établit de nouveaux paramètres du modèle CI afin de réduire la valeur du critère  $J$ ,
- le modèle CI\* optimum qui permet la détermination de la courbe de vie optimale  $V^*$  est obtenu lorsque le nombre d'itérations maximum est atteint ou si le critère  $J$  est suffisamment faible,
- enfin, la prévision finale est calculée à partir de l'application de l'influence des variables explicatives de la saison future, à cette courbe  $V^*$ .

La technique de réglage appliquée de façon identique au modèle HFCCX (section 3.2.1.1.4), est fondée sur le principe d'un algorithme génétique couplé à une optimisation non linéaire. Le critère d'évaluation de la performance de l'apprentissage  $J$  est également similaire au modèle non automatique.

Cette méthode requiert des historiques d'un minimum de deux saisons afin de pouvoir estimer la courbe de vie  $V^*$ . Dans notre contexte textile, une telle contrainte justifie l'agrégation des ventes au niveau famille (section 1.3.1, figure 1.6).

La connaissance d'une troisième saison permet d'envisager un processus de validation du modèle. Dans ce cas, le modèle est réglé sur les deux saisons d'apprentissage et le critère  $J$  est estimé à partir de la saison de validation.

Ainsi, le modèle AHFCCX est l'extension automatique du modèle HFCCX. Il permet de réaliser des prévisions à moyen terme sur de nombreuses familles d'articles. La contrainte principale reste la nécessité de disposer au minimum de deux années d'historiques par famille. Une augmentation du nombre de données d'apprentissage par l'intermédiaire d'une classification, permettrait également de modéliser plus efficacement les corrélations souvent complexes entre les ventes et les variables explicatives.

### **3.2.1.3 Classification des familles**

#### *3.2.1.3.1 Problématique*

Les historiques disponibles chez les distributeurs sont souvent très réduits (de 2 ou 3 ans maximum), même lorsque les données sont agrégées au niveau famille.

Les corrélations entre les ventes des articles textiles et les variables explicatives étant souvent très complexes (section 1.3.4), et l'influence de ces variables étant également très changeante selon la famille considérée, il est apparu nécessaire d'effectuer pour chaque famille un apprentissage du système.

Cependant, dans le cas des SIF et des réseaux de neurones, les conditions correctes pour un bon apprentissage demandent des séries relativement longues (Fiordaliso, 1999).

Aussi, afin d'augmenter le nombre de données d'apprentissage, une agrégation des familles par une procédure de classification (section 2.4) est envisagée. L'objectif est de regrouper les familles dont les ventes possèdent des corrélations fortes pour les mêmes variables explicatives. L'apprentissage du modèle est ensuite effectué, non plus sur l'historique de chaque famille, mais sur l'ensemble des historiques des familles d'une même classe.

#### *3.2.1.3.2 Propriétés de la stratégie proposée*

L'objectif est de former une base d'apprentissage en regroupant les historiques des familles. Les classes devant être définies de façon binaire, notre choix s'est orienté vers une classification ascendante hiérarchique (section 2.4).

Le critère de classification sélectionné permet de caractériser le comportement des ventes par rapport aux variables explicatives. Ainsi, nous regroupons dans une même classe les familles d'articles possédant des profils de vente similaires. En effet, le profil de vente, qui est facilement extrait des historiques, contient les informations primordiales sur l'évolution des ventes. Toutefois, il est également possible d'étudier l'impact d'une classification selon d'autres critères plus complexes (par exemple : coefficients de corrélation entre les ventes et les variables explicatives) ou plus qualitatifs (par exemple : données marketing) qui prennent en compte de façon plus directe les variables explicatives de chacune des familles d'articles.

Pour déterminer le nombre de classes optimal, nous avons sélectionné le critère de validité  $Sxie$  (Xie, 1995) défini de la façon suivante :

$$Sxie = \frac{\sum_{k=1}^c \sum_{i=1}^S \mu_{ik} d^2(z_i, a_k)}{N \times d_{\min}^2}$$

avec

$c$	nombre de classes
$S$	nombre de familles
$a_k$	centre de la classe $k$
$z_i$	famille $i$
$d_{\min}$	distance minimum entre les centres de classe
$\mu_{ik}$	degré d'appartenance de la famille $i$ à la classe $k$ ( $\mu_{ik} = 0$ or $1$ en classification hiérarchique)

Ce critère permet d'obtenir le meilleur compromis entre la compacité,  $d^2(z_i, a_k)$ , et la séparabilité,  $d_{\min}^2$ , des classes. La distance choisie est la distance euclidienne.

#### 3.2.1.4 Conclusion de la prévision moyen terme à la famille

Les modèles proposés dans cette section permettent de calculer, de façon semi-automatique ou automatique, des prévisions à moyen terme des ventes des familles d'articles. Ces systèmes utilisent une technique floue ou neuronale pour traiter l'influence, souvent très importante, des variables explicatives sur les ventes textiles.

L'enjeu des résultats obtenus est triple :

- permettre une première planification de la production et des commandes des produits un an (ou une saison) à l'avance,

- alimenter le système de prévision des ventes des familles d'articles à court terme (section 3.2.2),
- contribuer à l'élaboration des prévisions des ventes à moyen terme au niveau article (section 3.3.1).

## 3.2.2 Prévision court terme à la famille

### 3.2.2.1 Modèle SAMANN

Le modèle SAMANN (Short-term forecasting model by Adjustment of Mean-term forecast with Artificial Neural Network) (Thomassey, 2002c) réalise des prévisions à court terme à partir des dernières ventes de la saison en cours en réajustant les prévisions à moyen terme obtenues précédemment. La méthode utilisée est basée sur les capacités d'apprentissage et d'adaptation des techniques neuronales (section 2.3.4.1). Les variables explicatives sont toujours traitées par le modèle de prévision à moyen terme.

#### 3.2.2.1.1 Structure du réseau de neurones

La structure du modèle SAMANN (figure 3.9) est fondée sur celle du modèle NARX (Neural-based AutoRegressive model with eXplanatory variables) qui a été utilisée dans de nombreux domaines de prévision tels les ventes de bière (Koksalan, 1999), de journaux (Heskes, 1997b) et d'articles textiles (Vroman, 2000).

Ce réseau de neurones qui est du type multicouches "Feedforward", est reconnu pour sa bonne capacité de généralisation et sa compatibilité avec de nombreux algorithmes d'apprentissage et d'adaptation (Demuth, 1994).

Le nombre de couches cachées et de neurones par couche doit être suffisant afin de permettre au réseau de modéliser correctement les caractéristiques de la série étudiée. Néanmoins, une structure trop complexe, implique l'incapacité du réseau à généraliser les résultats sur de nouvelles données (problème "d'overfitting") (Thomas, 1997) (Kartalopolous, 1996). Ainsi, l'exploitation d'une ou deux couches cachées est généralement recommandée (Zhang, 1994)(Patterson, 1996)(Vroman, 1999). Compte tenu de la taille limitée du jeu de données d'apprentissage, nous avons choisi d'appliquer un réseau de neurones à une couche cachée.

Le nombre de neurones de la couche cachée ( $n_1$ ) définit également un compromis correct entre les capacités de généralisation et de modélisation du réseau. Le principal facteur limitant la quantité de neurones est le nombre de données historiques disponible

pour l'apprentissage (Vroman, 2000). Néanmoins, en général, dix neurones suffisent pour résoudre les problèmes de prévision (Hopffroff, 1993).

Les fonctions d'activation sont, comme pour le modèle HNCCX (section 3.2.1.1.5), du type sigmoïdale pour la couche cachée et linéaire pour le neurone de la couche de sortie. Cette configuration classique a fait ses preuves dans la modélisation des systèmes non linéaires et plus particulièrement dans les problèmes de prévision de séries temporelles (Wong, 1990)(Vishwakarma, 1994)(Kuan, 1995)(Thomas, 1997).

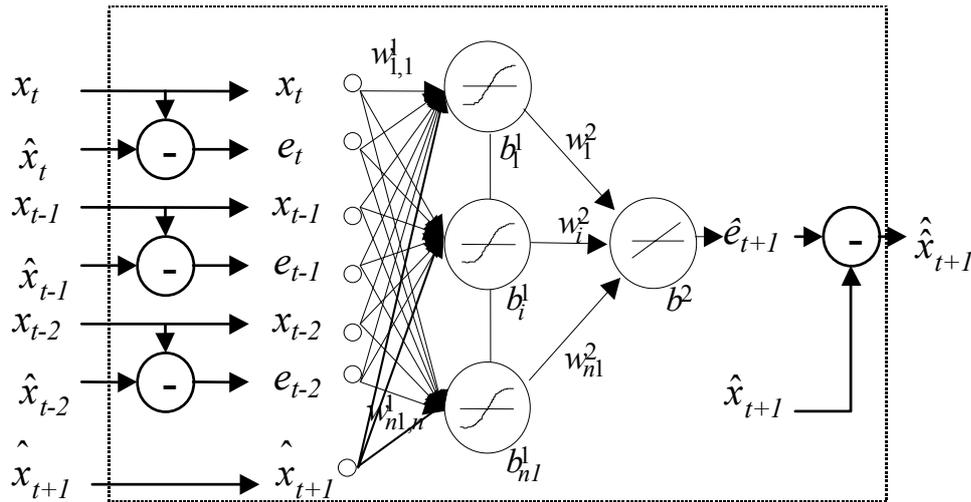


Figure 3.9. Principe du modèle SAMANN

### 3.2.2.1.2 Entrées et sorties

L'espace des entrées est composé des  $d$  dernières ventes réelles connues, des erreurs entre les  $d$  dernières ventes et la prévision obtenue à moyen terme par le modèle AHFCCX ( $e_{A+1,i} = \hat{x}_{A+1,i} - x_{A+1,i} ; i \in [t-d, t]$ ), et enfin de la prévision de la semaine future réalisée par le modèle AHFCCX. Le nombre d'entrées est alors de  $2d + 1$ . La sortie du réseau est la prévision de l'erreur produite par le modèle moyen terme pour la semaine future ( $\hat{e}_{A+1,t+1} = \hat{x}_{A+1,t+1} - x_{A+1,t+1}$ ). Ainsi, à partir de la prévision de l'erreur, il est possible de calculer la prévision à court terme ( $\hat{\hat{x}}_{A+1,t+1} = \hat{x}_{A+1,t+1} - \hat{e}_{A+1,t+1}$ ).

Le choix de la fenêtre d'observation  $d$  (retard de l'information) est délicat. Certaines études recommandent d'utiliser le nombre d'observations contenu dans une périodicité (par exemple ce nombre est de 12 pour des données mensuelles) (Tang, 1991)(Sharda, 1992). Cependant, la composante saisonnière des ventes est déjà prise en compte par la prévision moyen terme du modèle AHFCCX et de récents travaux dans le domaine des ventes textiles (Vroman, 1999) ont montré que la fenêtre d'information doit être

inférieure à la périodicité des données, et plus précisément de 3 à 6 périodes maximum lorsque sont considérées des variables explicatives. Aussi, compte tenu des ces remarques et de la structure réduite du réseau de neurone, nous choisissons  $d \leq 3$ .

#### 3.2.2.1.3 Initialisation et apprentissage

L'initialisation des paramètres du réseau est exécutée par une procédure identique au modèle HNCCX (section 3.2.1.1.5).

Le réglage des paramètres est confié à une méthode basée sur la rétropropagation du gradient conjuguée avec l'apprentissage adaptatif (Hagan,1996).

#### 3.2.2.1.4 Résumé des caractéristiques

Les principaux avantages du modèle SAMANN sont issus des capacités des réseaux de neurones à appréhender l'apprentissage et la modélisation des relations non-linéaires entre les dernières ventes et les erreurs sur les prévisions réalisées à moyen terme. Cependant, les possibilités de ce modèle, conditionnées par la structure du réseau de neurones, sont limitées par la taille réduite du jeu de données d'apprentissage (section 4.2.1).

Aussi, l'interprétation plus aisée des procédures neuro-floues permet de réduire le nombre de paramètres à optimiser, en estimant intuitivement certains d'entre eux.

### 3.2.2.2 Modèle SAMANFIS

Le modèle SAMANFIS, concurrent du modèle SAMANN, réalise des prévisions à court terme des ventes des familles d'articles. Il est basé sur un système neuro-flou du type ANFIS (Jang, 1993). Cette technique, utilisée précédemment pour l'apprentissage du modèle HFCCX (section 3.2.1.1.4) combine les avantages des SIF et des réseaux de neurones.

Les entrées sont similaires au modèle SAMANN ; les ventes et les prévisions à moyen terme établies sur les  $d$  dernières semaines ( $d \leq 3$ ) ainsi que la prévision de la future semaine sont également appliquées.

#### 3.2.2.2.1 Propriétés du SIF

Afin de limiter les paramètres, deux classes d'appartenance ( $n_i = 2, \forall i \in [1, 2d + 1]$ ), caractérisées par des fonctions de type triangle pour chacune des entrées, sont définies et réglées manuellement. Ainsi, le nombre de règles construites à partir de ces entrées est de

$m = \prod_{i=1}^{2d+1} n_i = 2^{2d+1}$ . A chaque règle est associée une fonction d'appartenance constante de la variable de sortie.

### 3.2.2.2.2 Propriétés du réseau de neurones

Pour réaliser l'apprentissage du SIF, nous le transformons en son réseau de neurones équivalent (figure 3.10) à propagation directe sur trois couches cachées, selon le principe simplifié suivant :

- la première couche, qui caractérise les fonctions d'appartenance des variables d'entrées, est constituée de  $\sum_{i=1}^{2d+1} n_i$  neurones connectés aux entrées correspondantes,
- la seconde couche, qui représente les règles d'inférences, contient  $m$  neurones reliés en amont aux fonctions d'appartenance concernées,
- la dernière couche, qui modélise les fonctions d'appartenance de la variable de sortie, se compose de  $m$  neurones reliant les règles et la couche de sortie ; un neurone est également ajouté pour normaliser les calculs.

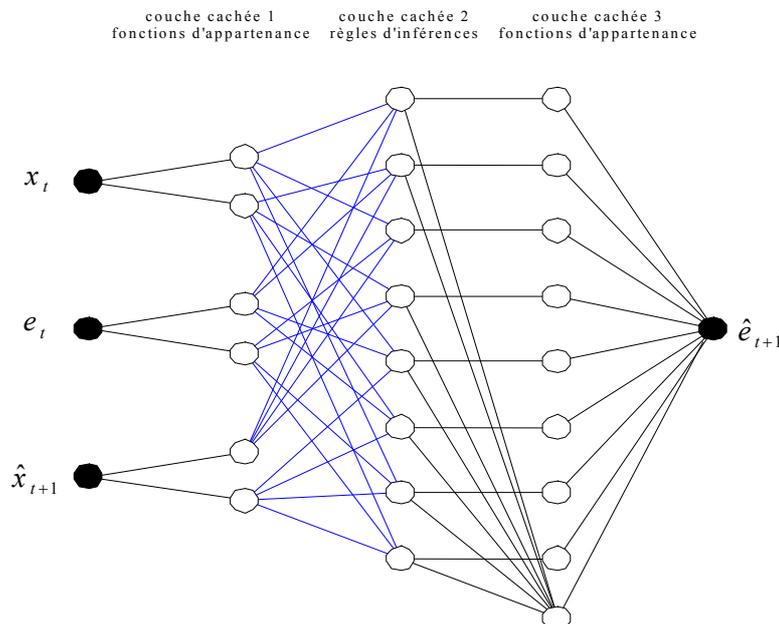


Figure 3.10. Exemple de traduction d'un SIF en RN pour 3 entrées et 2 classes d'appartenance selon la méthode ANFIS

L'apprentissage de ce réseau, qui concerne uniquement les fonctions d'appartenance de la sortie, est assuré par la combinaison de l'algorithme de rétro-propagation et de la méthode des moindres carrés.

Ainsi, le modèle SAMANFIS, fondé sur une technique neuro-floue, conserve les capacités d'apprentissage du modèle SAMANN et exploite les points forts des SIF.

### **3.2.2.3 Conclusion de la prévision court terme à la famille**

Les modèles élaborés dans cette section proposent une estimation automatique des prévisions à court terme (une semaine) des ventes de famille d'articles. Les méthodes d'apprentissage, basées sur des techniques neuronales, assurent par un réseau de neurones ou par un système flou le réajustement des prévisions à moyen terme à partir des dernières ventes.

Les résultats obtenus, que nous exposons dans le chapitre 4, permettent de corriger fortement les approvisionnements actuels. Cependant, l'évolution de ces modèles doit tenir compte d'un besoin de prévisions sur un horizon de 3 à 6 semaines afin d'ajuster également la production et les stocks les plus en amont du distributeur (par exemple : plate-formes à l'étranger). Une solution envisageable, compte tenu de la taille limitée du jeu de données d'apprentissage, est d'appliquer un modèle récursif (avec boucle de rétroaction) déjà recommandé dans différents problèmes de prévision (Weigend, 1992)(Atiya, 1999).

### **3.2.3 Conclusion de la prévision à la famille**

Dans cette section, nous avons présenté différents modèles, concurrents ou complémentaires, permettant de calculer les prévisions à court et moyen terme des ventes de familles d'articles. L'agrégation des données au niveau de la famille est avantageuse d'une part pour obtenir des historiques de plusieurs années, et d'autre part pour analyser l'influence des variables explicatives. Les prévisions obtenues permettent également au décideur d'élaborer une première évaluation et planification des commandes et des approvisionnements.

Toutefois, la structure des modèles, qui modélisent des ventes très perturbées, nécessite des jeux de données importants. Le recours à la classification est alors possible, au détriment d'une perte d'informations.

Les systèmes présentés dans la section suivante, concernent la prévision au niveau référence article. Ils sont partiellement fondés sur les résultats et les techniques des modèles précédents.

### 3.3 Prévision à l'article

Les prévisions des ventes par référence article sont indispensables pour le décideur. En effet, elles conditionnent, directement et spécifiquement, le nombre d'articles à produire (prévision à moyen terme) et à disposer dans les rayons des magasins (prévision à court terme). Cependant, le travail au niveau article est plus complexe. Les prévisionnistes estiment ces prévisions généralement de façon totalement intuitive (section 1.2.2.4) ; certains travaillent même sans prévision et conduisent leur collection "à vue". Nous proposons dans cette section, des méthodes automatiques de prévision des ventes au niveau article dont les résultats peuvent être directement utilisés par le système décisionnel ou exploités comme aide à la décision par les experts.

L'approche est différente en comparaison des familles d'articles. En effet, les références des articles sont généralement non renouvelées et possèdent une durée de vie très courte (6 à 12 semaines) largement inférieure à la périodicité des ventes des familles (52 semaines). La correspondance entre les articles (notion de modèle "père"), codifiés en caractères alpha-numériques, est également souvent perdue d'une saison à l'autre. Généralement, aucun historique de l'article à traiter n'est disponible. Les seules données historiques accessibles sont les ventes des articles des saisons passées. Toutefois, le distributeur peut fournir différents critères concernant les articles futurs tels la période de vie, le prix, le nombre de magasins distribuant l'article, le nombre de coloris différents,...

Les deux premiers modèles développés dans cette section concernent les prévisions à moyen terme des articles d'une même famille. Basés sur la notion de cycle ou profil de vie (section 1.3.2), ils exploitent les critères définis ci-dessus et la prévision au niveau famille. Une classification préalable des articles peut également être implémentée.

Le second modèle traite les prévisions à court terme. Son principe est similaire au modèle SAMANFIS élaborés au niveau famille (section 3.2.2).

#### 3.3.1 Prévision moyen terme à l'article

Les systèmes proposés (Thomassey, 2002d), nommés IDA (Items forecasting model based on Distribution of Agregated forecast) et IDAC (IDA and Classification), calculent les prévisions des ventes au niveau article. Ces procédures, qui concernent les articles d'une même famille, sont basées sur l'élaboration d'une courbe de vie et également sur la répartition des prévisions des ventes par famille.

### 3.3.1.1 Modèle IDA

#### 3.3.1.1.1 Principe

Le modèle IDA est destiné à prévoir les ventes au niveau modèle en s'appuyant sur une courbe de vie moyenne calculée à partir de tous les articles d'une même famille. Le contexte est le suivant : les ventes des articles des deux à trois années précédentes, les prévisions des ventes des familles pour la saison future, et les périodes de vente des articles futurs sont connues. Au contraire, les relations entre les articles appartenant aux collections historiques et futures sont indisponibles.

Le principe de cette méthode est la suivante (figure 3.11) :

- les ventes des articles historiques ( $\{x_T^k\}, \forall k \in [1, NI], \forall T \in [1, A]$  avec  $NI$  le nombre d'articles historiques dans la famille considérée) servent à élaborer un profil (courbe de vie) moyen ( $lcm$ ) par famille,
- ce profil, adapté aux périodes de vie (figure 3.12), constitue l'estimation du profil des articles futurs ( $lc_k, \forall k' \in [1, NI']$  avec  $NI'$  le nombre d'articles futurs dans la famille considérée). Il permet pour chaque semaine de la saison future de définir, pour tous les articles, les "coefficients courbe de vie" ( $c_k, \forall k \in [1, NI]$ ),
- les prévisions des ventes des articles futurs ( $\{\hat{x}_{A+1}^{k'}\}, \forall k' \in [1, NI']$ ) (figure 3.13) sont alors évaluées en fonction de ces précédents coefficients et des prévisions élaborées en niveau famille  $\hat{X}_{A+1}$  selon la formule suivante :

$$\forall i \in [1, NI] \forall t \in [1, p], \hat{x}_{A+1}^i(t) = \frac{c_i(t) \times \hat{X}_{A+1}(t)}{\sum_{k=1}^{NI} c_k(t)}.$$

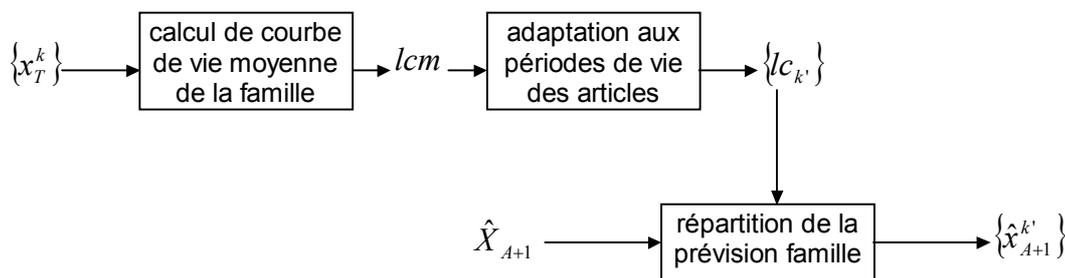


Figure 3.11. Principe du modèle IDA

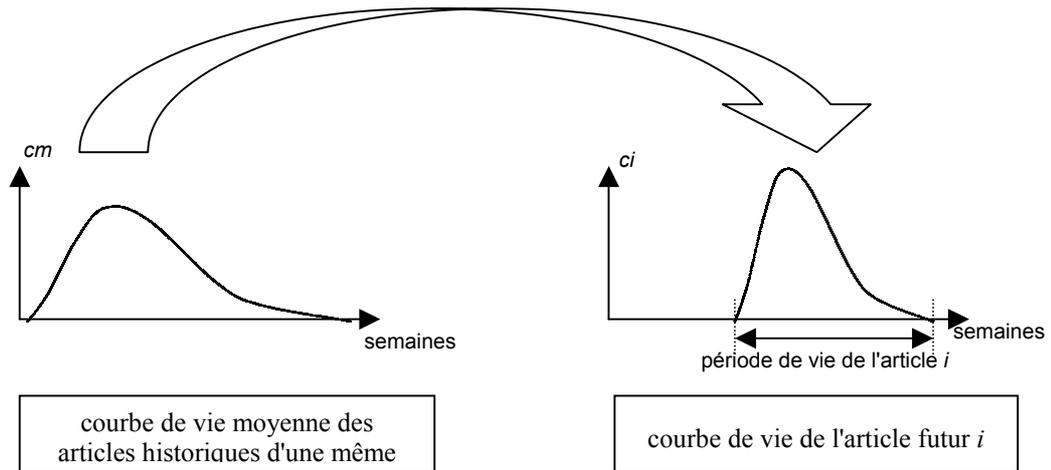


Figure 3.12. Adaptation de la courbe de vie moyenne à la courbe de vie prévisionnelle d'un article

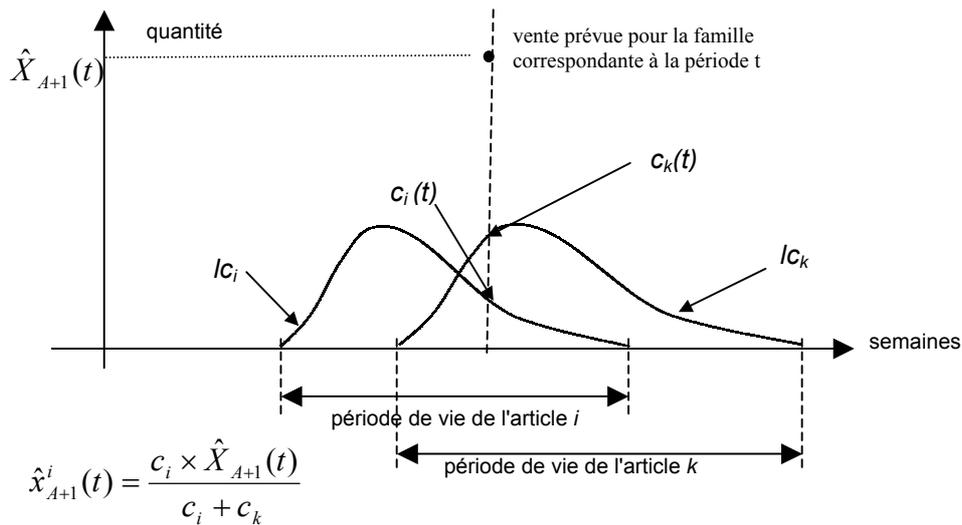


Figure 3.13. Principe de la répartition du modèle IDA pour deux articles  $i$  et  $k$

Cette méthode permet, pour toute période  $t$  de la saison future, de vérifier que la somme des prévisions des articles d'une même famille est effectivement égale à la prévision de cette famille, soit la relation suivante :

$$\sum_{i=1}^{Nf} \hat{x}_{A+1}^i(t) = \hat{X}_{A+1}(t), \forall t \in [1, p].$$

### 3.3.1.1.2 Résumé des caractéristiques

Le modèle IDA permet d'élaborer des prévisions de vente à moyen terme des articles, dont les références sont généralement non renouvelées d'une saison à l'autre. Il fonctionne à partir des prévisions des ventes établies au niveau famille et des ventes historiques de la totalité des articles de la famille considérée.

### 3.3.1.2 Modèle IDAC

Le système IDA, présenté précédemment, est fortement influencé par la précision de la courbe de vie moyenne qui est utilisée pour chaque nouvel article. Afin d'améliorer cette précision, le modèle IDAC propose de définir, par une procédure de classification, une courbe de vie spécifique à chaque article. A partir de ces courbes, la méthode de calcul des prévisions reste identique à celle du modèle IDA (figure 3.13).

#### 3.3.1.2.1 Principe

Dans la section 3.2.1.3, l'objectif de la procédure de classification est de regrouper les historiques des familles afin d'augmenter le nombre de données d'apprentissage. La procédure envisagée dans le modèle IDAC est différente puisqu'elle regroupe les articles historiques et classe les articles futurs. Son principe est le suivant (figure 3.14) :

- une partition  $P(c)$ , composée de  $c$  classes, est formée à partir des articles historiques d'une même famille, proches selon certains critères (prix, nombre de magasins distribuant l'article, nombre de coloris disponibles,...),
- les ventes des articles d'une même classe permettent d'élaborer une courbe de vie spécifique à la classe,
- les nouveaux articles sont associés à la classe dont le centre est le plus proche selon les critères considérés précédemment,
- les profils prévisionnels des articles futurs sont ainsi caractérisés par la courbe de vie de la classe à laquelle ils appartiennent, adaptée à leur durée de vie,
- enfin, à partir de ces profils spécifiques, la prévision est alors évaluée selon le même principe que le modèle IDA.

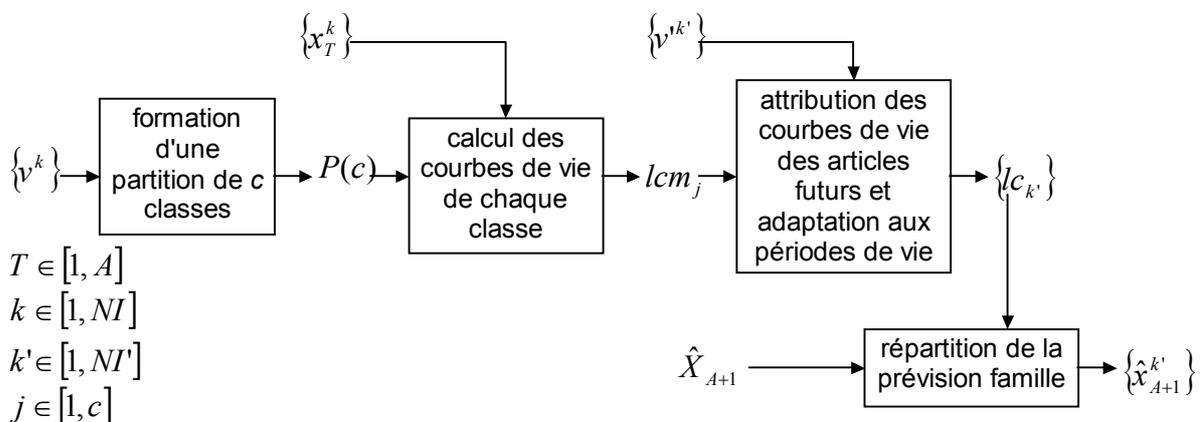


Figure 3.14. Principe du modèle IDAC

### 3.3.1.2.2 *Caractéristiques de la classification*

- *Critères de classification*

Les critères de classification des articles sont évidemment très importants et doivent représenter au mieux le comportement de vente des articles. Cependant, la disponibilité des données est limitée et la classification du profil de vente, proposée précédemment pour les ventes de familles d'articles, n'est pas applicable dans ce contexte. En effet, aucun des profils des nouveaux articles n'étant connu, il est impossible de leur attribuer une classe avec un profil proche. Notre choix s'est alors porté sur des critères disponibles sur la saison future et influençant, selon les experts, significativement les ventes soient : le prix moyen, le nombre de coloris différents, la période de vente et le nombre de magasins distribuant le modèle.

A partir de ces critères, plusieurs stratégies de classification sont envisagées :

- une procédure de classification "temporelle" qui réunit les articles dont les périodes de ventes sont similaires ; le comportement des ventes est alors supposé différent selon la période (vacances scolaires d'été, Noël, ...)
- une procédure de classification du type "multicritères" qui distingue partiellement ou en totalité les critères décrits précédemment à l'exception de la période de vente (prix moyen, nombre de coloris différents et nombre de magasins distribuant l'article) ; ces critères peuvent révéler une certaine évolution des ventes : par exemple, un modèle à faible prix possède un "pic de lancement" plus conséquent qu'un modèle onéreux,
- enfin, une procédure de classification "séquentielle" qui applique consécutivement les deux méthodes précédentes dans l'ordre "temporelle" - "multicritères" ; on obtient ainsi des partitions selon la période de vente des articles puis, pour chacune des partitions, les articles sont classés selon les critères sélectionnés.

Ces différentes stratégies peuvent être appliquées indifféremment selon une classification hiérarchique ou floue. Dans ce dernier cas, les profils des nouveaux articles sont élaborés en pondérant les courbes de vie des classes en fonction de leur degré d'appartenance.

La distance choisie pour cette application est également la distance euclidienne.

- *Critère CBF d'optimisation du nombre de classes*

En section 3.2.1.3.2, nous déterminons le nombre de classes optimal à partir du critère de Xie. Le calcul de ce critère, qui est basé sur l'optimisation des distances intra et

interclasses, peut également être reproduit pour la procédure de classification du modèle IDAC. Cependant, l'objectif est de viser la meilleure précision de prévision. Ainsi, nous avons envisagé un critère intégrant une quantification de cette précision, nommé *CBF* (Classification for Better Forecast). Ce critère élabore la prévision par le processus du modèle IDA sur les modèles historiques, pour un nombre de classes fixé variant entre 1 et le nombre d'articles dans la famille considérée. La performance des prévisions correspondantes pour chaque partition est alors estimée par le critère *NMSE* (section 2.3.1.4). Le choix ce critère *NMSE*, qui est indépendant de l'échelle des données, est motivé par la possibilité de considérer les séries de vente quelque soit leur importance en terme de quantité. Le nombre de classes correspondant à la meilleure prévision sur les ventes historiques est alors sélectionné pour les articles futurs.

#### 3.3.1.2.3 *Résumé des caractéristiques*

Le modèle IDAC intègre une procédure de classification identique au modèle IDA. Ainsi, l'estimation des courbes de vie des articles futurs est plus spécifique et permet d'envisager une amélioration de la précision de la prévision. Cependant, pour un fonctionnement optimal de ce modèle, les critères de la classification doivent être relativement caractéristiques du comportement des ventes.

#### 3.3.1.3 **Conclusion de la prévision moyen terme à l'article**

Les modèles IDA et IDAC présentés dans cette section élaborent des prévisions à moyen terme au niveau article. Ils répondent aux contraintes imposées par le contexte textile où les références des articles sont en général non renouvelées et sans aucune correspondance à chaque saison. Le modèle IDA, qui traite simultanément tous les articles d'une même famille, estime les ventes de chaque nouvel article un an à l'avance à partir des prévisions moyen terme des ventes de la famille, calculées par un modèle du type AHFCCX, et des ventes des articles historiques. Le modèle IDAC intègre par une procédure de classification certains critères influençant les ventes tels : le prix, le nombre de coloris, le nombre de magasins distribuant l'article.

L'efficacité de ces modèles est conditionnée par la définition des familles et la pertinence des données disponibles pour la classification, qui révèlent souvent une difficulté à obtenir des informations dans la distribution textile.

Enfin, les prévisions réalisées par ces modèles peuvent être directement justifiées en entrée d'un processus d'optimisation des approvisionnements ou d'un système de prévision

à la taille et au coloris, ou encore être appliquées comme aide à la décision par le prévisionniste.

### **3.3.2 Prévision court terme à l'article**

Les problématiques de la prévision à court terme au niveau famille et article sont identiques et les mêmes modèles de prévision du type SAMANN et SAMANFIS peuvent donc être intéressants.

Cependant, compte tenu du nombre réduit de données par article (durée de vie courte des articles), les difficultés d'apprentissage sont plus fortes. Ainsi, contrairement à la prévision au niveau famille où l'apprentissage du système est effectué pour chaque historique, le réglage des paramètres est réalisé sur la totalité des articles historiques d'une famille. La prévision des ventes à court terme de chacun des nouveaux articles d'une même famille, qui intègre les prévisions à moyen terme et les dernières ventes, est alors construit par un système SAMANFIS identique à la prévision au niveau famille.

### **3.3.3 Conclusion de la prévision à l'article**

Dans cette section, nous avons développé des méthodes de prévision des ventes de modèles à moyen et court terme, qui sont adaptées aux caractéristiques des données généralement disponibles par le distributeur : historiques inconnus des références de chaque article et critères descriptifs qualitatifs et quantitatifs des articles peu nombreux.

La prévision à moyen terme est traitée par le système IDA qui est fondé sur la répartition des prévisions à moyen terme au niveau famille et sur l'estimation d'une courbe de vie moyenne. La méthode reste simple et n'utilise pas de procédure d'optimisation complexe nécessitant de nombreuses données d'apprentissage.

Le modèle IDAC est une extension du modèle IDA, défini à partir d'une procédure de classification. Il permet, en regroupant les articles selon certains critères, de calculer des courbes de vie spécifiques. L'efficacité de cette méthode repose essentiellement sur l'utilisation et la disponibilité de critères suffisamment significatifs du comportement des ventes des articles.

Enfin, la prévision à court terme est développée à partir des mêmes modèles du type SAMANN et SAMANFIS déjà élaborés pour les familles. Compte tenu des historiques très réduits des articles et de l'impossibilité à régler les systèmes pour chacune des références, un seul apprentissage est effectué sur la totalité des modèles historiques.

La section suivante envisage les prévisions des ventes des articles au niveau coloris et tailles.

### 3.4 Prévision au coloris et à la taille

Plus le niveau d'agrégation des données est fin, plus les prévisions sont délicates. Ainsi, les prévisions des ventes au coloris et à la taille sont encore plus complexes.

Les problèmes rencontrés dans la section précédente, historiques réduits et références perdues d'une saison à l'autre, sont amplifiés, notamment pour les coloris.

#### 3.4.1 Prévision au coloris

Généralement, les coloris d'une collection sont choisis en fonction de l'évolution de la mode et sont donc non renouvelés, à l'exception des couleurs basiques (blanc, noir,...). Ils sont également parfois ajoutés ou soustraits au cours de la période de vie de l'article. Ces contraintes obligent les experts à affiner les prévisions par coloris intuitivement à partir de leur connaissance du marché. Dans ce contexte, l'automatisation paraît difficile. Le système envisagé (figure 3.15) est fondé sur une répartition des prévisions établies au niveau article. La répartition initiale est effectuée par le décideur (ou si possible par l'historique), et les premières ventes permettent d'ajuster les prévisions par un modèle du type SAMANN ou SAMANFIS (sections 3.2.2.1 et 3.2.2.2). Enfin, il est possible d'imaginer un apprentissage différent pour les coloris basiques et mode.

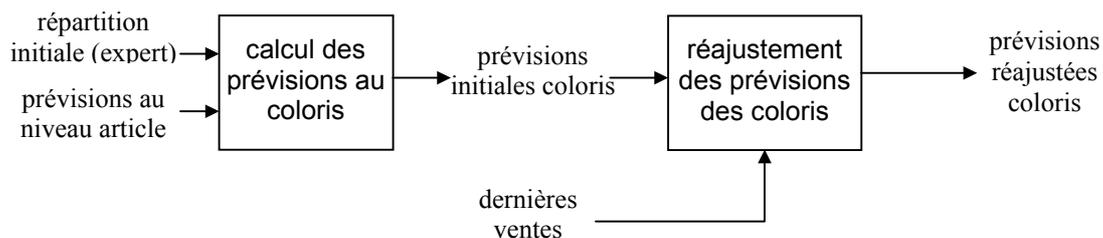


Figure 3.15. Principe d'un modèle de prévision au coloris

#### 3.4.2 Prévision à la taille

Contrairement à la problématique coloris, les prévisions par taille sont en général bien maîtrisées par le distributeur. En effet, la répartition des tailles du consommateur varie peu au cours du temps. Ainsi, les historiques, constituant une source d'informations fiable, la méthode de prévision des ventes proposée (figure 3.16) est fondée sur la répartition

présumée des ventes de l'article correspondant, calculée selon une distribution historique des tailles.

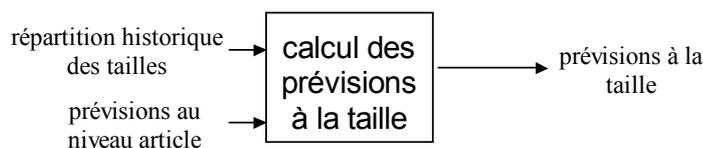


Figure 3.16. Principe d'un modèle de prévision à la taille

### 3.4.3 Conclusion de la prévision au coloris / taille

La prévision au niveau coloris, très délicate, nécessite l'intervention d'experts afin de prendre en compte les tendances du marché et de la mode. Seuls, les ajustements des répartitions des prévisions entre les coloris d'un modèle peuvent être réalisés par un système du type SAMANN ou SAMANFIS.

La prévision des ventes par taille est plus facile à mettre en œuvre, les répartitions attribuées par les ventes historiques pouvant être généralement extrapolées sur la saison future.

## 3.5 Conclusion

Dans la filière textile, nous avons proposé pour le distributeur différents modèles permettant d'élaborer des prévisions des ventes à divers niveaux d'agrégations (de la famille d'articles jusqu'à la référence taille/coloris) et à différents horizons (court et moyen terme).

Les modèles du type HFCCX, HNCCX et AHFCCX concernent les prévisions à moyen terme des ventes des familles. Leur fonctionnement est totalement ou partiellement automatique. L'agrégation des ventes par famille permet d'acquérir des historiques continus sur plusieurs années. Il est possible ainsi de traiter plus facilement l'influence des variables explicatives les plus pertinentes. Les corrélations entre ces dernières et les ventes, souvent non linéaires et très complexes, ont justifié, pour la construction et l'apprentissage de nos modèles, l'emploi de techniques issues du "soft computing". Afin d'augmenter la taille du jeu de données d'apprentissage, une procédure de classification des familles selon leur profil de vente a été également nécessaire et positionnée en amont de nos modèles de prévision.

Les modèles du type SAMANN et SAMANFIS, qui élaborent les prévisions à court terme au niveau famille et article, sont basés sur le réajustement des prévisions à moyen

terme en fonction des dernières ventes. Leur capacité d'adaptation aux nouvelles consignes de ventes est assurée par des méthodes neuronales ou neuro-floues. Si, compte tenu du nombre de données historiques disponibles, il est envisageable de réaliser un apprentissage du système par famille, le même système (un seul apprentissage global) est proposé pour tous les modèles d'une même famille.

Les systèmes IDA et IDAC, qui calculent les prévisions des ventes des articles, sont fondés sur l'estimation d'une courbe de vie moyenne par famille (système IDA) ou issus d'une classification des articles (système IDAC). La répartition des prévisions par famille est alors effectuée selon le nombre d'articles vendus et selon leur courbe de vie respective. La stratégie de classification, préconisée par le système IDAC, requiert la disponibilité de critères permettant de caractériser le plus précisément possible les ventes des articles historiques et futurs.

Enfin, des propositions de méthodes de prévision au coloris et à la taille sont développées. La problématique des ventes par coloris ne permettant pas d'envisager une procédure automatique fiable, nous optons pour un ajustement des répartitions initiales du prévisionniste à partir des dernières ventes. La prévision des ventes par taille est calculée sur la répartition classique historique.

Nous proposons, dans le chapitre suivant, d'expérimenter ces modèles sur un jeu de données réelles provenant d'un important distributeur de prêt-à-porter et correspondant à l'équivalent de 15000 références par an.

# Chapitre 4

## Expérimentation du système de prévision

### 4.1 Introduction

Nous avons développé, dans le chapitre précédent, différents modèles de prévision des ventes à divers niveaux d'agrégation (famille, article, taille/coloris) pour des horizons moyen et court terme (figure 4.1). Afin de prendre en compte le comportement complexe des ventes textiles et l'influence des variables explicatives les plus pertinentes, ces systèmes exploitent les avantages des outils issus du "soft computing".

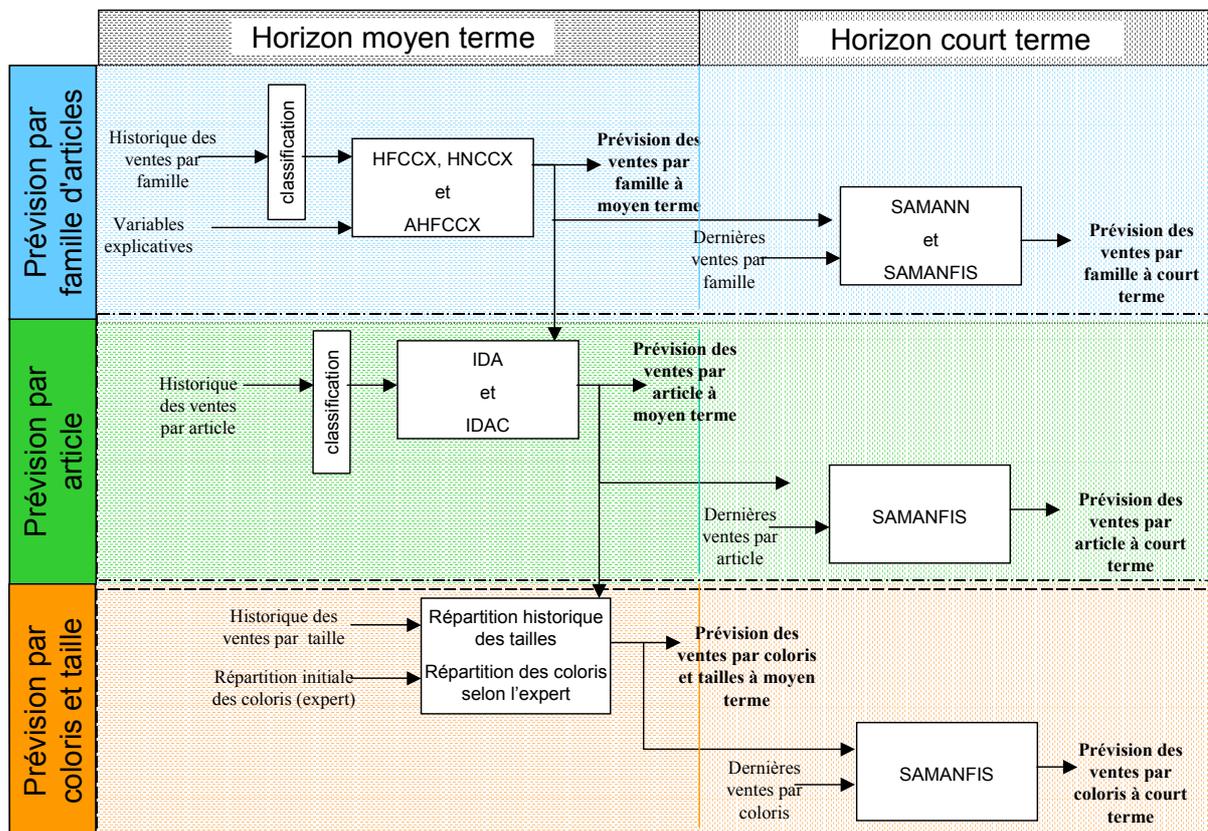


Figure 4.1. Rappel des modèles proposés selon l'horizon et l'agrégation des ventes

Dans ce chapitre, nous proposons de valider la performance de nos modèles en les comparant à des modèles classiques sur un jeu de données provenant d'un grand distributeur textile français. Les critères de précision utilisés sont présentés dans la section 2.3.1.4. Les modèles classiques testés sont soit issus du logiciel Forecast Pro de la société Business Forecasting Software, soit mis au point lors de mes travaux de recherche.

Dans la section suivante, nous présentons les principales caractéristiques des données de vente et les variables explicatives retenues pour notre expérimentation. Puis, nous abordons les modèles classiques servant de référence pour nos comparaisons. Enfin, nous décrivons successivement les résultats obtenus par nos modèles pour la prévision par famille, article et taille / coloris.

## **4.2 Caractéristiques du jeu de données**

Ce jeu, issu d'une base de données concernant le prêt à porter, est composé de l'historique des tickets de caisse, décrivant les ventes et les prix de vente à la référence taille/coloris par magasin par jour sur quatre années maximum (1998 à 2001). Ce jeu contient également une table de codification permettant d'agrèger les références par famille d'articles. Cependant, un bouleversement de la codification au cours de l'année 2001 a fortement limité le nombre de familles comportant quatre années d'historique.

### **4.2.1 Données de ventes**

Les données extraites des tickets de caisse subissent au préalable un traitement permettant d'agrèger les ventes à la semaine sur la totalité des magasins. La table de codification assure le reclassement du jeu de données par famille et par article.

#### **4.2.1.1 Ventes par famille**

L'objectif de l'agrégation des ventes par famille est de disposer d'historiques complets sur plusieurs années. Parmi les 2754 familles d'articles différentes recensées dans le jeu de données réelles, nous pouvons extraire 322 familles qui s'étendent sur trois années d'historiques complets (1998, 1999 et 2000). Ces dernières représentent 65%, 68% et 67% du chiffre d'affaires des années 1998, 1999 et 2000 de notre partenaire distributeur. Seuls, 9 parmi les 322 familles n'ont pas été affectées par le changement de codification de 2001 et permettent de tester nos modèles sur quatre années successives.

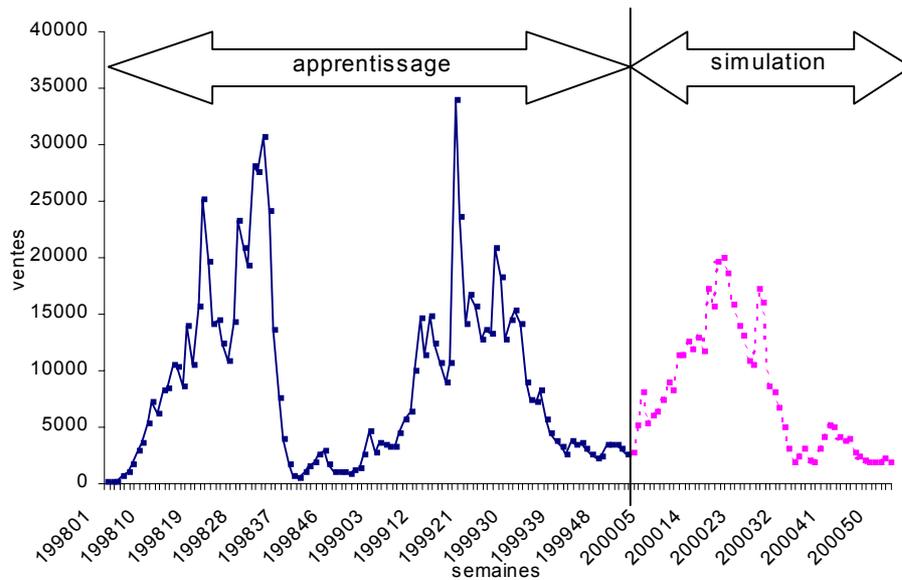


Figure 4.2. Prédiction à moyen terme pour 3 années d'historiques

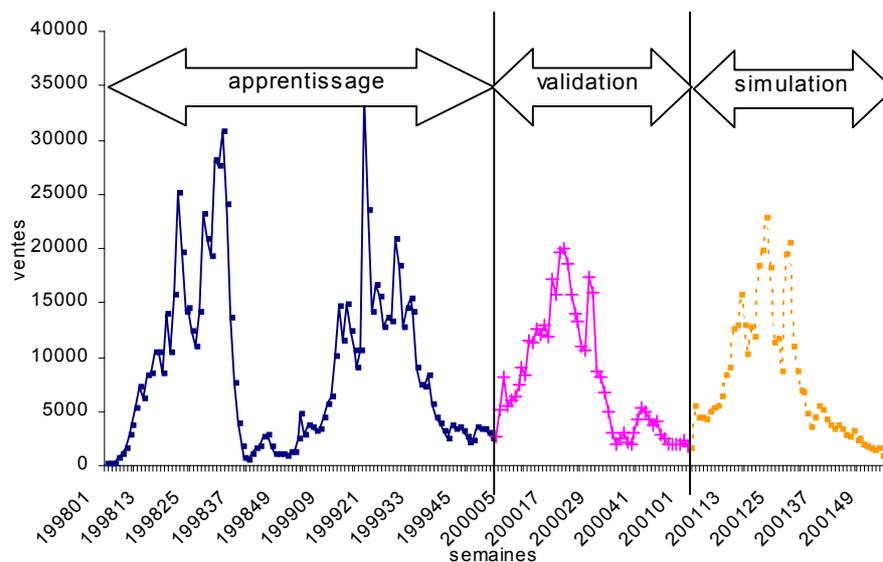


Figure 4.3. Prédiction à moyen terme pour 4 années d'historiques

Les familles concernent différents types de produits tels des pantalons, des pulls, des T-shirts, des robes, de la lingerie pour homme, femme ou enfant.

Pour les comparatifs des prévisions à moyen terme utilisant trois ans d'historiques, les deux premières années concernent l'apprentissage des modèles et la troisième année sert de référence pour la simulation (figure 4.2). Lorsqu'une quatrième année est disponible, il est possible d'envisager un apprentissage par validation (figure 4.3). La simulation (les ventes sont supposées inconnues) est effectuée sur la dernière année. La troisième année (les

ventes sont connues) permet d'évaluer les prévisions des modèles qui ont été réglés sur les deux premières années afin de choisir le plus performant.

Les modèles HFCCX et HNCCX, qui nécessitent de la part de l'expert une correction longue et fastidieuse des historiques, ont été testés et comparés uniquement sur deux familles de base composées d'articles de la collection automne-hiver.

Les tests des modèles de prévision à court terme exploitent, pour la procédure d'apprentissage, les deux premières années d'historiques ainsi que les ventes de l'année en cours jusqu'à la dernière semaine connue  $T$ , la prévision étant calculée sur la semaine  $T+1$ . L'évaluation des modèles est enfin réalisée pour  $T$  variant de 1 à  $p$  (figure 4.4).

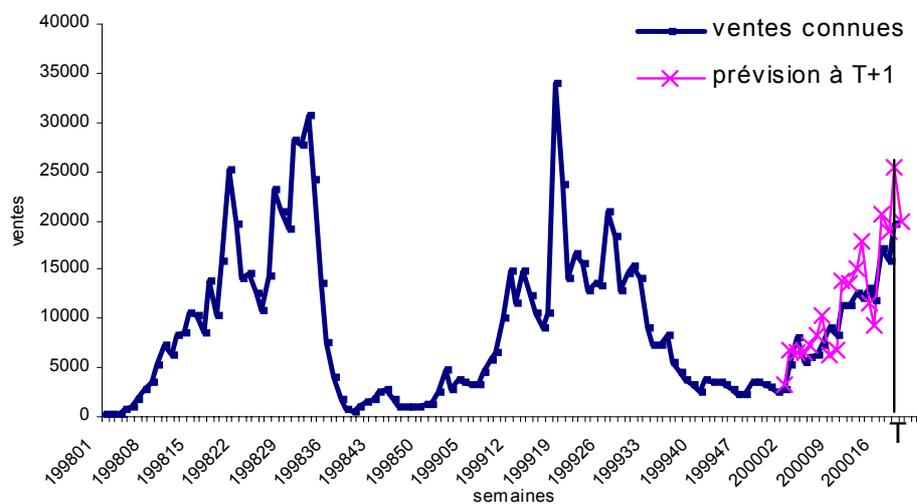


Figure 4.4. Prévision à court terme ( $T$  variant de 1 à  $p$ )

#### 4.2.1.2 Ventes par article

Les principales caractéristiques des ventes par article sont leur durée de vie réduite et le nombre fluctuant et souvent très important de références vendues par semaine (figure 4.5).

Les articles considérés sont issus des 322 familles étudiées précédemment (section 4.2.1.1). Cependant, compte tenu du nombre important de références à ce niveau d'agrégation (41966 articles pour les 322 familles), et principalement du temps d'extraction des données à partir de la base (1 minute 30 secondes par article), nous n'avons pu retenir que 4070 articles parmi les familles les plus importantes en terme de chiffre d'affaires. Le temps de traitement des informations par nos modèles est souvent négligeable. Parmi les articles d'une même famille, une nouvelle sélection selon le principe de classification 80/20, permet de ne traiter que les plus significatifs en terme de chiffres d'affaires. Cette

opération élimine les nombreuses références vendues très peu de temps et/ou celles dont les ventes sont négligeables.

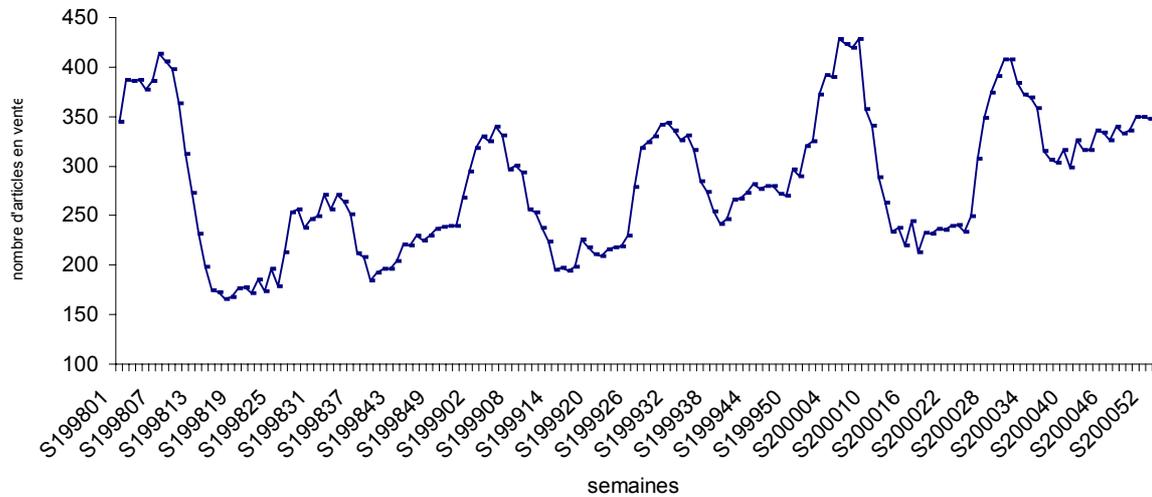


Figure 4.5. Nombre d'articles différents vendus par semaine pour une famille de type lingerie

De façon similaire à la répartition des données par famille, les historiques des deux premières années sont exploités pour l'apprentissage (formation des courbes de vie et des classes). La troisième année permet d'effectuer la comparaison entre les prévisions et les ventes réelles et également d'identifier les périodes de vente des articles ainsi que les critères utilisés par le modèle IDAC (prix, nombre de magasins distribuant l'article, nombre de coloris).

#### 4.2.2 Variables explicatives

L'influence des variables explicatives sur les ventes est prise en compte par les modèles HFCCX, HNCCX et AHFCCX (section 3.2.1). Ces derniers considèrent principalement le prix et les vacances. Deux autres variables, les vacances avec un retard d'une semaine et la période, sont également appliquées pour caractériser plus fortement l'effet des deux facteurs précédents. La figure 4.6 représente un cas réel de ventes et permet de justifier le choix de ces variables. En effet, on remarque que le prix et les vacances n'ont pas la même influence sur les ventes. La première semaine de la rentrée scolaire (l'indice *Vac* devient nul) est caractérisée par une forte hausse des ventes. Une baisse des prix (hausse de l'indice *Px*) paraît également très influente à cette période. Les vacances de Toussaint ont peu d'effet sur les ventes. Par contre, une promotion à cette époque provoque une

augmentation de la consommation. L'approche de Noël génère une forte hausse des ventes qui s'estompe dès l'échéance passée ; le prix est alors moins influent.

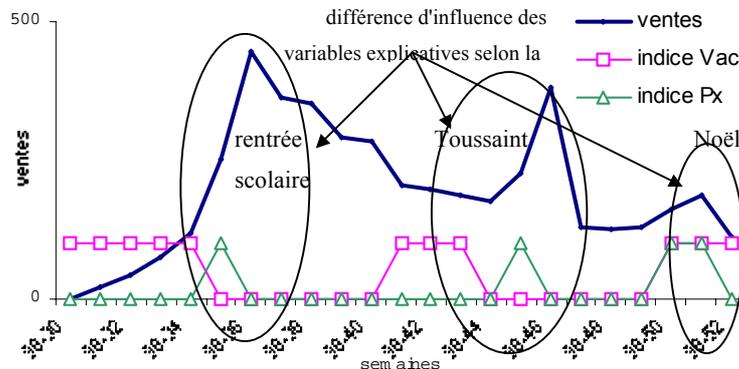


Figure 4.6. Influence des variables explicatives sur les ventes selon la période

Le prix de vente des articles, extrait à partir des données "ticket de caisse" et les périodes de vacances et de l'année, extraites à partir du calendrier scolaire, doivent être traduits par les indices suivants :

- Indice  $Px$

Les données brutes regroupent le prix des articles vendus dans tous les magasins du même distributeur. Il est fréquent que l'article ne soit pas au même prix en même temps dans tous les magasins. En effet, le prix peut parfois être normal ou promotionnel selon les magasins durant la période observée.

Aussi l'indice  $Px$ , compris dans l'intervalle  $[0, 100]$ , correspond à une valeur moyenne de la promotion sur la totalité des magasins et s'exprime comme suit :

$$Px(t) = \frac{px_{mag}(t) - px_{min}}{px_{max} - px_{min}} \times 100, \forall t \in [1, p]$$

avec

$px_{mag}$  prix moyen du produit considéré dans tous les magasins du distributeur

$px_{min}$  minimum de  $px_{mag}(t)$ ,  $t \in [1, p]$

$px_{max}$  maximum de  $px_{mag}(t)$ ,  $t \in [1, p]$

- Indices  $Vac$  et  $Vac-1$

L'indice  $Vac$ , compris entre 0 et 100, associé à la variable vacances est égal au nombre de zones scolaires en vacances, pondéré par le nombre de magasins répartis dans les zones correspondantes. Par exemple (figure 4.7), si seules les zones A et B sont en vacances :  $Vac = 30,2 + 52,3 = 82,5$ .

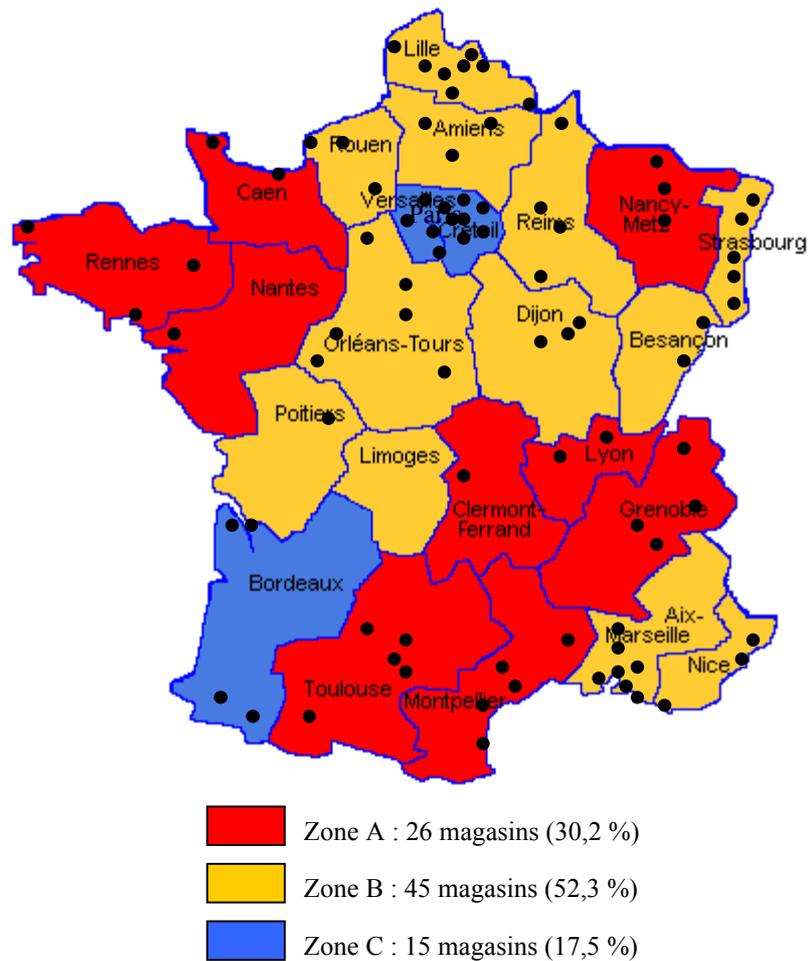


Figure 4.7. Répartition géographique des magasins et zones scolaires correspondantes

- Indice *Per*

L'indice de la période *Per* est égal au numéro de la semaine de l'année considérée. Cet indice est complémentaire des deux précédents. En effet, il permet de mieux caractériser l'influence du prix et des vacances, qui varie au cours de la saison (figure 4.6).

### 4.3 Modèles de prévision de référence

Afin d'évaluer sur notre jeu de données la performance de nos modèles, nous les comparons avec des modèles classiques (section 2.3). Ces modèles, testés sur les prévisions à moyen ou court terme des ventes par famille ou par article, sont les suivants :

- Modèle de base (BMS)

Le modèle de base BMS (Basic Model with Seasonality), destiné à la prévision à moyen terme des ventes par famille, est fondé sur la même méthode de calcul de la

prévision (moyenne de la saisonnalité) que les modèles HFCCX et HNCCX. La seule différence réside dans la non considération des variables explicatives.

- **Modèle de Holt Winter avec Saisonnalité (HWS)**

Ce modèle (section 2.3.2.1), testé sur les ventes par famille à moyen et court terme, est basé sur une saisonnalité multiplicative. L'optimisation des paramètres est effectuée par la méthode des moindres carrés. Cependant, le réglage de la composante saisonnière nécessite 3 années d'historique. Pour opérer le comparatif des prévisions à moyen terme, nous avons sélectionné l'année destinée à la simulation pour optimiser le coefficient saisonnier. La prévision calculée est donc la meilleure possible pour nos simulations mais peu probable dans la pratique industrielle.

- **Sélection automatique de modèles par Forecast Pro (AS-FP)**

Ces modèles ne prennent pas en compte les variables explicatives et sont appliqués pour les comparatifs des prévisions à moyen et court terme par famille d'articles.

Le logiciel Forecast Pro permet d'une part, de sélectionner parmi 3 modèles (moyenne mobile, lissage exponentiel, Box&Jenkin's) celui qui est le plus approprié à la série et d'autre part, d'optimiser ensuite ses paramètres. Différents tests statistiques sont également effectués automatiquement pour détecter la stationnarité et la saisonnalité des séries.

- **Modèle de Régression Dynamique (DRX)**

Ce modèle (Pankratz, 1991) est appliqué pour les prévisions à moyen et court terme au niveau famille. Proposé par le logiciel Forecast Pro, il autorise le traitement des variables explicatives. Le choix manuel des régresseurs est assisté de divers tests, permettant ainsi aux utilisateurs non expérimentés d'exploiter au mieux ce modèle.

Cependant, compte tenu de la nécessité de l'intervention d'un opérateur pour la sélection des régresseurs, il n'est pas possible de l'évaluer sur un grand nombre de séries.

- **Modèle ARMAX**

Afin d'ajouter un modèle supplémentaire avec variables explicatives, nous expérimentons également le modèle ARMAX (section 2.3.2.3). Ce modèle est expérimenté sur les prévisions à moyen et court terme au niveau famille. Les ordres des processus auto régressif (AR), moyenne mobile (MA) et variables explicatives (X), qui ne doivent pas généralement être trop élevés (Boubonnais, 1992)(Lewandowski, 1983), sont sélectionnés en fonction des résultats de ces processus sur les données d'apprentissage ; les paramètres sont optimisés par un algorithme de Gauss Newton itératif (Ljung, 1987).

- **Modèle neuronal ENARX**

Ce modèle, exploité sur les prévisions à moyen terme des ventes par famille, est du type auto-régressif issu d'un réseau de neurones avec variables explicatives (Vroman, 1999). Sa structure totalement neuronale autorise la modélisation de l'influence non-linéaire des variables explicatives, mais il nécessite généralement un grand nombre de données pour un apprentissage performant.

- **Modèle de répartition basique (RB)**

La prévision à moyen terme au niveau article est très spécifique (section 3.3). Afin d'acquérir une base de comparaison pour nos modèles IDA et IDAC, nous avons également évalué le modèle RB. Celui-ci, contrairement aux modèles classiques précédents, autorise le traitement des articles nouveaux qui ne possèdent pas d'historique propre, en répartissant uniformément les prévisions par famille sur chacun des articles vendus pendant la semaine considérée.

## **4.4 Prévision à la famille**

### **4.4.1 Prévision moyen terme à la famille**

#### **4.4.1.1 Modèles HFCCX et HNCCX**

##### *4.4.1.1.1 Présentation*

Ce premier comparatif vise l'étude des modèles HNCCX, HFCCX (section 3.2.1.1) et les variables explicatives correspondantes (section 4.2.2). Les deux modes d'apprentissage du modèle HFCCX : neuronal (ANFIS) et algorithme génétique (GA), sont testés. Les modèles classiques expérimentés sont les suivants : BMS, HWS, AS, DRX, ARMAX et ENARX. Compte tenu de l'intervention humaine nécessaire pour certains modèles (HFCCX, HNCCX et DRX), le jeu de données comporte uniquement deux familles d'articles de type pulls et pantalons basiques appartenant à la collection automne-hiver (semaines 31 à 52). Les prévisions possèdent un horizon à moyen terme d'une saison (22 semaines). Les deux premières saisons servent à l'apprentissage des modèles, la troisième concerne la simulation. Les critères de précision considérés sont le critère *RMSE*, qui sanctionne principalement les erreurs importantes, et le critère *EACA*, qui traduit les erreurs en chiffres d'affaires (section 2.3.1.4).

Les résultats obtenus permettent de valoriser :

- l'apport du traitement des variables explicatives en comparaison des méthodes purement extrapolatives (BMS, HWS, AS),
- l'intérêt des méthodes du "soft computing", comparées aux modèles classiques avec variables explicatives (DRX, ARMAX),
- le bénéfice du traitement séparé des variables explicatives par rapport au traitement simultané de la série temporelle et des variables associées (ENARX),
- les éventuelles différences entre les techniques floues (HFCCX) et neuronales (HNCCX).

#### 4.4.1.1.2 Résultats

Les figures 4.8 à 4.11 permettent d'évaluer la précision des prévisions des modèles expérimentés sur les familles d'articles de type pulls et pantalons, selon les critères *RMSE* et *EACA*. La figure 4.12 représente les courbes de prévision obtenues pour la famille de type pulls.

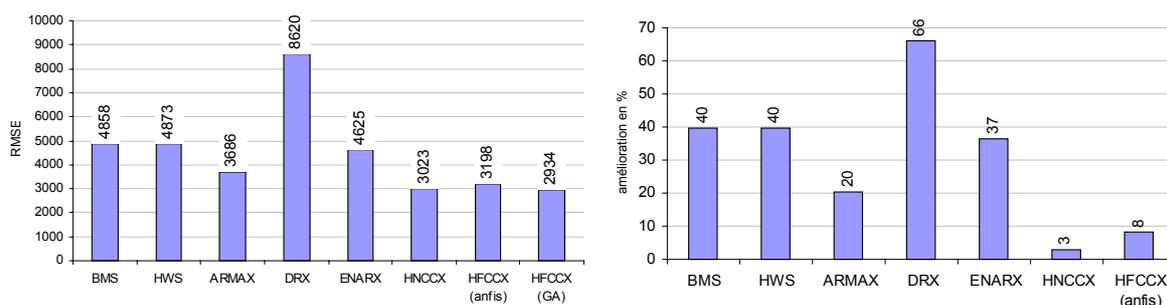


Figure 4.8. Performance des prévisions des ventes de la famille de type pull – critère *RMSE* et amélioration en % apportée par le modèle *HFCCX (GA)*

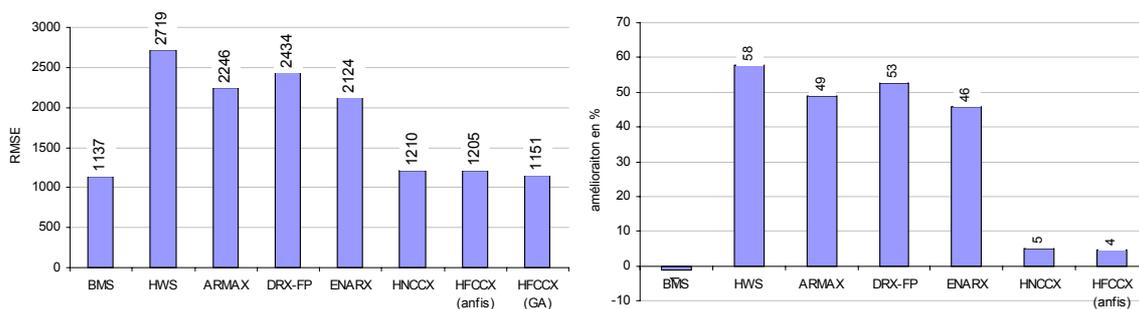


Figure 4.9. Performance des prévisions des ventes de la famille de type pantalon – critère *RMSE* et amélioration en % apportée par le modèle *HFCCX (GA)*

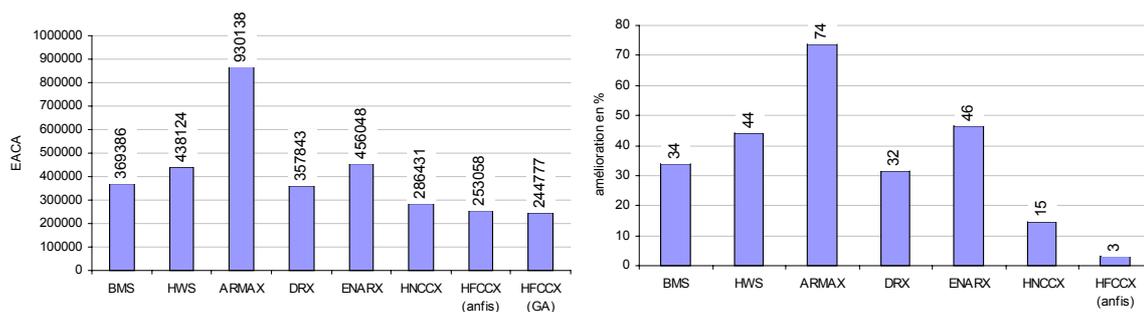


Figure 4.10. Performance des prévisions des ventes de la famille de type pull – critère EACA et amélioration en % apportée par le modèle HFCCX (GA)

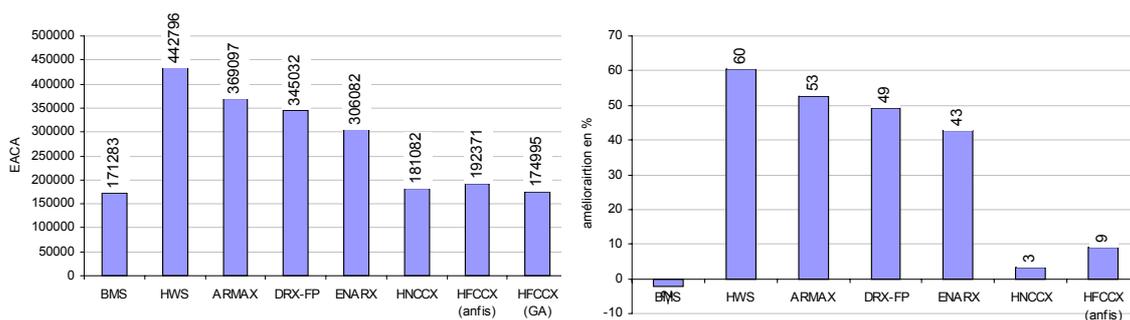


Figure 4.11. Performance des prévisions des ventes de la famille de type pantalon – critère EACA et amélioration en % apportée par le modèle HFCCX (GA)

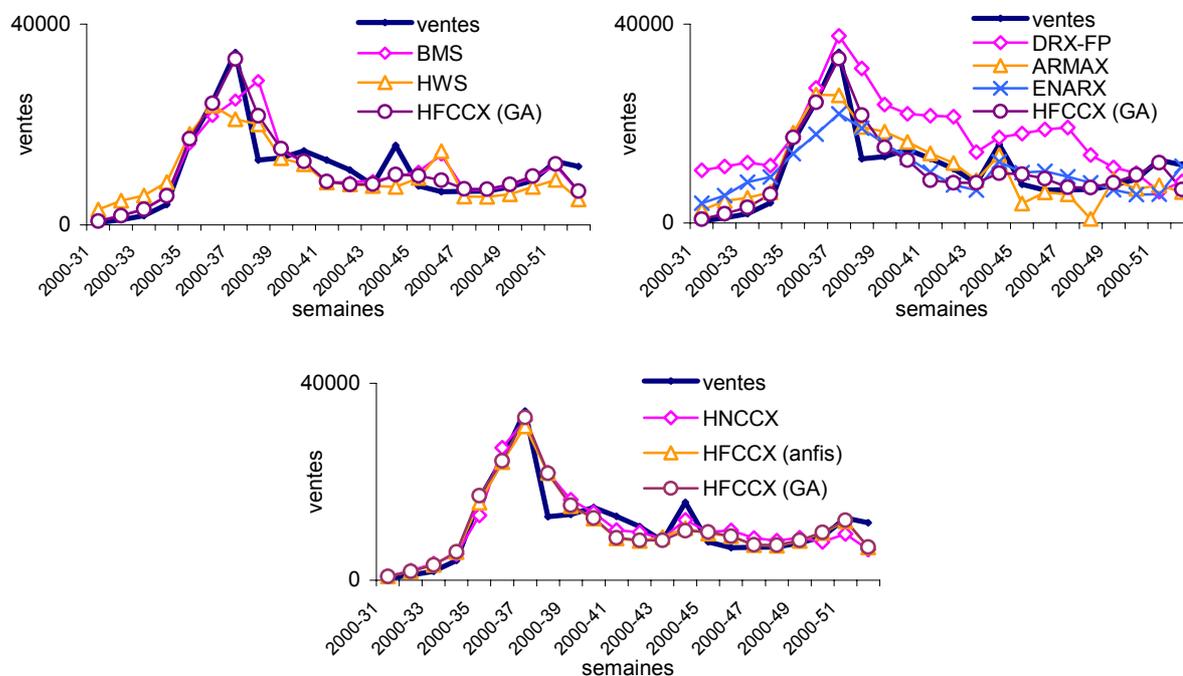


Figure 4.12. Prédiction des modèles sur les ventes de la famille de type pulls

#### 4.4.1.1.3 Analyse

Les performances des modèles classiques sans variable explicative pour la famille de type pulls sont faibles en terme de précision. Les résultats des modèles ENARX et DRX-FP ne sont guère plus favorables ; le modèle ARMAX réalise la meilleure prévision des systèmes classiques.

Nos trois modèles (HNCCX, HFCCX ANFIS et HFCCX GA) génèrent les valeurs des critères *RMSE* et *EACA* les plus faibles qui traduisent une erreur de prévision plus réduite, la procédure floue avec apprentissage par un algorithme génétique (modèle HFCCX GA) se distinguant sensiblement par une précision plus fine.

Nous constatons, pour les ventes de la famille de type pulls, que les variables explicatives sont relativement significatives. En effet, les modèles sans variable explicative n'anticipent pas ou peu l'augmentation des ventes provoquée par les vacances et les promotions sur les semaines 35 et 47. Les modèles ENARX et DRX-FP, pénalisés par le nombre réduit de données d'apprentissage, ne peuvent prendre en compte les dépendances entre les ventes et les variables explicatives. Le modèle ARMAX, moins complexe, est pour sa part limité par sa structure linéaire. Malgré des historiques réduits, nos modèles, en intégrant l'influence des variables explicatives, semblent mieux adaptés sur cette série chronologique.

Ces résultats se confirment sur les ventes de la famille de type pantalons. Seul, le modèle BMS fait exception. Les performances des autres modèles classiques restent toujours relativement faibles. On remarque que le modèle HNCCX obtient des résultats sensiblement meilleurs pour le critère *EACA* (celui-ci sanctionne les erreurs en chiffre d'affaires) que son homologue flou (HFCCX ANFIS) alors que les résultats de ce classement sont inversés pour le critère *RMSE* (celui-ci quantifie les erreurs en nombre d'articles). Ce résultat s'explique par les erreurs de prévision du modèle HFCCX plus particulièrement lorsque le prix moyen des articles est élevé.

Les ventes de la famille de type pantalons, sont plus dépendantes de facteurs saisonniers. L'influence des variables explicatives est plus complexe à modéliser. Ainsi, le modèle BMS, essentiellement basé sur la saisonnalité, réalise une prévision performante. Toutefois, les modèles proposés HNCCX et HFCCX réalisent également des performances très comparables. Les modèles HWS et AS-FP semblent traiter difficilement la composante saisonnière des ventes. Pour le modèle HWS, le réglage du coefficient saisonnier doit nécessiter des historiques plus conséquents alors que pour le modèle AS-FP, le logiciel

Forecast Pro considère que la saisonnalité n'est pas suffisamment stable pour assurer son intégration. Les modèles ENARX, ARMAX et DRX-FP sont toujours dépassés par le caractère perturbé des ventes et par le faible nombre de données d'apprentissage.

Enfin, les bonnes performances de nos modèles peuvent partiellement s'expliquer par l'intégration des trois facteurs suivants : la saisonnalité, les variables explicatives et la capacité d'apprentissage sur des historiques courts.

Nous remarquons également que les performances des modèles HFCCX et HNCCX sont relativement proches. La sélection des règles d'inférence par un algorithme génétique permet au modèle HFCCX d'être légèrement plus efficace que ces homologues, mais au détriment d'un temps de calcul plus important (de l'ordre de 12 heures au lieu d'une dizaine de minutes par famille).

#### **4.4.1.2 Modèle AHFCCX**

##### *4.4.1.2.1 Présentation*

L'évaluation du modèle AHFCCX est proposée pour les cinq comparatifs suivants :

- le premier comparatif distingue les différences entre les procédures automatique et semi-automatique des modèles AHFCCX et HFCCX. Ce dernier modèle, nécessitant l'intervention d'un expert, impose l'utilisation d'un jeu de données restreint aux deux familles d'articles précédentes.
- second comparatif s'intéresse à la sélection des règles par un algorithme génétique.
- le troisième comparatif envisage la généralisation des résultats du modèle AHFCCX sur les 322 familles (constituées de 41966 articles). Pour un nombre de familles aussi important, l'intervention d'un expert est très fastidieuse. Nous appliquons également les modèles classiques HWS, ARMAX et ENARX dont l'automatisation des procédures est plus facile. La large gamme de séries testées autorise l'utilisation du critère *MdAPE* (Armstrong, 1992) pour évaluer la précision des prévisions, en complément des deux critères *RMSE* et *EACA* précédemment appliqués.
- le quatrième comparatif étudie l'apport d'une procédure de classification des familles positionnée en amont de la prévision.
- enfin, le cinquième comparatif teste notre modèle AHFCCX pour un apprentissage réparti sur trois années (ou saisons) d'historique.

4.4.1.2.2 Comparatif des modèles HFCCX et AHFCCX

• Résultats

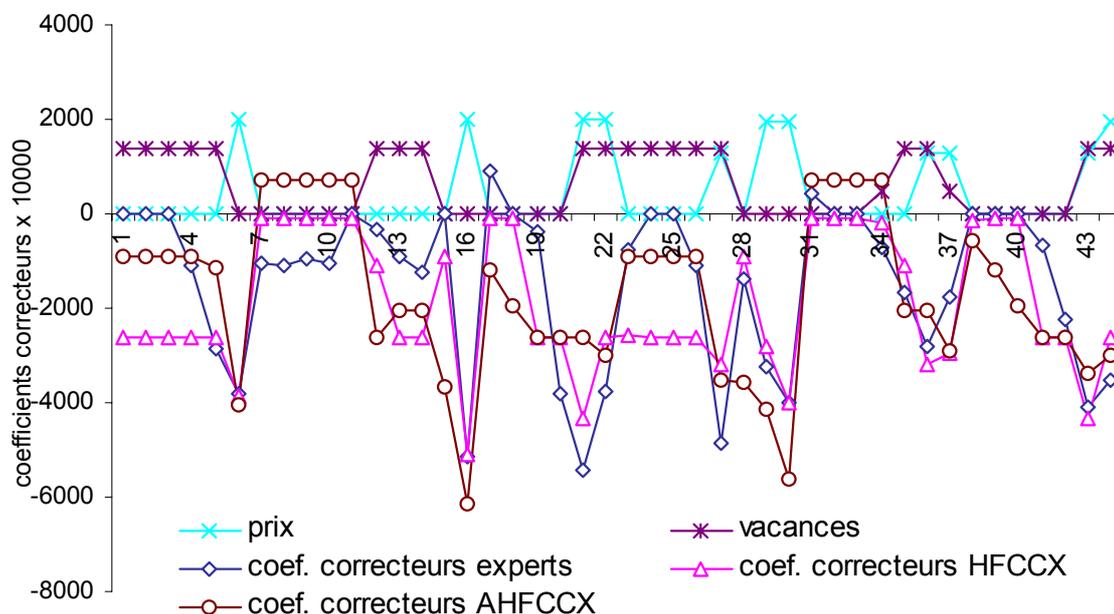


Figure 4.13. Coefficients correcteurs de l'influence des variables explicatives pour la famille de type pulls

La figure 4.13 représente les coefficients correcteurs (CX) de l'influence des variables explicatives élaborés respectivement par l'expert, le modèle HFCCX et le modèle AHFCCX sur les données d'apprentissage appartenant à la famille de type pulls. Elle permet de souligner les différences de capacité d'apprentissage de l'influence des variables explicatives entre les procédures semi-automatique (HFCCX) et automatique (AHFCCX).

La figure 4.14 et le tableau 4.2 mettent en évidence respectivement les résultats des prévisions et des critères de précision, obtenus par les modèles HFCCX et AHFCCX sur les deux familles de type pulls et pantalons.

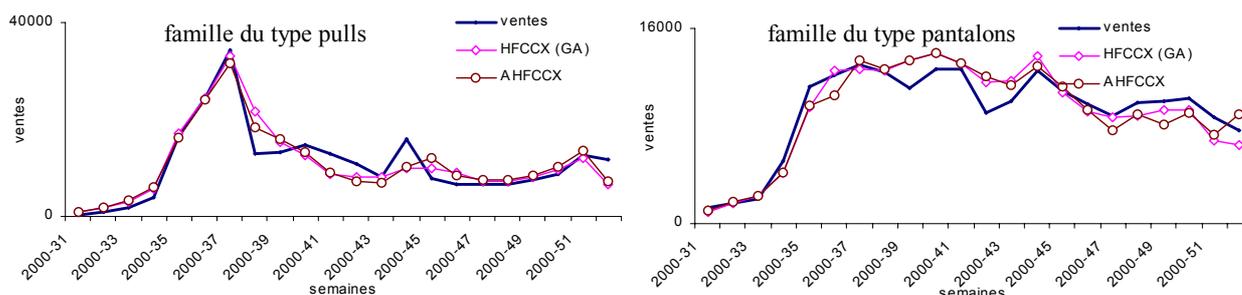


Figure 4.14. Prédiction des modèles HFCCX et AHFCCX sur les ventes des familles de type pulls et pantalons

famille de type pulls				famille de type pantalons			
modèle	HFCCX (GA)	AHFCCX	amélioration en % apportée par le modèle AHFCCX	modèle	HFCCX (GA)	AHFCCX	amélioration en % apportée par le modèle AHFCCX
RMSE	2934	2723	7,2	RMSE	1151	1186	-3,1
EACA	244777	259202	-5,9	EACA	174995	201097	-14,9

Tableau 4.2. Critères RMSE et EACA des modèles HFCCX et AHFCCX

- Analyse

Ce comparatif permet de démontrer que l'apprentissage automatique de l'influence des variables explicatives est possible dans un tel contexte. En effet, nous constatons que les coefficients correcteurs  $CX$  calculés par les modèles AHFCCX et HFCCX sont proches (figure 4.12). Le modèle AHFCCX est même parfois plus fidèle aux corrections de l'expert que son homologue semi-automatique pour les semaines 1-4, 17-18, 23-26. Cette capacité d'apprentissage du modèle AHFCCX se traduit par des prévisions relativement similaires au modèle HFCCX (figure 4.14). La précision, exprimée pour le critère  $RMSE$ , est également relativement bonne pour le modèle AHFCCX comparée à la procédure semi-automatique (tableau 4.2). Seul, le critère  $EACA$  pour la famille du type pantalons, paraît moins intéressant, ce qui peut s'expliquer principalement par l'erreur de prévision du modèle AHFCCX sur la dernière semaine (période de Noël) (figure 4.14) où le prix est le plus élevé.

#### 4.4.1.2.3 Analyse de la sélection des règles d'inférence du modèle AHFCCX

- Résultats

Les figures 4.15 à 4.19 se rapportent des essais réalisés sur des familles de type pulls. La figure 4.15 représente les règles d'inférence du modèle AHFCCX sélectionnées par AG et les fonctions d'appartenance de sortie correspondantes. La figure 4.16 montre la dispersion (quartiles inférieur et supérieur et erreur médiane) des résultats en fonction de la population initiale choisie aléatoirement ou fixée. La figure 4.17 illustre le temps de calcul de l'AG en fonction du nombre de générations. La figure 4.18 souligne l'évolution de la

fonction d'évaluation  $J$  à minimiser par l'AG sur les données d'apprentissage. Enfin, la figure 4.19 met en évidence le critère  $RMSE$  de la prévision sur les données de simulation en fonction du nombre de générations et le tableau 4.3 résume les performances obtenues par le modèle avec et sans AG.

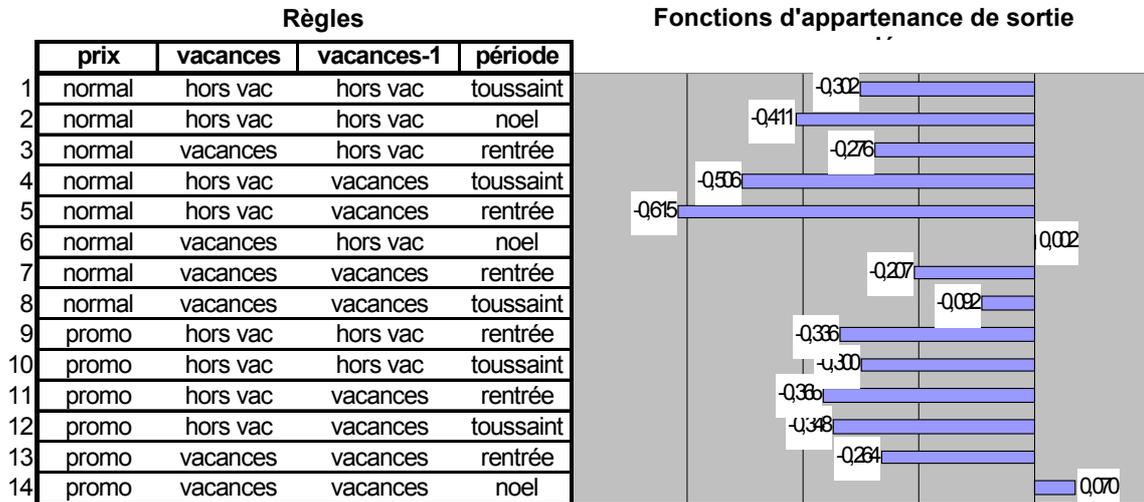


Figure 4.15. Règles d'inférence du modèle AHFCCX sélectionnées par un AG

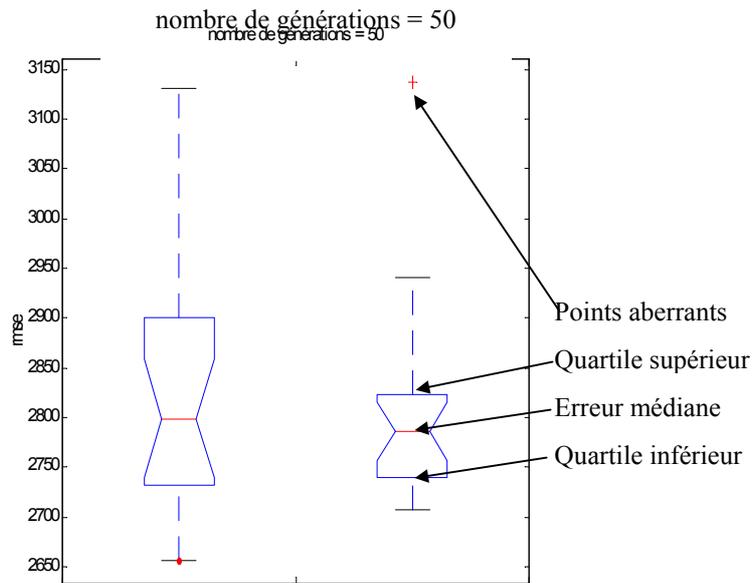


Figure 4.16. Evaluation de la prévision pour deux types différents de population initiale

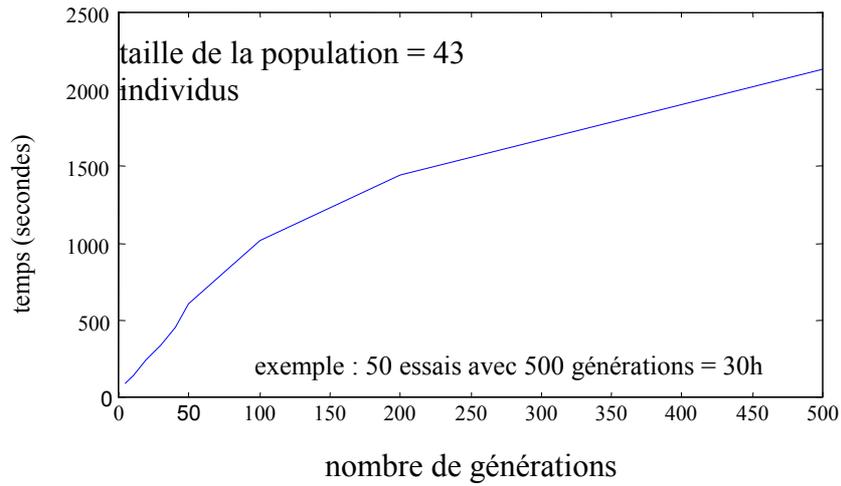


Figure 4.17. Temps de calcul, fonction du nombre de générations

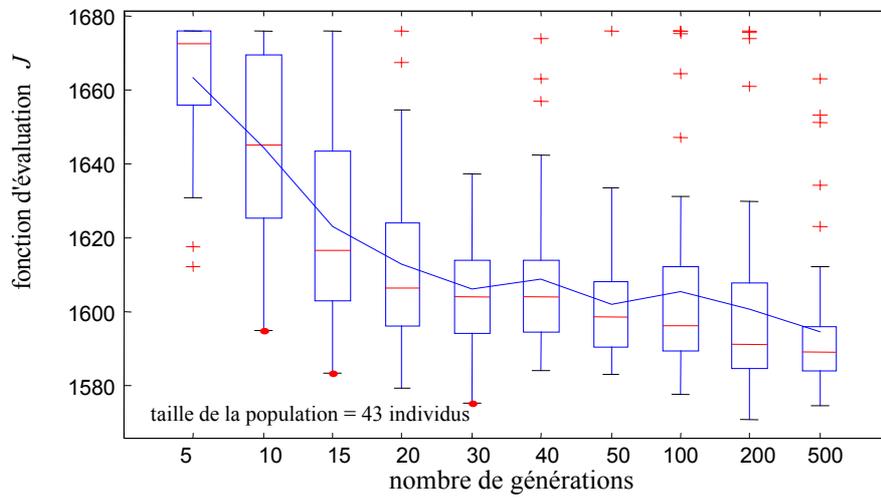


Figure 4.18. Correspondance entre la fonction d'évaluation  $J$  et le nombre de générations

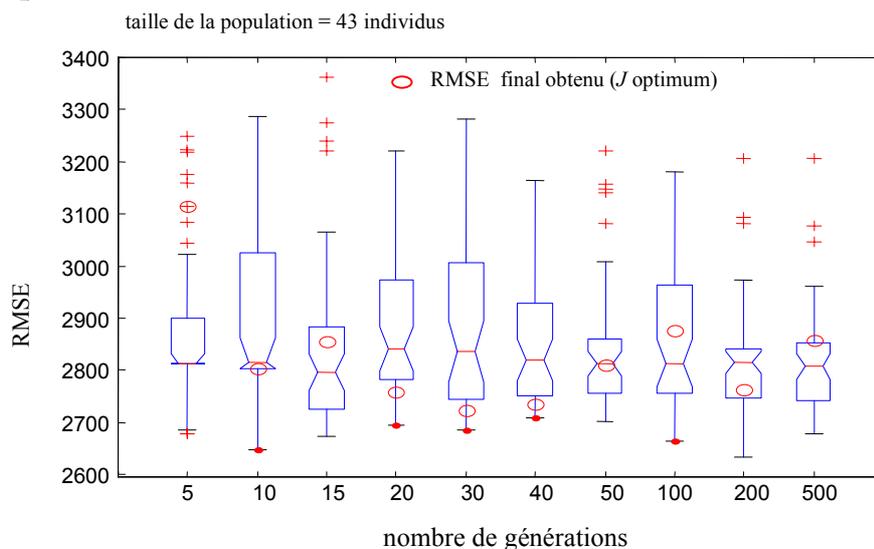


Figure 4.19. Critère RMSE sur les données de simulation en fonction du nombre de générations

	famille a		famille b	
	AG*	sans AG**	AG*	sans AG**
fonction d'évaluation J sur les saisons historiques	1575	1719	854	977
RMSE sur la saison future	2723	2873	1186	1037
nombre de règles d'inférence du SIF	14	24	5	24
temps de calcul	4 à 5h	< 1 minute	4 à 5h	< 1 minute

\* apprentissage avec sélection des règles d'inférence par AG et optimisation des fonctions d'appartenance de sortie

\*\* apprentissage avec optimisation des fonctions d'appartenance de sortie sans sélection des règles d'inférence

Tableau 4.3. Résultats du modèle AHFCCX avec et sans sélection des règles d'inférence par un AG

- Analyse

L'un des avantages des SIF est la possibilité d'interpréter leur structure. Ainsi, nous pouvons constater partiellement, à travers les règles d'inférence et les fonctions d'appartenance (constantes) de sortie du modèle AHFCCX, le raisonnement des experts prévisionnistes (figure 4.15). Par exemple, on remarque pour la semaine suivant la rentrée scolaire (règle 5), pour une promotion en période de Toussaint en dehors des vacances (règles 10, 12) ou en approche de Noël (règle 2), que les ventes augmentent fortement (le système corrige alors l'historique par un coefficient négatif important). Les règles qui perturbent et/ou ne sont pas considérées par le système sont éliminées lors de la sélection par l'algorithme génétique

Cependant, le temps de calcul (figure 4.17), généré par l'algorithme génétique (AG) qui sélectionne les règles d'inférence, pénalise son application sur de nombreuses séries. Ce temps relativement important est expliqué par le nombre imposant de générations et par le tirage aléatoire de la population initiale. La solution obtenue est en effet fortement

dépendante de la population initiale. Pour une interprétation correcte des résultats, il est nécessaire d'exécuter de nombreux essais (de l'ordre de 200). Ainsi, nous proposons de fixer cette population initiale pour réduire la dispersion des résultats (figure 4.16). Néanmoins, cette procédure nécessite une certaine expérience de l'utilisateur afin de construire une population couvrant la totalité de l'espace des solutions.

Le nombre de générations de l'AG est également très coûteux en temps de calcul. On constate que la valeur de la fonction d'évaluation  $J$ , déterminée à partir des données d'apprentissage, diminue avec le nombre de générations (figure 4.18). Cependant, une trentaine de générations semble suffisantes pour atteindre un résultat optimum sur les données de simulation (figure 4.19).

Enfin, si la sélection des règles d'inférence par un algorithme génétique améliore la précision des prévisions, le temps de calcul sur les 322 familles et les réglages des divers paramètres (probabilité de crossover et de mutation, taille et initialisation de la population, ...), restent des contraintes importantes. Ainsi, notre choix s'oriente sur la procédure d'optimisation des fonctions d'appartenance de sortie sans sélection des règles, qui assurent des résultats relativement corrects (tableau 4.3), pour appliquer le modèle AHFCCX sur la totalité des familles disponibles.

#### 4.4.1.2.4 Etude du modèle AHFCCX sur 322 familles

- Résultats

Les figures 4.20 et 4.21 permettent de caractériser les améliorations des critères  $RMSE$  et  $EACA$  apportées par le modèle AHFCCX en comparaison des modèles HWS, AS et ARMAX sur les 322 familles testées. La figure 4.22 présente le critère  $MdAPE$  et la dispersion du critère  $APE$  sur les 322 familles pour les quatre modèles expérimentés.

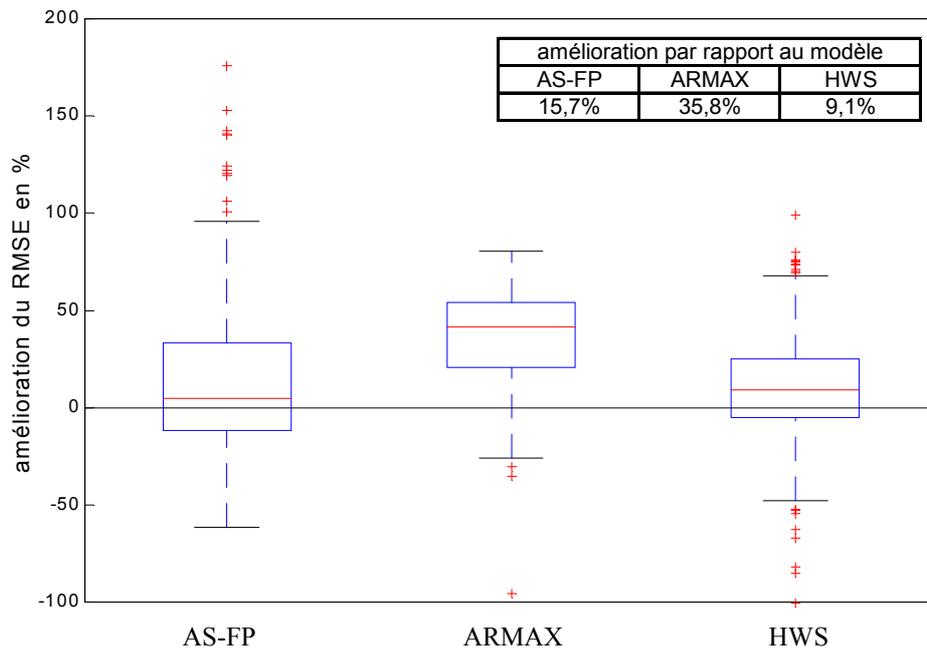


Figure 4.20. Amélioration en % du critère RMSE apportée par le modèle AHFCCX sur 322 familles

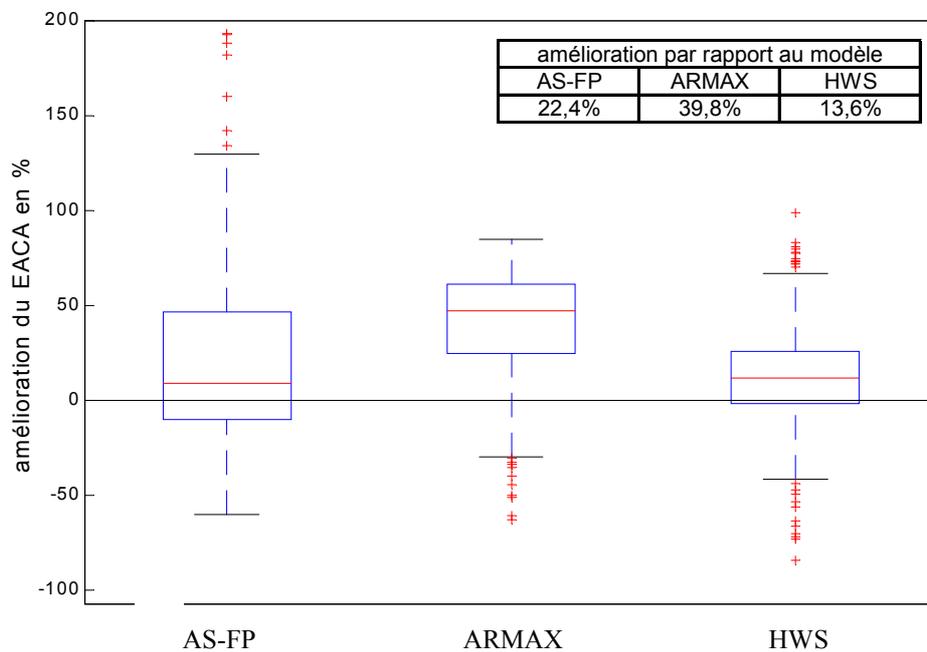


Figure 4.21. Amélioration en % du critère EACA apportée par le modèle AHFCCX sur 322 familles

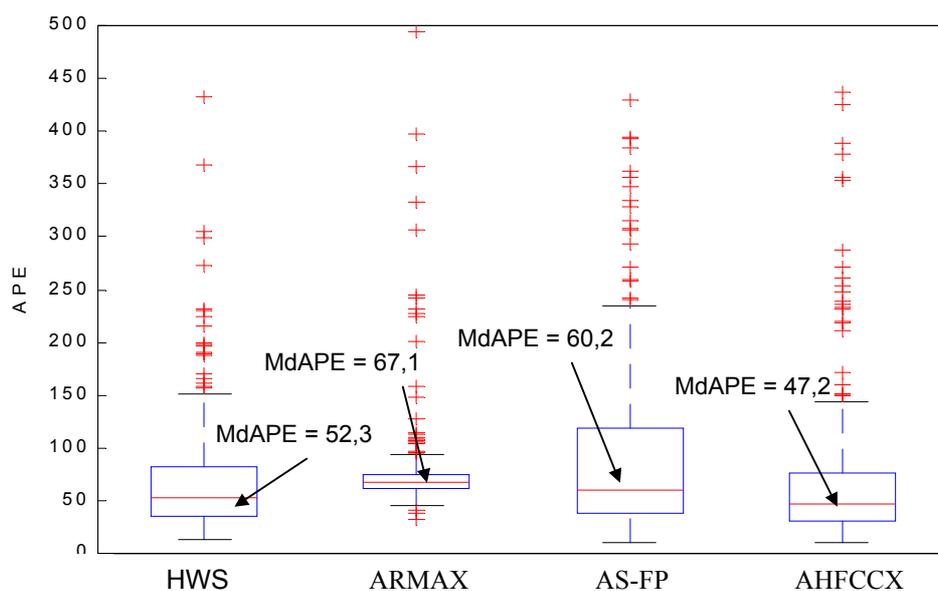


Figure 4.22. Critères MdAPE et APE des modèles sur 322 familles

Les figures 4.23 et 4.24 représentent respectivement les prévisions de ventes des familles d'articles de type sweat femme et lingerie.

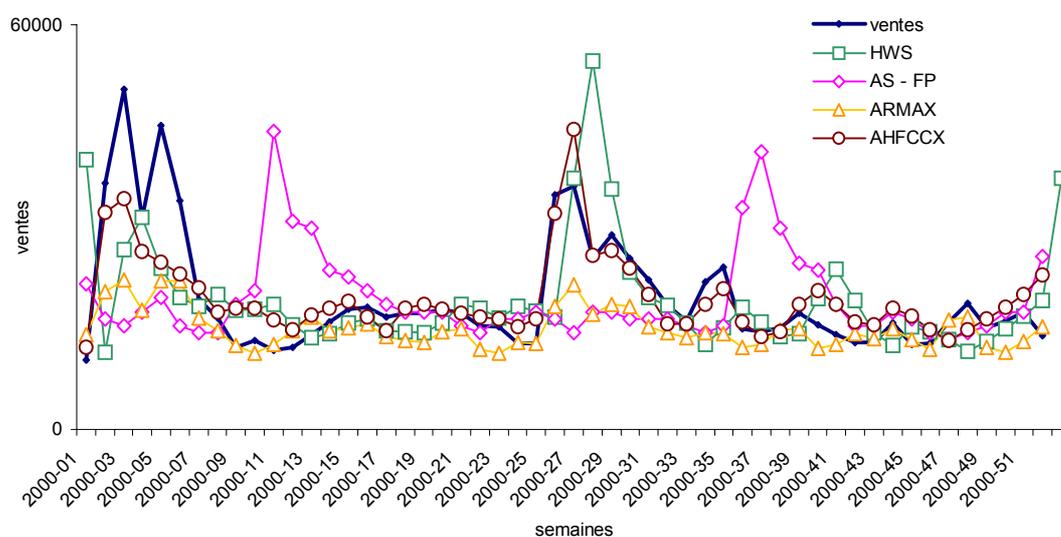


Figure 4.23. Prédiction des modèles sur une famille d'articles de type sweat femme

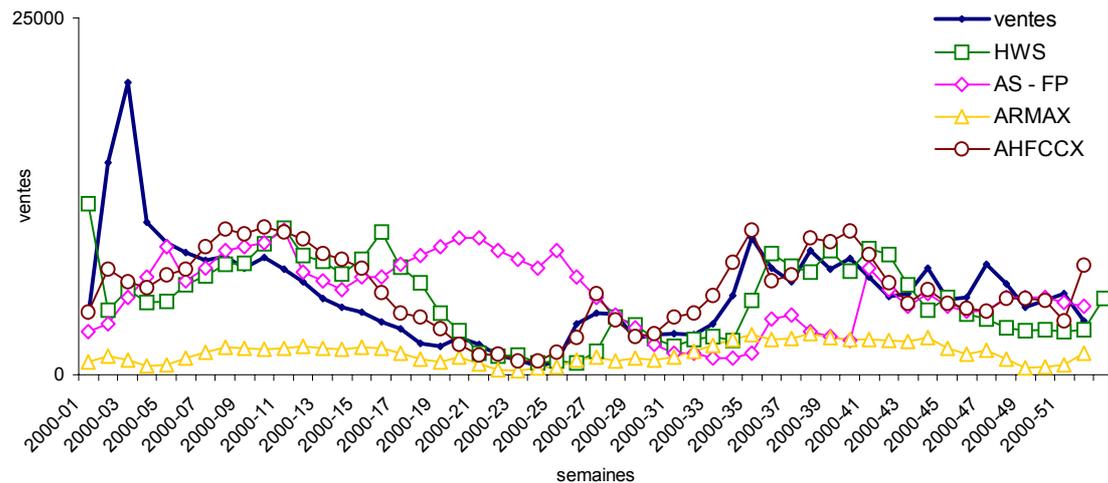


Figure 4.24. Prédiction des modèles sur une famille d'articles de type lingerie

- Analyse

Le modèle AHFCCX est globalement plus précis pour les critères *RMSE* et *EACA* que ses concurrents. Pour la majorité des cas testés (figures 4.20 et 4.21), les critères *RMSE* et *EACA* sont améliorés. Le critère *MdAPE*, qui résume les performances globales sur les 322 familles, est également plus favorable au modèle AHFCCX (figure 4.22).

Pour des problèmes d'instabilité, le logiciel Forecast Pro n'intègre pas la saisonnalité des ventes historiques. Le choix automatique des modèles de ce logiciel et le réglage des paramètres correspondants sont également fortement perturbés par le nombre réduit de données d'apprentissage. Ainsi, le modèle AS-FP sélectionné génère des résultats très controversés.

De part sa structure non-linéaire, le modèle ARMAX ne parvient généralement pas à prendre en compte les relations entre les ventes et les variables explicatives sur des historiques courts. Ainsi, les prévisions obtenues n'anticipent pas les fluctuations des ventes (figures 4.23 et 4.24).

La prise en compte de la saisonnalité des ventes dans la structure simple du modèle HWS, lui permet de réaliser les meilleures performances des modèles classiques. Cependant, en n'intégrant pas les variables explicatives, il ne devance pas les variations des ventes contrairement au modèle AHFCCX (figures 4.23 et 4.24).

#### 4.4.1.2.5 Apport de la classification

Afin d'augmenter le nombre de données historiques, une procédure de classification des familles selon le critère profil de vente est proposée en amont du modèle AHFCCX.

Le nombre optimal de classes, obtenu par le critère de Xie (section 3.2.1.3.2) pour une classification ascendante hiérarchique (section 2.4.2), est de 8. Ainsi, l'apprentissage du modèle AHFCCX n'est plus effectué sur les 104 semaines historiques de chacune des 322 familles, mais sur la totalité des familles appartenant à chacune des 8 classes. La taille de la base d'apprentissage devient alors plus conséquente (tableau 4.4).

classes	nombre de familles	taille de la base d'apprentissage (semaines)
1	27	27 x 104 = 2808
2	20	20 x 104 = 2080
3	20	20 x 104 = 2080
4	40	40 x 104 = 4160
5	43	43 x 104 = 4472
6	97	97 x 104 = 10088
7	42	42 x 104 = 4368
8	33	33x 104 = 3432

Tableau 4.4. Nombre de familles et taille de la base d'apprentissage par classe

critère	% d'amélioration moyenne du modèle AHFCCX avec classification
RMSE	5,1%
EACA	3,1%
MdAPE	9,4%

Tableau 4.5. Amélioration des critères de précision par la classification

L'analyse du tableau 4.5 fait apparaître, quelque soient les critères de précision, une amélioration significative de la prévision calculée par le modèle AHFCCX avec classification. Cette procédure de classification et le critère retenu (profil de vente) permettent un meilleur apprentissage de l'influence des variables explicatives.

#### 4.4.1.2.6 Apprentissage sur trois années d'historique

Dans ce comparatif, nous disposons de quatre années (ou saisons) d'historique de ventes (1998 à 2001) : deux années pour l'apprentissage du modèle (1998 et 1999), une année pour la validation (2000) et la dernière année pour la simulation (2001) (section 4.2.1.1, figure 4.3). Un tel processus est avantageux afin d'éviter d'apprendre exactement les données historiques. Cependant, compte tenu du changement de codification (pratiqué par le distributeur durant l'année 2001), les tests comprenant 4 années d'historique se sont restreints à 9 familles possibles ; celles-ci permettent de quantifier les performances du modèle AHFCCX avec un apprentissage respectivement de deux (1999 et 2000) et trois années (1998 à 2000) d'historique. L'amélioration de la précision obtenue pour les critères RMSE et EACA est relativement faible (tableau 4.6).

critère	% d'amélioration moyenne apportée pour un apprentissage sur 3 années
RMSE	1,4%
EACA	0,2%

Tableau 4.6. Amélioration sur 9 familles testées pour un apprentissage sur 3 années d'historique

#### 4.4.1.3 Conclusion de la prévision moyen terme à la famille

Nous avons expérimenté dans cette section trois modèles, nommés respectivement HNCCX, HFCCX et AHFCCX et se déclinant en différentes versions selon la méthode d'apprentissage employée.

Le premier comparatif met en valeur les performances des modèles HNCCX et HFCCX sur les ventes de deux familles d'articles basiques. Ces deux modèles, qui utilisent respectivement des techniques neuronales et floues, nécessitent l'intervention d'un expert pour la procédure d'apprentissage. De façon générale, les performances obtenues, selon les critères *RMSE* et *EACA*, sont meilleures que celles des modèles classiques testés. En effet, nos modèles permettent d'intégrer les caractéristiques saisonnières des ventes et également de modéliser l'influence des variables explicatives considérées sur des historiques courts.

Le second comparatif appréhende le modèle AHFCCX, version automatique du modèle HFCCX. L'automatisation de l'apprentissage autorise une expérimentation du modèle sur un nombre important de séries, tout en conservant une précision proche de la procédure avec expert. Ainsi, le modèle AHFCCX, testé sur les 322 familles d'articles, permet une amélioration significative des critères de précision *RMSE*, *EACA* et *MdAPE* par rapport aux modèles classiques (section 4.4.1.2.4).

La sélection par un AG des règles d'inférence du SIF constituant la base du modèle AHFCCX, s'avère très coûteuse en temps de calcul, contraignante pour le réglage des paramètres et finalement peu efficace. Aussi, cette procédure est abandonnée pour la suite des travaux sur toutes les séries de données testées.

Une classification des familles selon le critère profil de ventes, positionnée en amont du modèle de prévision, permet d'augmenter efficacement la précision des résultats. En effet, l'élaboration de classes augmente la taille de la base de données historiques et améliore ainsi la procédure d'apprentissage.

Enfin, lorsqu'une troisième année de données historiques est disponible, il est envisageable d'effectuer l'apprentissage du modèle AHFCCX par validation. Les résultats

obtenus méritent une expérimentation sur un nombre plus important de familles, lors d'une prochaine collection.

## 4.4.2 Prévision court terme à la famille

### 4.4.2.1 Présentation

L'expérimentation des nouveaux modèles nommés respectivement SAMANN et SAMANFIS, décrits en section 3.2.2, est réalisée sur le jeu de données composé des 322 familles. Ces modèles sont basés sur le réajustement de la prévision à moyen terme, qui est calculée par le modèle AHFCCX (section 4.4.1.2).

Nos deux modèles sont comparés aux modèles classiques ARMAX et HWS. La composante variable explicative du modèle ARMAX permet d'intégrer, similairement aux modèles SAMANN et SAMANFIS, les prévisions à moyen terme.

Pour tous les modèles testés, l'horizon de prévision à court terme est de une semaine. L'évaluation des performances des modèles, portant sur les critères *RMSE*, *EACA* et *MdAPE*, est assurée sur toutes les semaines  $t$  ( $t \in [1, p]$ ) de la dernière année (ou saison), disponibles dans notre base de données. Ainsi, l'apprentissage est effectué sur les deux premières années historiques et les  $t$  premières semaines de l'année (ou saison) en cours.

### 4.4.2.2 Résultats

Les figures 4.25 et 4.26 représentent respectivement les prévisions à court terme des modèles testés et les prévisions à moyen terme du modèle AHFCCX sur deux familles d'articles de type T-shirt manches courtes et manches longues pour femme.

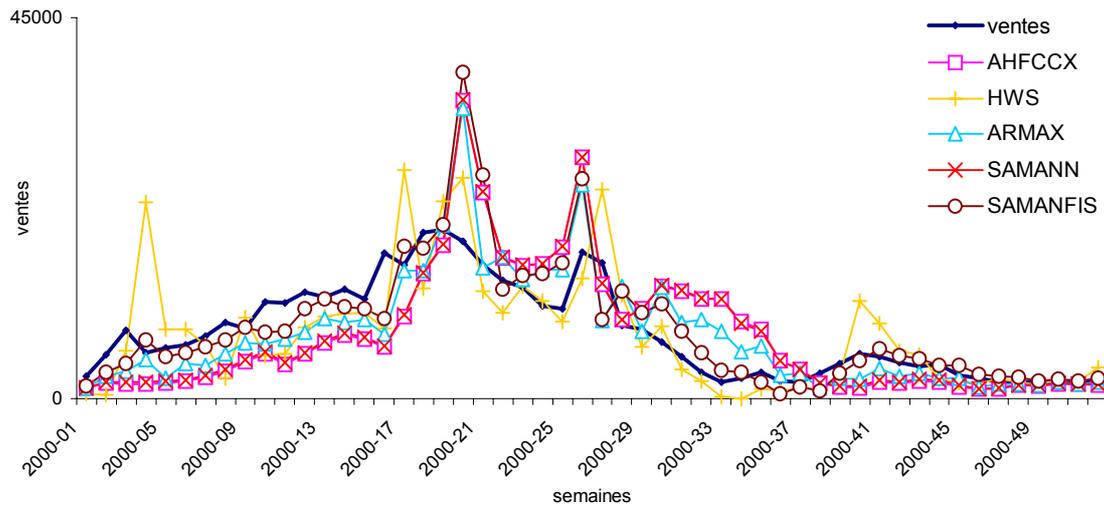


Figure 4.25. Prédiction des modèles sur les ventes d'une famille de type T-shirt manches courtes pour femme

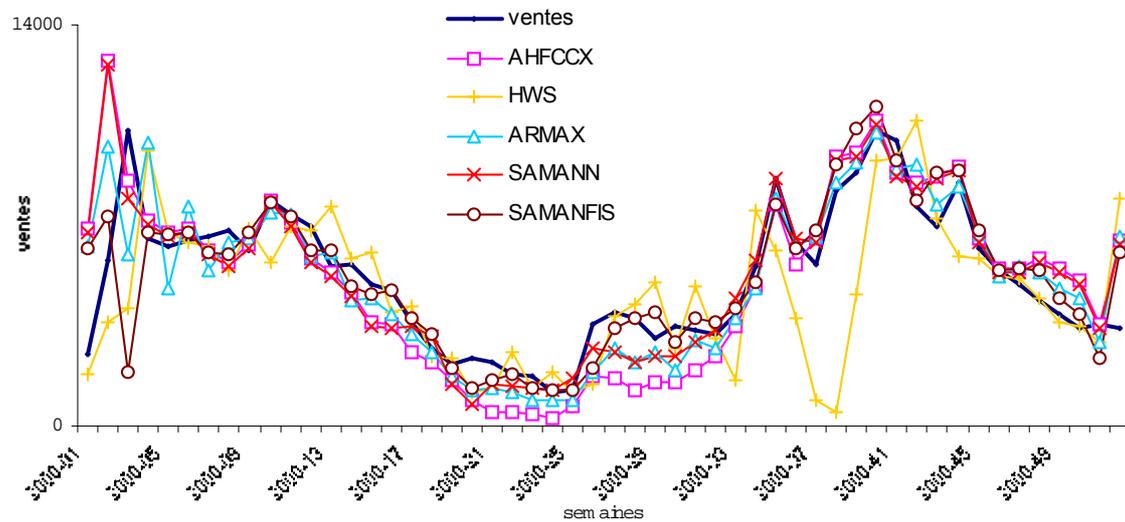


Figure 4.26. Prédiction des modèles sur les ventes d'une famille de type T-shirt manches longues pour femme

Les figures 4.27 et 4.28 expliquent l'amélioration générale des critères  $RMSE$  et  $EACA$  sur les 322 familles pour les modèles proposés à court terme, comparée au modèle de prévision à moyen terme AHFCCX.

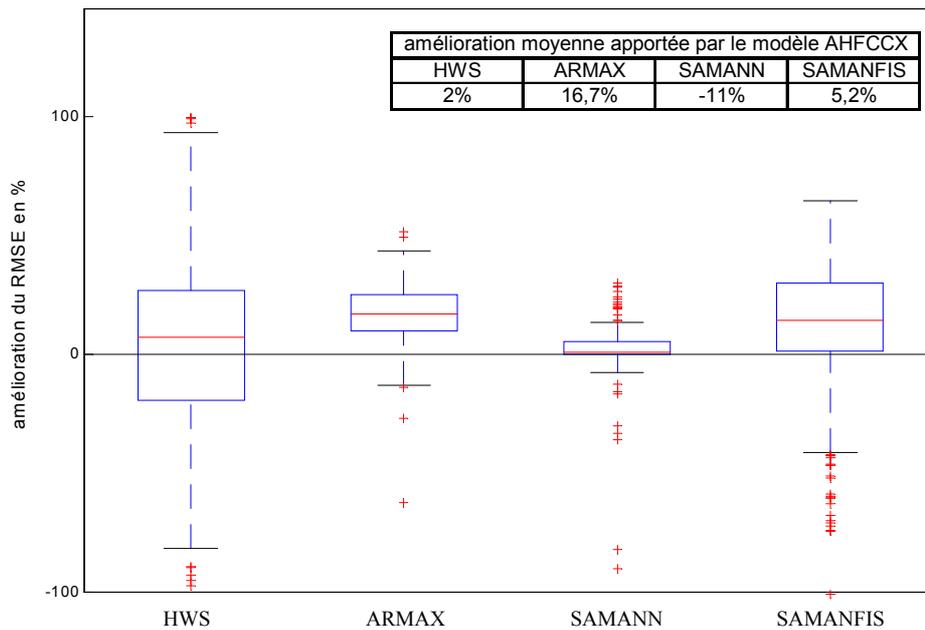


Figure 4.27. Amélioration du critère RMSE apportée par les modèles HWS, ARMAX, SAMANN et SAMANFIS par rapport au modèle moyen terme AHFCCX

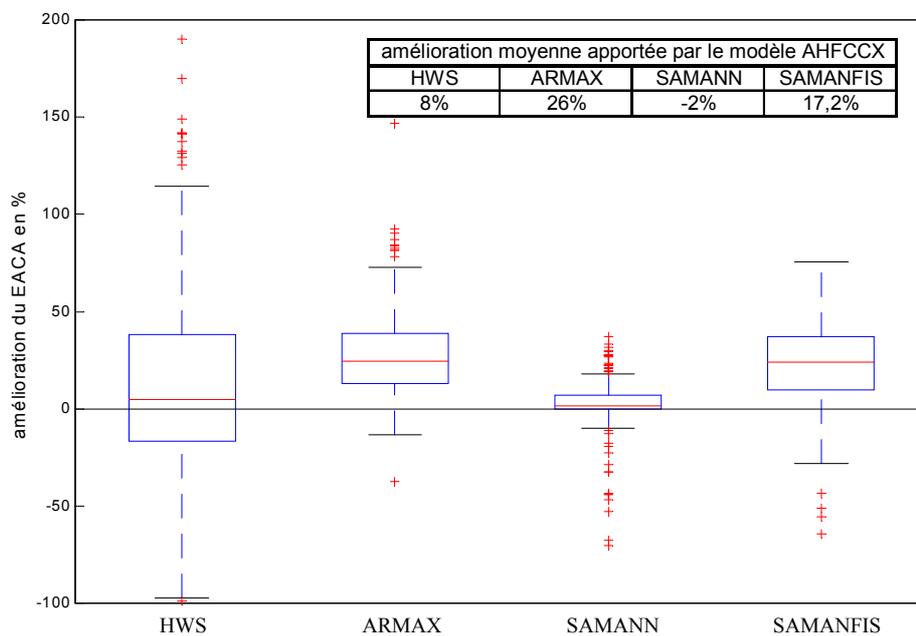


Figure 4.28. Amélioration du critère EACA apportée par les modèles HWS, ARMAX, SAMANN et SAMANFIS par rapport au modèle moyen terme AHFCCX

Enfin, la figure 4.29 montre, pour le modèle AHFCCX et les modèles de prévision à court terme, la dispersion des critères *APE* et *MdAPE* sur les 322 familles testées.

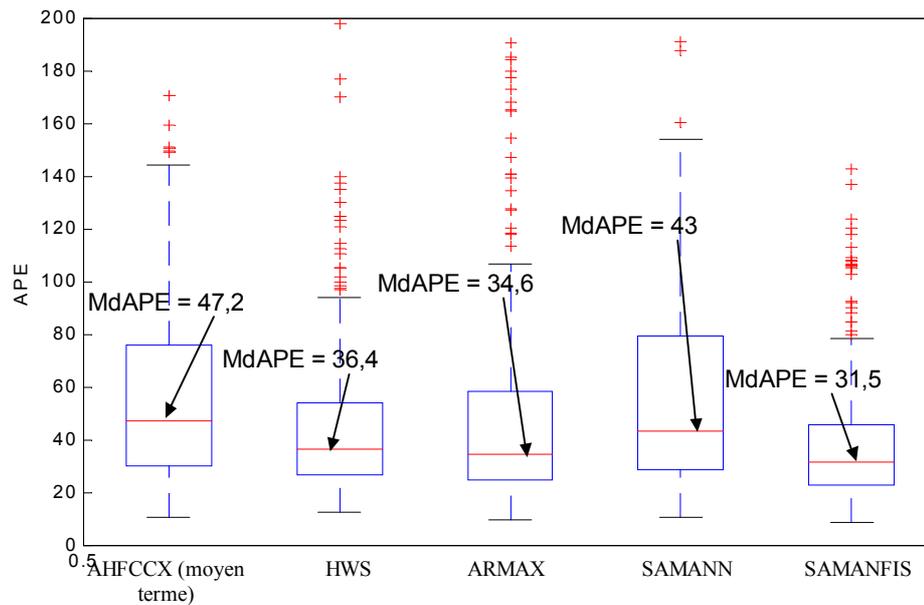


Figure 4.29. Evaluation des critères APE et MdAPE sur les 322 familles

#### 4.4.2.3 Analyse

Les prévisions des ventes à court terme des différents modèles expérimentés présentent des résultats très variés :

- le modèle HWS, qui ne tient pas compte des résultats du modèle AHFCCX, réalise des prévisions très fluctuantes et anticipe parfois mal les variations des ventes (figures 4.25 et 4.26).
- le modèle SAMANN obtient des résultats très semblables au modèle moyen terme AHFCCX et ne parvient pas à réajuster les prévisions en fonction des dernières ventes. Le manque de données ne permet pas de justifier une structure de réseau de neurones suffisamment importante pour apprendre et modéliser les caractéristiques des ventes et des erreurs des prévisions à moyen terme.
- les modèles ARMAX et SAMANFIS assurent une réduction de l'erreur des prévisions à moyen terme en intégrant mieux les dernières ventes et les prévisions passées et futures du modèle AHFCCX.

L'analyse des critères de précision *RMSE*, *EACA* et *MdAPE* confirme globalement la supériorité des modèles ARMAX et SAMANFIS et les difficultés du modèle SAMANN. En effet, ce dernier détériore même en moyenne le critère *RMSE* par rapport au prévision du modèle AHFCCX. Les résultats du modèle HWS sont honorables et supérieurs au modèle SAMANN.

La structure linéaire du modèle ARMAX permet d'obtenir des performances meilleures pour les critères *RMSE* et *EACA* et proches du modèle neuro-flou SAMANFIS pour le critère *MdAPE*. Cependant, on remarque pour certaines familles, que le réajustement de la prévision à moyen terme par les modèles ARMAX et SAMANFIS est détérioré (figures 4.27 et 4.28 : points inférieurs à zéro). Enfin, les résultats des modèles HWS et SAMANN restent globalement plus faibles.

#### 4.4.2.4 Conclusion de la prévision court terme à la famille

Dans cette section, nous avons développé deux modèles de prévisions des ventes à court terme, nommés SAMANN et SAMANFIS, basés respectivement sur des techniques neuronale et neuro-floue.

Le modèle SAMANN, qui s'appuie sur un réseau de neurones dont l'efficacité est prouvée dans certains contextes de prévision (section 2.3.4.1.1), n'améliore pas les résultats obtenus à moyen terme par le modèle AHFCCX. Le nombre de données d'apprentissage restreint ne permet pas l'élaboration et le réglage d'une structure suffisante pour modéliser les relations entre les dernières ventes et les prévisions à moyen terme.

Le modèle SAMANFIS, assure une amélioration de la précision en comparaison au modèle AHFCCX. La prise en compte des prévisions à moyen terme lui permet d'anticiper les fluctuations des ventes et apparaît ainsi plus performant que le modèle HWS. Enfin, le modèle ARMAX, qui traite également les prévisions à moyen terme, obtient des résultats comparables à notre modèle SAMANFIS.

L'ensemble de ces résultats doit toutefois être généralisé pour des prévisions portant sur un horizon à court terme de 2 à 3 semaines.

#### 4.4.3 Conclusion de la prévision à la famille

Nous avons expérimenté cinq nouveaux modèles de prévision de ventes à moyen et court terme par famille d'articles. Afin de quantifier leur performances sur des données réelles, nous les avons comparés aux modèles de prévisions classiques, à travers l'évaluation des critères *RMSE*, *EACA* et *MdAPE*.

Les modèles de prévision à moyen terme HNCCX et HFCCX au niveau famille, et plus particulièrement le modèle HFCCX (GA) avec un apprentissage par algorithme génétique, obtiennent de bons résultats sur les ventes des 2 familles basiques testées. Ils permettent d'intégrer, de façon semi-automatique le comportement saisonnier des ventes et l'influence

des variables explicatives. Cependant, sur un nombre plus important de familles, ils sont fortement pénalisés lors de l'apprentissage avec intervention de l'expert.

Le modèle AHFCCX, une variante automatique du modèle HFCCX, autorise une expérimentation sur de nombreuses familles d'articles. Par l'apprentissage automatique de l'influence des variables explicatives, il assure une précision des prévisions relativement proches de son homologue semi-automatique. Afin de réduire le temps de calcul et de faciliter l'utilisation répétée du système, la sélection des règles d'inférence par un algorithme génétique peut être supprimée sans nuire trop fortement aux performances. Il peut être envisageable d'exploiter, pour sélectionner les règles d'inférence, une autre méthode du type Abe ou algorithme décremental de Fiordaliso.

L'amélioration des résultats passe également par une procédure de classification des familles placée en amont des modèles de prévision. Basée sur le regroupement des familles selon le critère profil de vente, cette procédure permet au modèle de mieux modéliser l'influence des variables explicatives en augmentant la taille de la base d'apprentissage.

La connaissance d'une troisième année (ou saison) de données historiques autorise l'exploitation d'un apprentissage par validation. Cette stratégie doit assurer une meilleure généralisation du modèle sur les données futures. Cependant, compte tenu du faible nombre de familles disponibles, les résultats controversés obtenus méritent d'être approfondis sur de nouvelles séries.

Le modèle de prévision SAMANN ne donne pas les résultats escomptés. Ses prévisions sont même, selon le critère *RMSE*, moins précises que les prévisions réalisées à moyen terme par le modèle AHFCCX. La structure de type réseau de neurones, limité par le faible nombre de données d'apprentissage, ne permet pas de modéliser les relations entre les dernières ventes et les prévisions à moyen terme.

Le modèle SAMANFIS assure une amélioration globale significative de la précision des prévisions du modèle AHFCCX. Il réajuste correctement les prévisions en fonction des dernières ventes. On remarque également que le modèle classique ARMAX peut se justifier pour un tel contexte.

Enfin, le modèle HWS, exploité pour des prévisions à court terme, n'intègre pas les prévisions élaborées à moyen terme. Ses performances plus faibles que celles des modèles ARMAX et SAMANFIS montrent l'intérêt d'appliquer les prévisions à moyen terme pour calculer les prévisions à court terme.

## 4.5 Prévision à l'article

### 4.5.1 Prévision moyen terme à l'article

#### 4.5.1.1 Présentation

Cette section se propose d'expérimenter nos modèles de prévision à moyen terme au niveau article, nommés IDA et IDAC (section 3.3.1), qui s'appuient sur la répartition des prévisions au niveau famille et sur l'estimation du profil de vente de chaque article. Les profils de vente des articles futurs sont calculés à partir des profils moyens des articles historiques de la même famille (modèle IDA) ou à partir des centres de classes issus d'une procédure de classification (modèle IDAC).

Pour notre application, la procédure de classification mise en œuvre par le modèle IDAC est du type ascendante hiérarchique multicritères ; elle ne considère, en fonction des données disponibles dans la base de notre partenaire, que les seuls critères prix / nombre de magasins distribuant le produit. Compte tenu du temps important d'extraction des données dans la base (1 minute 30 secondes par article) et du volume de stockage nécessaire pour chaque test, les autres méthodes de classification envisagées (section 3.3.1.2.2), n'ayant pas apporté de résultats significatifs sur un échantillon d'articles (Dornier, 2002), ne sont pas exploitées. L'expérimentation porte sur les 4070 articles constituant 20 familles choisies selon leur importance en terme de chiffres d'affaires.

Les historiques des articles vendus pendant les deux premières années servent à l'élaboration des courbes de vie moyenne (modèle IDA) et des classes (modèle IDAC). Les critères de précision *RMSE*, *EACA* et *MdAPE* sont évalués, la troisième année, lors de la simulation de la prévision.

Le caractère très particulier de la prévision des ventes d'articles (renouvellement continu et nombre important de références, durée de vie très courte et inexistence d'historique pour chaque article) rend également difficile l'application de la plupart des modèles de prévision classiques. Nous ne sélectionnons, comme modèle classique de référence, que le modèle de répartition basique (RB), qui permet d'une façon simple de calculer la prévision des nouveaux articles sans historique (section 4.3).

Ainsi, nous envisageons de tester :

- la technique originale de répartition des prévisions par famille sur les articles correspondants (comparaison des modèles IDA et RB),

- l'apport de la procédure de classification, avec sélection des classes par notre critère spécifique CBF (section 3.3.1.2.2), pour la conception des profils de vente des nouveaux articles (comparaison des modèles IDA et IDAC).

#### 4.5.1.2 Résultats

La figure 4.30, qui concerne le traitement des articles d'une famille de type T-shirt manches courtes femmes par le modèle IDAC, permet de visualiser les classes d'articles obtenues par la procédure de classification du type multicritères prix / nombre de magasins distribuant l'article.

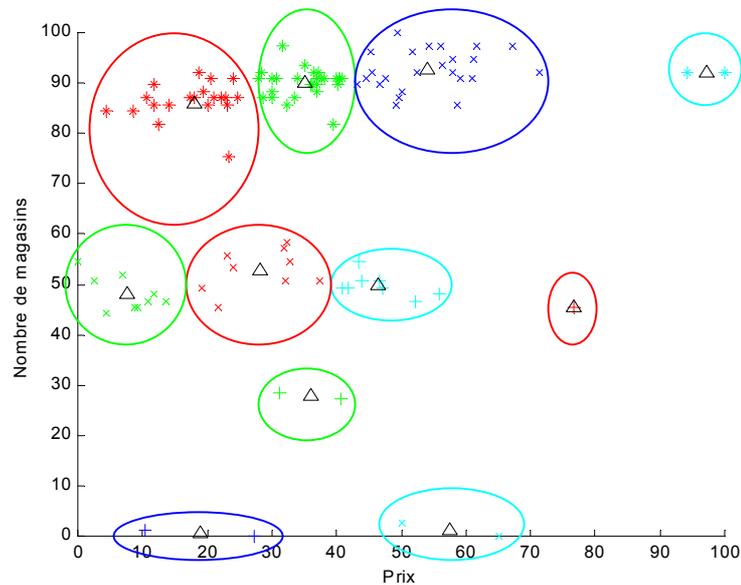


Figure 4.30. Résultats d'une classification multicritères appliquée sur une famille du type T-shirt manches courtes pour femme

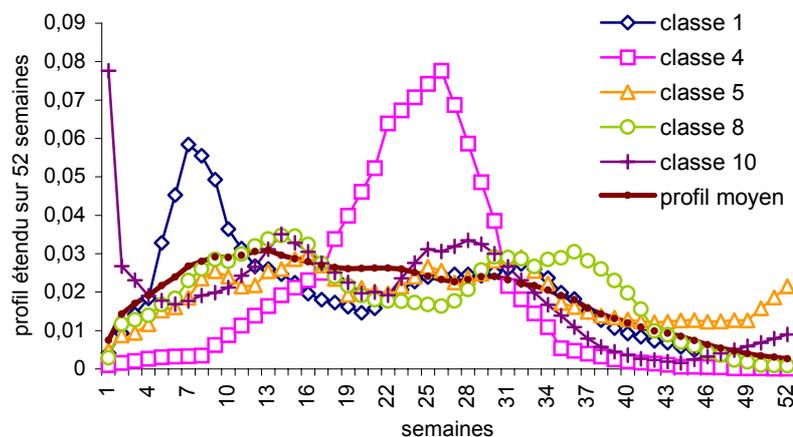


Figure 4.31. Exemple de profils de ventes de centre de classe et profil moyen des articles d'une famille du type T-shirt manches courtes pour femme

La figure 4.31 représente un exemple de profils de vente de cinq centres de classes (parmi les onze obtenues en figure 4.30) construites par le modèle IDAC et le profil de vente moyen des articles, élaboré par le modèle IDA pour une famille de type T-shirt manches courtes pour femme. Les courbes de prévision calculées respectivement à partir des profils des centres de classes (modèle IDAC) et du profil moyen (modèle IDA) sont visualisées pour quatre articles (*a*, *b*, *c* et *d*) de la famille de type T-shirt manches courtes femme (figure 4.32).

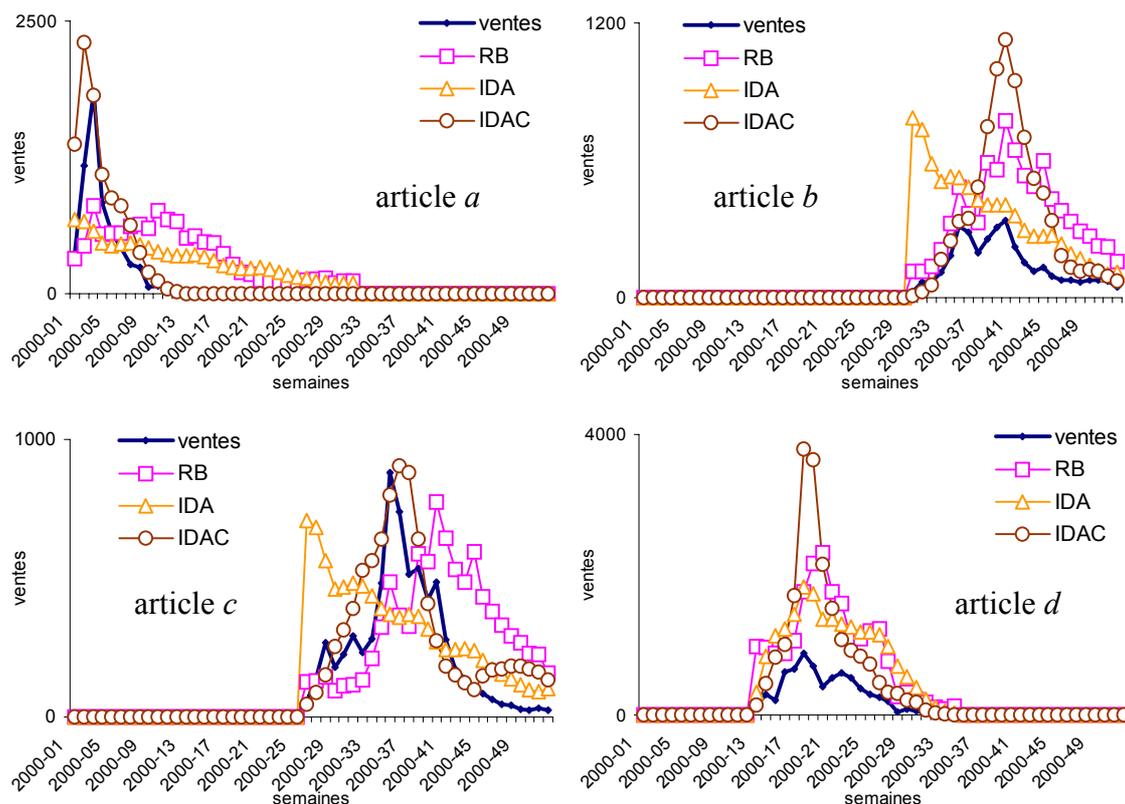


Figure 4.32. Comparaison des trois modèles pour quatre articles d'une famille du type T-shirt manches courtes femme

Le tableau 4.7 souligne les performances de nos modèles selon les critères *RMSE*, *EACA* et *MdAPE*, pour les 4070 articles des 20 familles testées.

critères	M1 / M2 : amélioration du modèle M1 comparée au modèle M2		
	IDA / RB	IDAC / RB	IDAC / IDA
RMSE	-6%	-4,6%	1,2%
EACA	-1,3%	-5,7%	-5,4%
MdAPE	-10%	21%	25%

Tableau 4.7. Amélioration des critères *RMSE*, *EACA* et *MdAPE* apportée par les modèles IDA et IDAC

#### 4.5.1.3 Analyse

La procédure de classification du modèle IDAC permet de construire, pour une même famille, des classes bien distinctes d'articles proches selon les critères prix et nombre de magasins distribuant l'article (figure 4.30). Ainsi, nous pouvons espérer que le profil de vente estimé par classe soit plus précis que le profil moyen calculé (modèle IDA) pour tous les articles d'une même famille (figure 4.31). On remarque également, pour la famille de type T-shirt manches courtes femme, que le profil moyen coïncide pratiquement avec la courbe théorique proposée au chapitre 1 (section 1.3.2 figure 1.7).

Cependant, les résultats sont parfois ambigus. En effet, les prévisions du modèle IDAC paraissent souvent plus précises que celles des modèles RB et IDA, notamment par une meilleure prise en compte du profil de vente des articles (figure 4.32, article *a* et *c*), mais l'estimation de la quantité vendue par le modèle IDAC peut être mauvaise (figure 4.32, articles *b* et *d*). Le modèle IDAC étant basé sur la répartition des prévisions des ventes par famille, de telles erreurs sur le calcul de la quantité vendue d'un article impliquent des imprécisions sur les prévisions de tous les autres articles de la même famille, en vente dans cette période (section 3.3.1.1, figure 3.13).

Les critères de précision *RMSE* et *EACA* sanctionnent très fortement ces erreurs d'évaluation de la quantité de quelques articles et expliquent les médiocres résultats obtenus par les modèles IDA et IDAC. Le critère *MdAPE*, moins sensible à ces phénomènes, est beaucoup plus favorable au modèle IDAC.

#### 4.5.1.4 Conclusion de la prévision moyen terme à l'article

Pour notre expérimentation, les résultats obtenus par le modèle IDAC dépendent des critères qualitatifs ou quantitatifs de classification des articles, disponibles dans le jeu de données (dans notre cas : prix et nombre de magasins distribuant l'article). Néanmoins, il apparaît que notre procédure de classification assure une estimation plus précise du profil de vente des articles en comparaison des modèles IDA et RB. Ainsi, le modèle IDAC assure des résultats, en terme de critère *MdAPE*, très intéressants. Mais, la quantité prévue est souvent erronée et induit pour le modèle IDAC des évaluations globalement inférieures au modèle RB selon les critères *RMSE* et *EACA*.

L'amélioration générale des performances de nos derniers modèles nécessite une meilleure estimation de la quantité totale vendue par article, qui peut être envisagée par une stratégie de classification similaire à l'estimation des profils.

Ces modèles, qui permettent une première approche de la prévision des ventes à moyen terme à un niveau d'agrégation relativement fin (niveau article), assurent, notamment par une estimation relativement correcte du profil de vente (modèle IDAC), les réajustements à court terme proposés par le modèle SAMANFIS (section 4.5.2).

## 4.5.2 Prévision court terme à l'article

### 4.5.2.1 Présentation

Dans cette section, nous expérimentons le modèle SAMANFIS pour la prévision des ventes d'articles à court terme (section 3.3.2). Ce modèle permet, à partir des dernières ventes, de réajuster les prévisions des articles établies à moyen terme par les modèles IDA ou IDAC (section 4.5.1). Compte tenu de la précision toute relative des résultats des prévisions à moyen terme obtenus précédemment, le modèle SAMANFIS doit être capable de réagir très rapidement aux dernières ventes.

Nos quantifions, dans ce comparatif, les améliorations apportées par le modèle SAMANFIS, par rapport au modèle IDAC, et testées sur les 165 articles de la même famille de type T-shirt manches courtes femmes.

### 4.5.2.2 Résultats

La figure 4.33 compare les prévisions à moyen terme du modèle IDAC et à court terme du modèle SAMANFIS pour deux articles (*e* et *f*) de la famille de type T-shirt manches courtes femme.

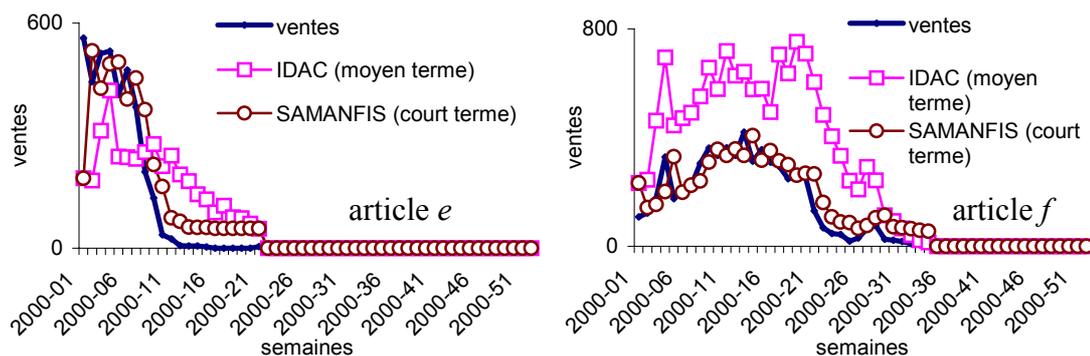


Figure 4.33. Comparaison des modèles IDAC (moyen terme) et SAMANFIS (court terme) pour deux articles d'une même famille de type T-shirt manches courtes femme

Le tableau 4.8 résume les améliorations apportées, en terme de critères *RMSE*, *EACA* et *MdAPE*, par le modèle SAMANFIS comparé au modèle IDAC.

critère	% d'amélioration de la prévision à moyen terme du modèle IDAC
RMSE	52%
EACA	55%
MdAPE	36%

Tableau 4.8. Amélioration apportée par le modèle SAMANFIS par rapport au modèle IDAC

#### 4.5.2.3 Analyse

Les dernières ventes de la saison en cours autorisent un réajustement important des prévisions du modèle IDAC, notamment en terme de quantité (le profil de vente étant généralement relativement bien estimé à moyen terme). Ainsi, la prévision à court terme du modèle SAMANFIS permet d'améliorer très significativement la prévision à moyen terme du modèle IDAC (tableau 4.8). Les critères d'évaluation de la précision (*RMSE*, *EACA* et *MdAPE*), très favorables au modèle SAMANFIS par rapport au modèle IDAC, indiquent fortement l'intérêt de ré-évaluer les prévisions chaque semaine, et particulièrement au niveau article où la précision de la prévision à moyen terme est toute relative (section 4.5.1).

#### 4.5.2.4 Conclusion de la prévision court terme à l'article

Le modèle SAMANFIS considère avantageusement les profils de vente établis à moyen terme par le modèle IDAC et propose ainsi une amélioration très importante de la précision de la prévision à l'article. Déjà appliqué avantageusement au niveau famille, il nous apparaît un modèle nécessaire et incontournable dans la prévision des ventes à court terme au niveau article.

## 4.6 Prévision taille/coloris

### 4.6.1 Présentation

Dans cette section, nous appliquons les modèles de prévision à la taille et au coloris (section 3.4) qui établissent les répartitions des prévisions à l'article sur les différentes références de tailles et couleurs correspondantes. L'estimation de ces répartitions, élaborée au niveau d'agrégation le plus fin possible, semble :

- simple pour les tailles, les fluctuations d'une année à l'autre étant faibles,
- mais délicate pour les coloris, ceux-ci étant continuellement renouvelés au gré de la mode et / ou changeant fréquemment de référence d'une année à l'autre.

Compte tenu du nombre très important de références article/taille/coloris, notre analyse des répartitions réelles des ventes selon les tailles s'est restreinte aux 2520 références d'une famille de type T-shirt manches courtes femme pour les années 1998, 1999 et 2000.

L'automatisation de la prévision des ventes par coloris est difficile en raison principalement des références rencontrées très diversifiées d'une saison à l'autre (nombre de couleurs, nuances, association de coloris) mais également non standardisées entre les articles (par exemple, le coloris rouge peut être référencé par les codes suivants : "ROUGE", "ROU" ou "RGE"). Ainsi, l'intervention d'un expert s'avère généralement nécessaire. Nous expérimentons notre méthode (section 3.4.1) uniquement sur les coloris de deux articles différents ( $g$  et  $h$ ) de type T-shirt manches courtes femme, dont les répartitions initiales estimées des ventes nous ont été communiquées par les experts de notre partenaire distributeur. Le premier article ( $g$ ), de type basique, se décline en trois coloris (blanc, gris et noir), et le second ( $h$ ), de type mode, est composé de dix références coloris (beige/blanc, blanc/gris, gris/blanc, bleu/blanc, jaune/kaki, kaki/rouge, rouge/kaki, marin/vert, vert/marin et rouille/rouge). La prévision des ventes par coloris est effectuée à moyen terme à partir d'une répartition initiale évaluée par un expert et est ensuite réajustée par un modèle du type SAMANFIS (prévision à court terme) en fonction des dernières ventes réalisées. Cependant, nous ne disposons pas, dans le jeu de données, des répartitions coloris des articles historiques (années 1998 et 1999) proposées par l'expert pour l'apprentissage du modèle SAMANFIS. Aussi, la prévision pour l'année 2000 des répartitions coloris des deux articles  $g$  et  $h$  est exécutée directement à partir du même modèle SAMANFIS, avec un apprentissage au niveau article (section 4.5.2). Le nombre de coloris par article (respectivement 3 et 10 pour les articles  $g$  et  $h$ ) étant trop faible pour appliquer le critère  $MdAPE$  (section 2.3.1.4), seuls les critères  $RMSE$  et  $EACA$  sont évalués pour quantifier la précision de nos prévisions.

#### 4.6.2 Résultats

La figure 4.34 représente la répartition des ventes par taille des articles d'une famille de type T-shirt manches courtes femme pour les années 1998 à 2000.

La figure 4.35 permet de comparer, pour les coloris de l'article  $g$ , les répartitions réelle et initiale (donnée par l'expert) des ventes à celle du modèle court terme SAMANFIS. La figure 4.36 révèle, pour l'article  $h$ , les fortes fluctuations de la répartition réelle des ventes selon les différents coloris "mode".

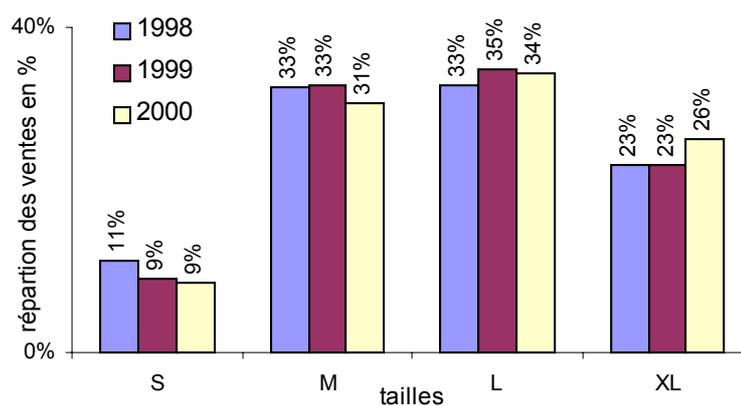


Figure 4.34. Répartition des ventes par taille pour une famille de type T-shirt manches courtes femme

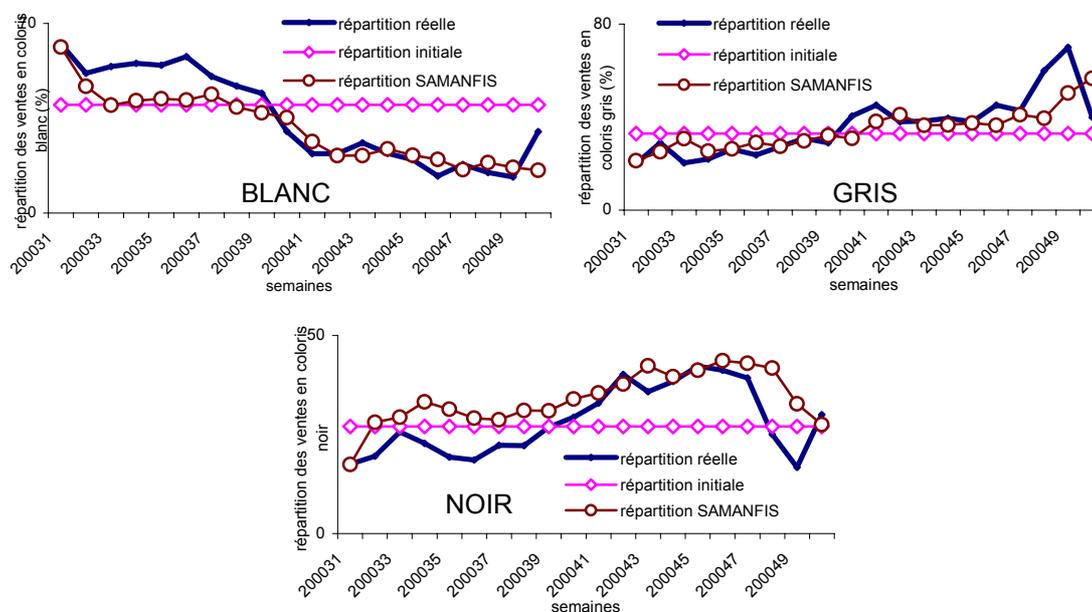


Figure 4.35. Comparaison des répartitions réelle, initiale et du modèle SAMANFIS, pour les coloris de l'article g de type T-shirt manches courtes femme

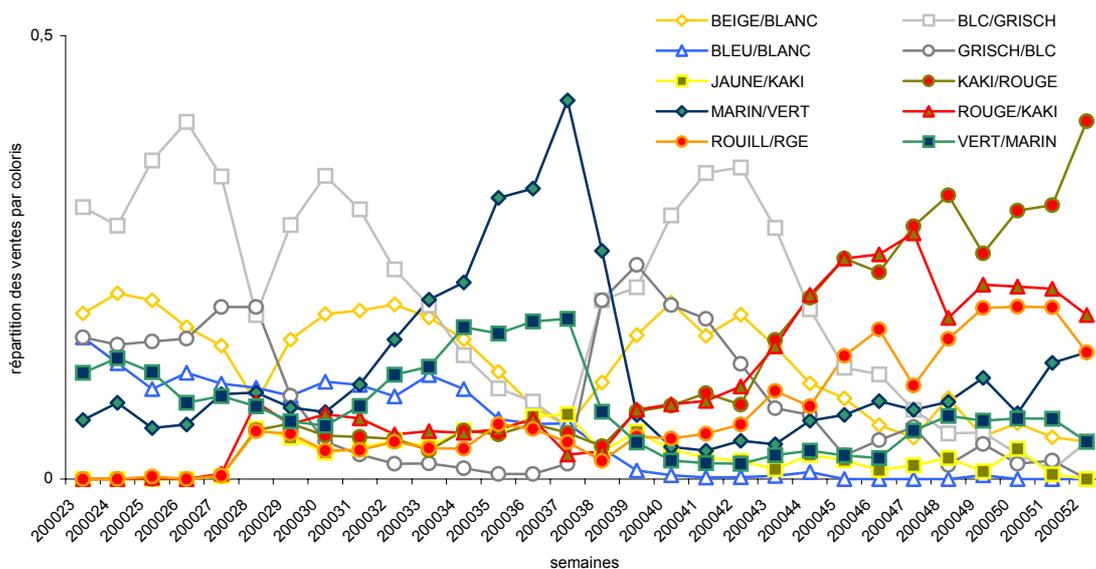


Figure 4.36. Répartition réelle des ventes pour les dix coloris de l'article h de type T-shirt manches courtes femme

Les tableaux 4.9 et 4.10 considèrent, en terme de critères *RMSE* et *EACA*, les améliorations apportées par le modèle SAMANFIS comparées à la répartition initiale proposée par l'expert pour les coloris des articles g et h.

	% d'amélioration du modèle SAMANFIS comparée à la répartition initiale		
	BLANC	GRIS	NOIR
RMSE	29,4%	27,7%	5,7%
EACA	46,1%	23,3%	2,4%

Tableau 4.9. Amélioration de la précision de la prévision par le modèle SAMANFIS comparée à la répartition initiale de l'expert, pour les trois coloris de l'article g

	% d'amélioration du modèle SAMANFIS comparée à la répartition initiale				
	BEIGE/BLANC	BLC/GRISCH	BLEU/BLANC	GRISCH/BLC	JAUNE/KAKI
RMSE	6,8%	-9,3%	7,5%	10,3%	-37,8%
EACA	14,9%	2,3%	21,4%	14,0%	-34,3%
	KAKI/ROUGE	MARIN/VERT	ROUGE/KAKI	ROUILL/RGE	VERT/MARIN
RMSE	36,4%	17,5%	31,7%	-4,0%	18,8%
EACA	29,7%	41,4%	29,2%	-12,9%	22,2%

Tableau 4.10. Amélioration de la précision de la prévision par le modèle SAMANFIS comparée à la répartition initiale de l'expert, pour les dix coloris de l'article h

### 4.6.3 Analyse

L'analyse de la figure 4.34 révèle, sur trois ans, une relative stabilité de la répartition des ventes sur les quatre tailles classiques des 2520 références articles d'une famille de type

T-shirt manches courtes femme. De façon générale, la prévision des ventes au niveau taille apparaît à la fois très fiable et facile à mettre en œuvre.

La précision de l'estimation des répartitions par coloris apparaît fortement dépendante de la nature des coloris à traiter. En effet, la répartition initiale des ventes sur les coloris de l'article basique *g* est relativement bien déterminée par l'expert (figure 4.35) et le modèle SAMANFIS assure un réajustement relativement précis de la répartition en fonction des dernières ventes (tableau 4.9). Mais, la répartition réelle des ventes de l'article *h* sur les coloris "mode" est beaucoup plus perturbée (figure 4.36). L'appréciation, par l'expert, de la distribution des quantités vendues entre les différentes couleurs est plus délicate. Le modèle SAMANFIS donne également des résultats plus difficilement interprétables et ne parvient pas à améliorer systématiquement les répartitions initiales de l'expert, à partir des dernières ventes (tableau 4.10, coloris jaune/kaki, rouille/rouge et blanc/gris).

#### **4.6.4 Conclusion de la prévision taille / coloris**

La prévision au niveau taille n'est pas problématique. Les historiques permettent généralement d'offrir des répartitions fiables et relativement stables par taille lors du lancement d'une nouvelle collection.

Compte tenu de la forte influence de la mode et de la grande diversité des références, la prévision à moyen terme au coloris nécessite une première estimation d'un expert. Un modèle du type SAMANFIS permet ensuite de réajuster à court terme les répartitions des ventes sur les différents coloris d'un article, à partir des dernières ventes. Cette stratégie s'avère efficace pour les coloris basiques (blanc, noir, gris,...), mais reste très aléatoire pour les coloris "mode".

### **4.7 Conclusion**

A partir des données réelles provenant d'un important distributeur textile, nous avons expérimenté notre système global (chapitre 3) constitué de divers modèles de prévision de ventes à différents niveaux d'agrégation et sur des horizons moyen et court terme. La prise en compte de données réelles a permis de considérer les fortes contraintes du contexte textile.

Les modèles de prévision à moyen terme au niveau famille nommés HFCCX, HNCCX et AHFCCX sont expérimentés sur les ventes réelles de familles d'articles. La prise en compte de données de ventes agrégées au niveau famille autorise un apprentissage sur des

historiques continus de 2 à 3 années (ou saisons). Ces modèles permettent d'améliorer significativement la précision des prévisions en comparaison aux modèles classiques. Avec l'intervention d'un expert, les capacités d'apprentissage de l'influence des variables explicatives du SIF ou du RNA exploités par les modèles HFCCX et HNCCX sont relativement comparables. Cependant, la technique floue est plus avantageuse pour interpréter le fonctionnement du processus. Le modèle AHFCCX, fondé sur le même principe que le modèle HFCCX, calcule automatiquement les prévisions sur un grand nombre de familles. Ces résultats sont proches, en terme de précision, du processus semi-automatique.

Les modèles de prévision à court terme au niveau famille SAMANN et SAMANFIS ont été évalués sur les dernières ventes de la saison en cours pour réajuster les prévisions à moyen terme élaborées précédemment. La technique neuronale exploitée par le modèle SAMANN doit nécessiter une structure importante pour modéliser correctement les différences entre les ventes réelles et les prévisions à moyen terme. L'apprentissage d'une telle structure requiert également un grand nombre de données historiques. Ainsi, l'amélioration apportée pour un horizon à moyen terme n'est pas significative. Grâce à l'exploitation d'une procédure neuro-floue, le modèle SAMANFIS permet de mieux caractériser les relations entre les ventes et les prévisions moyen terme ; la précision de la prévision est alors relativement intéressante, mais demeure comparable au modèle linéaire ARMAX.

Les modèles de prévision IDA et IDAC ont fonctionné sur les ventes à moyen terme des articles futurs, à partir des prévisions des familles correspondantes et des ventes des articles historiques. Les références des articles n'étant généralement pas renouvelées à chaque saison, la principale difficulté réside dans l'inexistence d'historique pour les articles futurs. Ainsi, l'élaboration des profils de vente de chaque article a été réalisée sur la totalité des articles de la famille correspondante. La procédure de classification du modèle IDAC assure la détermination de profils plus spécifiques pour chaque article. Néanmoins, les résultats obtenus restent ambigus. En effet, les quantités vendues sont parfois imprécises et impliquent des résultats peu performants comparés à une répartition basique (modèle RB). La disponibilité complète, chez le distributeur, des données caractérisant plus précisément les articles futurs devrait améliorer significativement les performances du modèle IDAC. Pour l'application industrielle de notre système de prévision et devant les performances toutes relatives et complémentaires des trois modèles RB, IDA et IDAC, nous envisageons

de proposer, à partir des articles historiques, une sélection automatique du modèle le plus approprié par famille.

Le modèle à court terme SAMANFIS appliqué au niveau article a permis de réajuster les prévisions réalisées à moyen terme. Compte tenu de la difficulté de calcul des prévisions à moyen terme, ce modèle est nécessaire afin de corriger les éventuelles erreurs dès les premières ventes de la saison future. L'amélioration obtenue est très significative en comparaison au modèle IDAC.

La relative stabilité des répartitions des ventes d'articles par taille, autorise l'utilisation d'un modèle de prévision à la taille, basé uniquement sur la simplicité et la fiabilité de la répartition classique historique. Les ventes par coloris, de type basique, sont également relativement simples à anticiper avec l'aide d'un expert, mais l'estimation des répartitions des ventes par coloris de type mode est souvent imprécise, compte tenu de leur comportement de vente très incertain et éphémère.

Finalement, le tableau 4.11 résume les méthodes développées pour notre système global de prévision.

agrégation des ventes		famille		article		coloris		taille
horizon de prévision		moyen terme	court terme	moyen terme	court terme	moyen terme	court terme	moyen et court terme
méthode	modèle							
traitement semi-automatique flou des variables explicatives	HFCCX							
traitement semi-automatique neuronal des variables explicatives	HNCCX	peu interprétable						
traitement automatique flou des variables explicatives	AHFCCX							
réajustement des prévisions MT par un réseau de neurones	SAMANN				non appliqué		non appliqué	
réajustement des prévisions MT par un système neuro-flou	SAMANFIS							
répartition des prévisions à la famille à partir d'une courbe de vie moyenne des articles	IDA							
répartition des prévisions à la famille à partir de courbes de vie issues d'une classification	IDAC							
répartition initiale donnée par un expert						coloris basique		
répartition historique						coloris mode		

	résultats très satisfaisants
	résultats satisfaisants
	résultats peu satisfaisants
	modèle non applicable au contexte

Tableau 4.11. Méthodes employées pour notre système global de prévision

## Conclusion générale

Afin d'augmenter leur réactivité face à une forte concurrence et devant les exigences croissantes des consommateurs, les industriels du textile, depuis quelques années, commencent à exploiter les outils de la "Supply Chain Management". Cependant, la spécificité de la filière textile (nombre important de références, étapes de fabrication coûteuses en temps,...) nécessite toujours l'implantation de stocks, dont la taille conditionne les ruptures ou les sur-stocks.

Ainsi, les acteurs de la filière doivent anticiper correctement leur production au plus juste en s'appuyant sur un système fiable de prévision des ventes. Pour mieux prendre en compte les demandes des consommateurs, un tel système doit s'appliquer prioritairement au niveau du distributeur. Compte tenu des contraintes liées au distributeur, nous avons proposé une stratégie basée sur des prévisions à moyen et court terme sur différents niveaux d'agrégation des ventes (de la famille à l'article taille/coloris). L'horizon à moyen terme autorise une première planification de la production, une saison à l'avance. L'horizon à court terme assure le réajustement des prévisions en fonction des dernières ventes. L'agrégation des données au niveau famille d'articles est également indispensable pour obtenir des historiques complets autorisant la modélisation de la saisonnalité et de l'influence des variables explicatives. Les prévisions des ventes agrégées peuvent ensuite être réparties au niveau article.

De nombreux modèles de prévision sont exploités avec succès dans divers domaines. Cependant, ils demeurent généralement inadaptés au contexte textile. En effet, les historiques réduits rendent difficile la modélisation du comportement des ventes qui sont perturbés par de nombreux facteurs souvent non contrôlés. L'interprétation et l'intervention de l'utilisateur sont également souvent compliquées avec les modèles classiques.

Ainsi, nous proposons **un système de prévision, constitué de plusieurs modèles, spécifique au domaine textile**. Les caractères complexe et incertain des ventes textiles sont pris en compte par des techniques issues du "soft computing" telles la logique floue, les réseaux de neurones artificiels ou les procédures évolutionnistes. Ces outils possèdent les capacités d'apprentissage et de modélisation requises en milieu incertain.

**La prévision à moyen terme au niveau famille** est élaborée par des modèles, basés sur un système d'inférence flou (modèles HFCCX et AHFCCX) ou un réseau de neurones artificiel (modèle HNCCX), intégrant et traitant séparément la saisonnalité des ventes et l'influence des variables explicatives.

L'apprentissage des modèles HFCCX et HNCCX s'appuie sur la quantification, par un expert, de l'influence des variables explicatives. Une expérimentation sur des données réelles a mis en évidence l'amélioration de la précision de la prévision de nos modèles, par comparaison aux modèles classiques testés. Néanmoins, l'intervention nécessaire de l'expert rend fastidieuse l'application de nos modèles sur de nombreuses familles.

Ainsi, le modèle AHFCCX peut se justifier en proposant une automatisation complète du calcul de la prévision, tout en conservant des résultats similaires au modèle HFCCX. Les évaluations sur 322 familles confirment les performances du modèle AHFCCX en comparaison des modèles classiques.

Afin, d'augmenter le nombre de données d'apprentissage et de mieux modéliser l'influence des variables explicatives, une procédure de classification positionnée en amont du modèle de prévision, a permis de regrouper les familles possédant un comportement de vente similaire. L'apport d'une telle procédure est très significatif sur la précision des résultats.

Nous avons envisagé également l'amélioration de la sélection des règles d'inférence du système d'inférence flou composant le modèle AHFCCX, par l'emploi d'une procédure évolutionniste. L'apport très moyen de cette approche nous incite à proposer une procédure plus adaptée de construction itérative des règles telle la méthode de Abe, ou d'élimination des règles, tel un algorithme décremental, qui devrait améliorer les capacités de généralisation de notre modèle.

**La prévision à court terme au niveau famille** peut être conduite par le modèle SAMANN, basé sur un réseau de neurones, ou par le modèle SAMANFIS, fondé sur une procédure neuro-floue. Le principe de ces modèles est de réajuster, à partir des dernières ventes, les prévisions à moyen terme du modèle AHFCCX.

Le modèle SAMANN ne parvient pas à améliorer convenablement les prévisions à moyen terme. Compte tenu du nombre réduit de données d'apprentissage, la structure du réseau de neurone n'est pas suffisamment importante pour autoriser une modélisation correcte des erreurs entre les ventes et les prévisions à moyen terme.

La technique neuro-floue du modèle SAMANFIS s'avère plus adaptée. En effet, ce modèle intègre rapidement les dernières ventes et réajuste significativement les prévisions du modèle à moyen terme (AHFCCX). Cependant, le modèle ARMAX, qui considère également la prévision à moyen terme, donne des résultats également intéressants.

Les perspectives d'amélioration, pour la prévision court terme, s'orientent vers l'utilisation de processus mieux adaptés aux données d'apprentissage incertaines et peu nombreuses. Afin de mieux prendre en compte les contraintes du marché textile, notre modèle devra également permettre de calculer des prévisions sur un horizon de deux à trois semaines. Une procédure de classification, selon les erreurs de prévision historique, positionnée en amont du modèle de prévision pourrait également s'avérer bénéfique.

Les modèles (IDA et IDAC), basés sur la répartition des prévisions à la famille sur les articles correspondants, élaborent **la prévision à moyen terme au niveau article**. Les références des articles étant très rarement renouvelées d'une saison à l'autre, la principale difficulté réside dans l'indisponibilité des historiques des articles futurs. Ainsi, nos modèles, dont le principe est fondé sur la construction d'une courbe de vie prévisionnelle et sur la répartition des prévisions par famille, n'ont pu exploiter que les historiques des ventes de tous les articles d'une même famille.

Le modèle IDA établit une courbe de vie moyenne identique pour chacun des articles d'une même famille. La répartition des prévisions par famille a été effectuée en fonction des courbes de vie adaptées aux période de ventes des articles futurs. La construction d'une courbe de vie unique pour tous les articles d'une famille constitue le principal inconvénient de ce modèle.

Le modèle IDAC, construit sur la même méthode de répartition des prévisions par famille que le modèle IDA, met en œuvre une procédure de classification définissant des courbes de vie plus spécifiques aux articles futurs. Néanmoins, les données qualitatives et quantitatives caractérisant les articles sont limitées. Parmi les critères de classification disponibles, nous avons retenu les plus significatifs : le prix et le nombre de magasins distribuant l'article.

L'application de nos modèles sur 4070 articles montre que la courbe de vie prévue par le modèle IDAC est généralement plus précise que la courbe de vie moyenne du modèle IDA. Cependant, l'estimation des quantités totales vendues reste trop approximative. Le gain du modèle IDAC, en terme de précision, en comparaison à une répartition basique des

prévisions par famille n'est pas manifeste. L'évolution de nos modèles, qui doit permettre de calculer plus précisément la quantité vendue par article, peut être envisagée d'une part en considérant d'autres critères disponibles et plus caractéristiques des articles, et d'autre part en exploitant une procédure de classification supplémentaire pour l'estimation des quantités.

**La prévision à court terme au niveau article** est calculée par un modèle neuro-flou du type SAMANFIS, utilisé précédemment au niveau famille. Ce modèle réajuste les prévisions à moyen terme du modèle IDAC. Compte tenu du caractère incertain des prévisions à moyen terme, l'amélioration apportée par le modèle SAMANFIS est très importante.

La distribution des ventes d'articles textiles par taille est relativement stable dans le temps. Ainsi, **la prévision au niveau taille** est élaborée à partir d'une simple répartition historique. **La répartition des ventes sur les coloris**, très sensible aux phénomènes de mode, impose l'intervention d'un expert. Cette méthode intuitive, complétée par le réajustement à court terme du modèle neuro-flou SAMANFIS, donne de bons résultats pour les coloris basiques (blanc, noir, gris) mais reste aléatoire pour les coloris "mode". Les perspectives d'amélioration de la prévision au niveau coloris concernent l'intégration d'informations qualitatives sur les tendances et évolutions de la mode.

Finalement, le tableau suivant résume les méthodes les plus pertinentes développées pour notre système global de prévision.

horizon prévision	moyen terme	court terme
à la famille	système flou avec apprentissage automatique des paramètres	système neuro-flou
à l'article	répartition des prévisions par famille basée sur l'estimation de courbe de vie par classification	système neuro-flou
à la taille	répartition historique	
au coloris	répartition élaborée par l'expert	système neuro-flou

Tableau 5.1. Méthodes adoptées pour notre système global de prévision

Ce système de prévision de ventes, associé à un module de simulation et d'optimisation des approvisionnements, compose **un outil complet à destination des acteurs de la filière textile**. Cet outil d'aide à la décision conçu par le GEMTEX et développé par l'IFTH, constitue la finalité industrielle du projet AIDE. Il se présente sous la forme d'un service accessible par Internet. Ce support répond principalement aux deux exigences que nous nous sommes fixées : "la couverture et la disponibilité" qui permettront à toute entreprise, quelle que soit sa taille, d'accéder facilement par l'usage d'un simple navigateur à ce type de service.

Enfin, nous avons proposé une première approche de la prévision des ventes, applicable directement pour la distribution textile. Ce système d'aide à la décision pour l'expert est à la fois simple d'utilisation et efficace sur divers horizons et à différents niveaux d'agrégation des références ; aujourd'hui, il ne peut qu'améliorer significativement les prévisions du distributeur et indirectement la gestion des flux matières et informationnels de toute la chaîne d'approvisionnement de la filière textile.

Nous avons ainsi résolu globalement le problème de la prévision ; cependant, nos résultats expérimentaux peuvent être parfois affinés et nous conduisent à envisager des perspectives de développement qui correspondent aux axes de progrès suivants :

- prendre en compte plus efficacement l'influence des variables explicatives au niveau famille par une méthode plus appropriée de sélection des règles d'inférence de notre modèle de prévision à moyen terme AHFCCX,
- améliorer l'apprentissage du modèle AHFCCX en regroupant les familles selon leur comportement face aux variables explicatives,
- mettre en œuvre des techniques d'apprentissage et de modélisation issues du "soft computing" plus adéquates à la prévision court terme à la famille,
- aborder les prévisions sur un horizon plus large de deux à trois semaines souhaitables pour les délais de réapprovisionnement des magasins de vente,
- déterminer plus précisément les quantités prévisionnelles au niveau article par une classification considérant éventuellement des critères qualitatifs des produits (style, matière, ...),
- contrôler rigoureusement toutes les ventes par coloris en intégrant les phénomènes de mode par l'intermédiaire d'informations issues du marketing, des créateurs ou de la tendance du marché,

- et adapter l'outil informatique, issu de nos travaux, aux nécessités des industriels du textile, en prenant en compte les éventuelles remarques des premiers utilisateurs.

Finalement, la figure 5.1 ci-dessous illustre, dans notre système global de prévision, les points d'intervention hiérarchisés de ces axes de progrès.

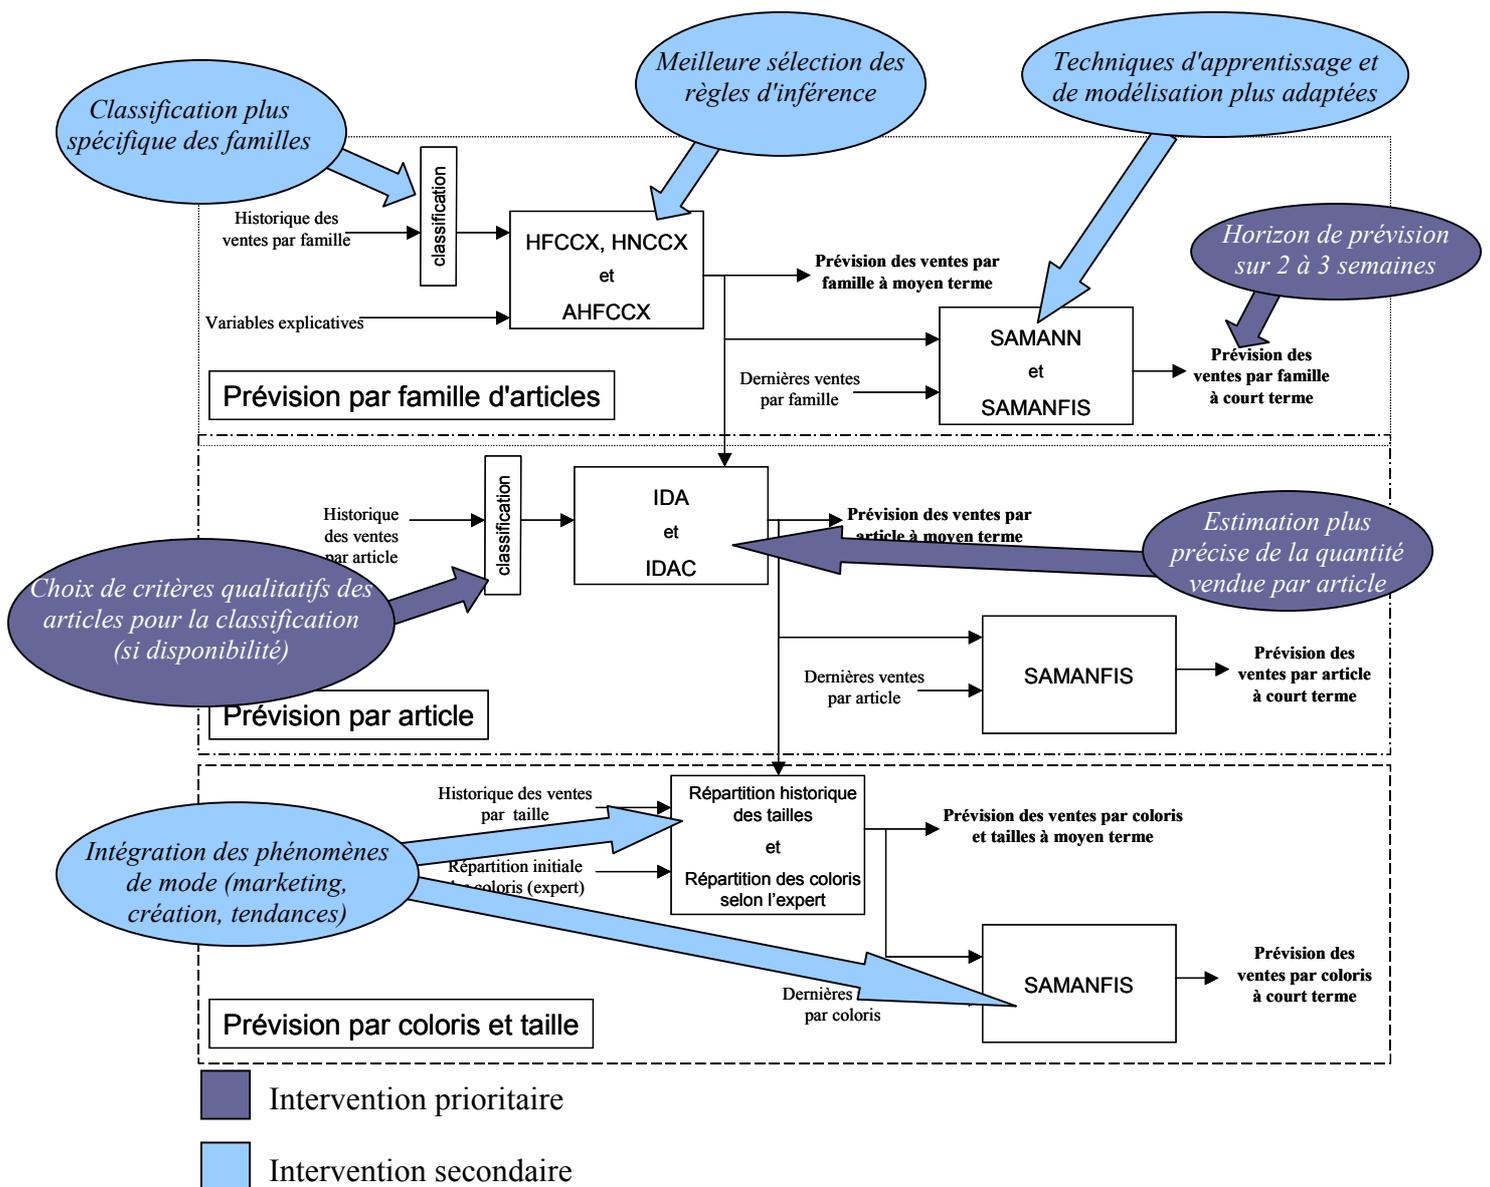


Figure 5.1. Amélioration du système global de prévision

## Références bibliographiques

- Abadir, K.M., Hadri, K., Tzavalis, E., 1999. The influence of VAR dimensions on estimator biases, *Econometrica*, vol. 67, pp. 163-181.
- Abe, S., Lan, M., 1995. Fuzzy rules extraction directly from numerical data for function approximation, *IEEE Transaction on Systems, Man and Cybernetics*, vol. 25, no. 1, pp. 119-129.
- Abrahart, R.J., See, L., 2000. Comparing neural network and autoregressive moving average techniques for the provision of continuous river flow forecasts in two contrasting catchments, *Hydrological processes*, vol. 14, no 11-12, pp. 2157 – 2172.
- Adya, M., Armstrong, J.S., Collopy, F., Kennedy, M., 2001. An application of rule-based forecasting to a situation lacking domain knowledge, *International Journal of Forecasting*, vol. 16, pp. 477-484.
- Akaike, H., 1974. A new look at the statistical model identification. *IEEE Transactions on Automatic Control*, vol. 19, pp. 716-723.
- Alba, E., Cotta, C., Troyo, J.J., 1996. Type constrained genetic programming for rule based definition in fuzzy logic controllers, *GP'96 San Francisco*, pp. 255-260.
- Alexandre, F., Cardeira, C., Charpillet, F., Mammeri, Z., Portmann, M.C., 1997. Compu-search methodologies II : Scheduling using genetic algorithms and artificial neural networks, *The Planning and Scheduling of Productions Systems : Methodologies and Applications*, chapitre 10, pp. 301-336, Editions Artiba A., Elmaghraby S.E., Chapman & Hall.
- Aliev, R.A. , Fazlollahi, B., Vahidov, R.M., 2001. Genetic algorithm-based learning of fuzzy neural networks. Part 1 : feed-forward fuzzy neural networks, *Fuzzy Sets and Systems*, vol. 118, no. 2, pp. 351–358.
- Allen, P.G., 1994. Economic forecasting in agriculture, *International Journal of Forecasting*, vol. 10, pp. 81-135.
- Allen P.G., Fildes, R., 2001. Econometric forecasting, in Armstrong J.S., *Principles of forecasting – A handbook for researchers and practitioners*, Kluwer Academic Press, Norwell, MA, pp. 303-362.
- Ansuji, A.P., Carmago, M.E., Radharamanan, R., Petry, D.G., 1996. Sales forecasting using time series methods and neural networks, *Computers and Industrial Engineering*, vol. 31, no. 1-2, pp. 421-424.
- Armstrong, J.S., 1985. *Long-range forecasting : from crystal ball to computer*, 2<sup>nd</sup> Edition, New York : John Wiley.
- Armstrong, J.S., Collopy, F., 1992. Error measures for generalizing about forecasting methods : empirical comparisons, *International Journal of Forecasting*, vol. 8, pp. 69-80.
- Armstrong, J.S., Fildes, R., 1995. Correspondance on the selection of error measures for comparisons among forecasting methods, *Journal of Forecasting*, vol. 14, pp. 67-71.
- Armstrong, J.S., Morwitz, V.G., Kumar, V., 2000. Sales forecasts for existing consumer products and services : do purchase intentions contribute to accuracy ?, *International Journal of Forecasting*, vol. 16, pp. 383-397.

- Armstrong, J.S., 2001. Principles of forecasting – A handbook for researchers and practitioners, Kluwer Academic Press, Norwell, MA.
- Armstrong, J.S., Brodie, R., Parsons, A., 2001b. Hypotheses in marketing science : literature review and publication audit, *Marketing Letters*, vol. 12, pp. 171-187.
- Armstrong, J.S., 2001c. Extrapolation of time-series and cross-sectional data, in Armstrong J.S., Principles of forecasting – A handbook for researchers and practitioners, Kluwer Academic Press, Norwell, MA.
- Armstrong, J.S., 2001d. Selecting methods, in Armstrong J.S., Principles of forecasting – A handbook for researchers and practitioners, Kluwer Academic Press, Norwell, MA.
- Armstrong, J.S., Adya, M, Collopy, F, 2001e. Rule-based forecasting : using judgment in time-series extrapolation, in Armstrong J.S., Principles of forecasting – A handbook for researchers and practitioners, Kluwer Academic Press, Norwell, MA.
- Armstrong, J.S., 2001f. Combining forecasts, in Armstrong J.S., Principles of forecasting – A handbook for researchers and practitioners, Kluwer Academic Press, Norwell, MA.
- Armstrong, J.S., 2001g. Evaluating forecasting methods, in Armstrong J.S., Principles of forecasting – A handbook for researchers and practitioners, Kluwer Academic Press, Norwell, MA.
- Armstrong, J.S., 2001h. Role playing : a method to forecast decisions, in Armstrong J.S., Principles of forecasting – A handbook for researchers and practitioners, Kluwer Academic Press, Norwell, MA.
- Armstrong, J.S., 2001i. Judgmental bootstrapping : inferring expert's rules for forecasting, in Armstrong J.S., Principles of forecasting – A handbook for researchers and practitioners, Kluwer Academic Press, Norwell, MA.
- Arslan, A., Kaya, M., 2001. Determination of fuzzy logic membership functions using genetic algorithms, *Fuzzy Sets and Systems*, vol. 118, no. 2, pp. 297–306.
- Atiya, A.F., Shaheen, S.I., 1999. A comparison between neural network forecasting techniques – Case study : river flow forecasting, *IEEE Transaction on neural networks*, vol. 10, no. 2, pp. 402-409.
- Azoff, E.M., 1994. Neural network time series forecasting of financial markets, Wiley Finance, Chistester, England.
- Bass, F.M., 1969. A new product growth model for consumer durables, *Management Sciences*, pp. 215-227.
- Bastian, A., 2000. Identifying fuzzy models utilizing genetic programming, *Fuzzy Sets and Systems*, vol. 113, no. 3, pp. 335–350.
- Batchelor, R., Dua, P., 1995. Forecaster diversity and the benefits of combining forecasts, *Management Sciences*, vol. 41, pp. 68-75.
- Battiti, R., 1992. First and second order methods for learning : between steepest descent methods and newton's methods, *Neural Computation*, vol. 4, no. 2, pp. 141-166.
- Behloul, F., Boudraa, A. , Lelieveldt, B.P.F., Janier, M., Reiber, J.H.C., 2001. Myocardium extraction in positron emission tomography based on soft computing, *Computerized medical imaging and graphics*, vol. 25 , no 3 , pp. 277 – 286.

- Bersini, H., 1992. Génération automatique de systèmes de commande floue par les méthodes de gradient et les algorithmes génétiques, *Acts des Journées Nationales sur les Applications des Ensembles Flous, EC2, Nîmes*, pp. 199-209.
- Bezdek, J.C., *Pattern recognition with fuzzy objective function algorithm*, Plenum Press, New York.
- Bliemel, F.W., 1973. Theil's forecast accuracy coefficient : a clarification, *Journal of Marketing Research*, vol. 10, pp. 444-446.
- Bollerslev, T., 1986. Generalized autoregressive conditional heteroskedasticity, *Journal of Econometrics*, vol. 31, pp. 307-328.
- Bourbonnais, R., Usunier, J. C., 1992. *Pratique de la Prévision des Ventes – Conception de Systèmes*, Economica, Paris,
- Boussu, F., 1998. *Simulation de la filière Textile – Habillement – Distribution : réduction de la complexité en vue d'une meilleure prévision des ventes*, Thèse de l'Université des Sciences et Technologie de Lille I.
- Box, G.E.P, Jenkins, G.M., 1969. *Time series analysis – Forecasting and control*, Prentice Hall, Englewood Cliffs, NJ, USA.
- Brockhoff, K., 1967. A test for the product life cycle, *Economica*, vol. 35, no. 3-4, pp. 472-484.
- Brown, R.G., 1959. *Smoothing forecasting and prediction of discrete time series*, Englewood Cliffs, Prentice Hall.
- Bultez, A., Pardoën, E., Siniglia, N., 1995. Modélisation dans le commerce de détail : l'esprit de géométrie soufflé dans les gondoles, *Revue Française de Gestion*, vol. 102, pp. 71-85.
- Calado, J.M.F., Korbicz, J., Patan, K, Patton, R.J., Sa Da Costa, J.M.G., 2001. Soft computing approaches to fault diagnosis for dynamic systems, *European Journal of Control*, vol. 7, no. 2-3, pp. 248-286.
- Camerer, C., 1981. General conditions for the success of bootstrapping models, *Organizational Behavior and Human Performance*, vol. 27, pp. 411-422.
- Carpenter, G.A., Grossberg, S., Rosen, D.B., 1991. Fuzzy-ART : fast stable learning and categorization of analog patterns by an adaptive resonance system, *Neural Networks*, vol. 4, pp. 759-771.
- Casdagli, M.C., 1989. Nonlinear prediction of chaotic time series, *Physica, D*. 35, pp. 335-356.
- Cattin, P, Wittink, D.R., 1982. Commercial use of conjoint analysis : a survey, *Journal of Marketing*, vol. 46, pp. 44-53.
- Celeux, G., Diday, E., Govaert, G., Lechevallier, Y., Ralambondrainy, H., 1989. *Classification automatique des données : environnement statistique et informatique*, Editions Dunod, Paris.
- Chan, K.S., Tong, H, 1986. On estimating threshold in autoregressive models, *Journal of Time Series Analysis*, vol. 7, pp. 179-190.
- Chan, D.Y.C., Prager, D., 1994. Analysis of time series by neural networks, In : *Proceeding of the IEEE Joint Conference on Neural Networks*, vol. 1, pp. 355-360.

- Chang, F.J., Chen, Y.C., 2001. A counterpropagation fuzzy-neural network modeling approach to real time streamflow prediction, *Journal of Hydrology*, vol. 245, no. 1-4, pp. 153-164.
- Chatfield, C., 1988. Apples, oranges and mean square error, *International Journal of Forecasting*, vol. 4, pp. 515-518.
- Chatfield, C., 1993. Calculating interval forecasts, *Journal of Business and Economic Statistics*, vol. 11, pp. 121-144.
- Chatfield, C., 1995. *Problem solving : a statistician's guide*, 2<sup>nd</sup> Edition, Chapman and Hall, London.
- Chatfield, C., 1996. Model uncertainty and forecast accuracy, *Journal of Forecasting*, vol.15, pp. 495-508.
- Chatfield, C., 2001. Prediction intervals for time-series forecasting, in Armstrong J.S., *Principles of forecasting – A handbook for researchers and practitioners*, Kluwer Academic Press, Norwell, MA.
- Choudhury, J.P., Sarkar, B., Mukherjee, S.K., 2001. Prediction of Engineering Manpower using Fuzzy Feed Forward Back Propagation Neural Network model, *IETE Journal of Research*, vol. 47, no. 1-2, pp. 79–83.
- Chow, M.Y., Tram, H., 1997. Application of Fuzzy Logic Technology for Spatial Load Forecasting, *IEEE Transactions on Power Systems*, vol. 12, no. 3, pp. 1360 – 1366.
- Church, K.B., Curram, S.P., 1996. Forecasting consumer's expenditure : a comparison between econometric and neural network models, *International Journal of Forecasting*, vol. 12, pp. 255-267.
- Clements, M.P., Hendry, D.F., 1999. *Forecasting non-stationary economic time series : the Zeuthen lectures on economic forecasting*, Cambridge, MA, MIT Press.
- Chiang, W.S., Urban, T.L., Baldrige, G.W., 1996. A neural network approach to mutual fund net asset value forecasting, *Omega*, vol. 24, pp. 205-215.
- Ciuca, I., Jitaru, E., 1998. On the recurrent neural network induction by evolutionary computations with applications in forecasting, *Studies in Informatics and Control*, vol. 7, no. 2, pp. 187-191.
- Collopy, F., Armstrong, J.S., 1992. Rule-based forecasting : development and validation of an expert systems approach to combining time series extrapolations, *Management Science*, vol. 38, pp. 1394-1414.
- Collopy, F., Adya, M., Armstrong, J.S., 2001. Expert systems for forecasting, in Armstrong J.S., *Principles of forecasting – A handbook for researchers and practitioners*, Kluwer Academic Press, Norwell, MA, pp. 283-300.
- Cottrell, M., Girard, B., Girard, Y., Mangeas, M., Muller, C., 1995. Neural modelling for time series : a statistical stepwise method for weight elimination, *IEEE Transaction on Neural Networks*, vol. 6, no. 6, pp. 1355-1364.
- Cundari, T.R., Jun, D., Pop, H.F., Sarbu, C., 2000. Structural analysis of transition metal  $\beta$ -X substituent interactions. Toward the use of soft computing methods for catalyst modelling, *Journal of chemical information and computer sciences*, vol. 40, n<sup>o</sup>. 4, pp. 1052-1061.

- Cundari, T.R., Russo, M., 2001. Database mining using soft computing techniques – An integrated neural network-fuzzy logic-genetic algorithm approach . *Journal of Chemical Information and Computer Sciences*, vol. 41, no. 2, pp. 281-287.
- Dasgupta, C.G., Dispensa, G.S , Ghose, S., 1994. Comparative the Predictive Performance of a Neural Network Model with some Traditional Market Response Models. *International Journal of Forecasting*, vol. 10, pp. 235-244.
- Dalrymple, D.J., 1987. Sales forecasting practices : results from an United States survey, *International Journal of Forecasting*, vol. 3, pp. 379-391.
- De Falco, I., Iazzetta, A., Luongo, G., Mazzarella, A., Tarantino, E., 2000. The seismicity in the Southern Tyrrhenian area and its neural forecasting, *Pure and Applied Geophysics*, vol. 157, no. 3, pp. 343–355.
- De Gooijer, J.G., Kumar, K., 1992. Some Recent Developpement in Non Linear Time Series Modelling, Testing, and Forecasting, *International Journal of Forecasting*, vol. 8, pp. 135-156.
- Del Moral, M.J., Valderrama, M.J., 1997. A principal component approach to dynamic regression models, *International Journal of Forecasting*, vol. 13, pp. 237-244.
- Demuth, H. B., and Beale, M. H., 1994. *Neural Network Toolbox User's Guide*, The MathWorks Inc., MA.
- Desmet, P., Renaudin, V., 1998. Estimation of product category sales responsiveness to allocate shelf space, *International Journal of Research in Marketing*, vol. 15, pp. 443-457.
- De Toni, A., Meneghetti, A., 2000. The production planning process for a network of firms in the textile-apparel industry, *International Journal of Production Economics*, vol. 65, pp.17-32.
- Diebold, F.X., Giorgianni, L., Inoue, A., 1996. STAMP 5.0 : a review, *International Journal of Forecasting*, vol. 12, pp. 309-315.
- Dijkstra, J.J., Liebrand, W.B.G., Timminga, E., 1998. Persuasiveness of expert systems, *Behavior and Information Technology*, vol. 17, no. 3, pp. 155-163.
- Dornier, F., 2002. *Apport de la classification pour la prévision des ventes – Application à la distribution textile*, Projet de Fin d'Etudes, Ecole Nationale des Arts et Industries Textiles.
- Dote, Y., Ovaska, S.J., 2001. Industrial applications of soft computing : a review, *Proceedings of the IEEE*, vol. 89, no. 9, pp. 1243-1265.
- Dracopoulos, D.C., Kent, S., 1997. Genetic programming for prediction and control, *Neural Computing & Applications*, vol. 6, no. 4, pp. 214-228.
- Dua, P., Smyth, D.J., 1995. Forecasting US home sales using BVAR models and survey data on households' buying attitudes for homes, *Journal of Forecasting*, vol. 14, pp. 217-227.
- Duncan, G.T., Gorr, W.L., Szczypula, J., 2001. Forecasting analogous time series, in Armstrong J.S., *Principles of forecasting – A handbook for researchers and practitioners*, Kluwer Academic Press, Norwell, MA.
- Dunn, J.C., 1974. Well separated clusters and optimal fuzzy partitions, *J. Cybern.*, vol. 4; pp. 95-104.

- Engle, R.F., 1982. Autoregressive conditional heteroskedasticity with estimate of variance of UK inflation, *Econometrica*, vol. 50, pp. 987-1008.
- Edmundson, R.H., Lawrence, M.J., O'Connor, M.J., 1988. The use of non time-series information in sales forecasting : a case study, *Journal of Forecasting*, vol. 7, pp. 201-211.
- Eskin, G.K., 1973. Dynamic forecasting of new product demand using a depth or repeat model, *Journal of Marketing Research*, pp. 115-129.
- Faraway, J., Chatfield, C., 1998. Time series forecasting with neural networks : a comparative study using the airline data, *Applied Statistics*, vol. 47, part 2, pp. 231-250.
- Farg, W.A., Quintana, V.H., Lambert-Torres, G., 1998. A genetic-based neuro-fuzzy approach for modeling and control of dynamic systems, *IEEE Transactions on Neural Networks*, vol. 9, no. 5, pp. 756-767.
- Farber, J., 1987. Predicting chaos time series, *Physical Review Letters*, vol. 59, pp. 845-848.
- Farmer, J.D., Sidorowich, J.J., 1988. Exploiting chaos to predict the future and reduce noise, in Lee, Y.C., *Evolution and Cognition*, Singapore, World Scientific.
- Fathi-Torbaghan, M., Hildebrand, L., 1994. Evolutionary strategies for the optimisation of fuzzy rules, *Actes de la 5<sup>ème</sup> Conférence Internationale IPMU*, Paris, pp. 671-674.
- Fenneteau, H., 1998. *Cycle de vie des produits*, Edition Economica, Paris.
- Fessant, F., 1995. *Prédiction des séries temporelles par réseaux de neurones artificiels : application aux séries temporelles ionosphériques*, Thèse à l'université de Rennes 1, Département Traitement du Signal et Télécommunication.
- Fildes, R., Hibon, M., Makridakis, S., Meade, N., 1998. Generalizing about univariate forecasting methods : further empirical evidence, *International Journal of Forecasting*, vol. 14, pp. 339-358.
- Fildes, R., Makridakis, S., 1988. Forecasting and loss function, *International Journal of Forecasting*, vol. 4, pp. 545-550.
- Fiordaliso, A., 1996. A pruning method for self-structuring of the fuzzy systems applied to function approximation, in *Proceeding of the EUFIT96 conference*, vol. 1, pp. 581-586, Elite Foundation.
- Fiordaliso, A., 1998a. A Nonlinear Forecast Combination Method Based on Takagi-Sugeno Fuzzy Systems, *International Journal of Forecasting*, vol. 14, pp. 367-379.
- Fiordaliso, A., 1998b. A decremental algorithm for autostructuring fuzzy systems based on rules sensitivity analysis, in *Proceeding of the ICAFS'98 conference*, pp. 220-226.
- Fiordaliso, A., 1999. *Systèmes flous et prévision de séries temporelles*, Hermès science, Paris.
- Fischhoff, B., MacGregor, D.G., 1982. Subjective confidence in forecasts, *Journal of Forecasting*, vol. 1, pp. 155-172.
- Fletcher, E.W., Goss, E., 1993. Forecasting with neural networks – An application using bankruptcy data, *Information and Management*, vol. 24, pp. 159-167.
- Gately, E., 1996. *Neural networks for financial forecasting*, John Wiley, New York.
- Gath, I., Geva, A.B., 1989. Unsupervised optimal fuzzy clustering, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 11, pp. 773-781.

- Geriner, P.T., Ord, J. K. 1991. Automatic forecasting using explanatory variables: a comparative study, *International Journal of Forecasting*, vol. 7, pp. 127-140.
- Geurts, M.D., 1975. A market screen for the noncorporate product innovation, *Oregon Business Review*, vol. 33, no. 3.
- Geurts, M.D., Lawrence, K.D., Guerard, J., 1994. Forecasting sales, *advances in business and management forecasting*, JAI Press inc., vol. 1.
- Gilbert, P.D., 1995. Combining VAR estimation and state space model reduction for simple good predictions, *Journal of Forecasting*, vol. 14, pp. 229-250.
- Glaser, D., 1954. A reconsideration of some parole prediction factors, *American Sociological Review*, vol. 19, pp. 335-340.
- Goldberg, D.E., 1989. Genetic algorithms in search, optimization, and machine learning, reading, MA : Addison-Wesley.
- Gorrini, V., Salomé, T, Bersini, H., 1995. Self-structuring systems for function approximation, in *Proceeding of the FUZZ-IEEE/IFES'95*.
- Gottardi, G, Scarso, E., 1994. Diffusion models in forecasting : a comparison with the Box-Jenkins approach, *European Journal of Operational Research*, vol. 75, pp. 600-616.
- Gouriéroux, C., Monfort, A., 1990. Qualitative threshold ARCH models, working paper 9009, ENSAE/INSEE.
- Granger, C.W.J., Teräsvirta, T., 1992. Modelling nonlinear economic relationship, Oxford University Press.
- Graves, S.C., Kletter, D.B., Hetzel, W.B., 1998. A dynamic model for requirements planning with application to supply chain optimization, *Operations Research*, vol. 46, pp. 35-49.
- Gupta, S., Chintagunta, P., Kaul, A., Wittink, D.R., 1996. Do household scanner panels provide representative inference from brand choices : a comparison with store data, *Journal of Marketing Research*, vol. 33, pp. 383-398.
- Gustafson, E.E, Kessel, W.C., 1979. Fuzzy clustering with a fuzzy covariance matrix, in *Proceeding of the IEEE CDC*, pp. 761-766.
- Hagan, M.T., Demuth, H.B., Beale, M.H., 1996. *Neural Network Design*, MA: PWS Publishing.
- Han, Z.Z., Tang, Y.H., 1999. Fuzzy forecast of flood disaster caused by solar proton flares, *Applied Mathematics and Computation*, vol. 98, no. 1, pp. 83-89.
- Hansen, J.V., Nelson, R.D., 1997. Neural networks and traditional time series methods : a synergistic combination in state economic forecasts, *IEEE Transaction on Neural Networks*, vol. 8, no. 4, pp. 863-873.
- Happiette, M., Rabenasolo, B., Boussu, F., 1996. Sales partition for forecasting into textile distribution network. *IEEE International Conference on Systems, Man, and Cybernetics*, Beijing, China, vol.4, pp. 2868-2873, October 14-17.
- Haykin, S., 1994. *Neural networks : a comprehensive foundation*, Macmillan College Publishing Company, New York.
- Herpin, N., 1986. L'habillement, la classe sociale et la mode, *Economie et Statistique*, pp. 35-54.

- Heskes, T., 1997. Practical confidence and prediction intervals, advances in neural information processing systems, Edition Mozer et al., MIT Press.
- Hidden, H., Willis, M., McKay, B., Montague, G., 1997. Non-linear and direction dependent dynamic modelling using genetic programming, Genetic Programming 1997 : Proceedings of the second Annual Conference, Edition Koza et al., pp. 168-173.
- Hill, T., Marquez, L., O'Connor, M., Remus, W., 1994. Artificial neural Network Models for Forecasting and Decision Making, International Journal of Forecasting, vol. 10, pp. 1-15.
- Hlebar, B., 2001. Forecasting closing overvoltages in high-voltage networks using a fuzzy model, Fuzzy Sets and Systems, vol. 118, no. 1, pp. 1-8.
- Holland, J.H., 1975. Adaptation in natural and artificial systems, University of Michigan Press, Ann Arbor.
- Hong, T.L., Sheu, H.C., 2001. Fuzzy regression model with fuzzy input and output data for manpower forecasting, Fuzzy Sets and Systems, vol. 119, no. 2, pp. 205-213.
- Hongbin, Y.S.C., Wong, S.C., Jianmin, X.C.K., Wong, C.K., 2002. Urban traffic flow prediction using a fuzzy-neural approach, Transportation Research. Part C, Emerging Technologies, vol. 10, no. 2, pp. 85-98.
- Hoptroff, R.G., 1993. The principles and practice of time series forecasting and business modeling using neural networks. Neural Computing and Applications, vol. 1, pp. 59-66.
- Hornik, K., Stinchcombe, M., White, H., 1989. Multilayer feedforward networks are universal approximators, Neural Networks, vol. 2, pp. 359-366.
- Howard, E., Oakley, N., 1995. Genetic programming as a mean of assessing and reflecting chaos, technical Report FS-95-01, AAAI Press, pp. 68-72.
- Hsu, Y.Y., Ho, K.L., 1992. Fuzzy expert systems : an application to short-term load forecasting, IEEE proceedings Part C : Generation, Transmission and Distribution, vol. 139, no. 6, pp. 471-477.
- Ishibuchi, H., Tanaka, H., Okada, H., 1993. Fuzzy neural networks with fuzzy weights and fuzzy biases, In : IEEE Technology Update Series, Neural Networks Theory, Technology, and Applications, Edition Simpson P., NY, pp. 155-160.
- Ishibuchi, H., Nii, M., 2001. Fuzzy regression using asymmetric fuzzy coefficients and fuzzified neural networks, Fuzzy Sets and Systems, vol. 119 , no. 2 , pp. 273-290.
- Jamshidi, M., 2001. Autonomous control of complex systems : robotic applications, Applied Mathematics and Computation, vol. 120, no. 1-3, pp. 15-29.
- Jang, J.S., 1992. Fuzzy controller design without domain expert, In : IEEE International Conference on Fuzzy Systems, pp. 289-296.
- Jang, J.R., 1993. ANFIS : adaptive-network-based fuzzy inference system, IEEE Transaction on Systems, Man and Cybernetics, vol. 23, no. 3, pp. 665-685.
- Janiak, A., Portmann, M.C., 1998. Genetic algorithms for the permutation flow-shop scheduling problem with linear models of operations, Annals of Operations Research, vol. 83, pp. 95-114.

- Johnson, V.M., Rogers, L.L., 2001. Applying soft computing methods to improve the computational tractability of a subsurface simulation-optimization problem, *Journal of Petroleum Sciences & Engineering*, vol. 29, no. 3-4, pp. 153-175.
- Johnson, M., Firoozbakhsh, K., Moniem, M., Jamshidi, M., 2001b. Determining flexor-tendon repair techniques via soft computing, *IEEE engineering in medicine and biology magazine*, vol. 20, no 6, pp. 176 – 183.
- Jones, J.M., Zufryden, F.S., 1980. Adding explanatory variables to a purchase behavior model – An explanatory study, *Journal of Marketing Research*, vol. 17, pp. 323-334.
- Ju, Y.J., Kim, C.E., Shim, J.C., 1997. Genetic-based fuzzy models : Interest rate forecasting problem, *Computers & Industrial Engineering*, vol. 33, no. 3-4, pp. 561–564.
- Kamgar-Parsi, B., Kanal, L.N., 1985. An improved branch and bound algorithm for computing k-nearest neighbors, *Pattern Recognition Letters*, vol. 3, pp. 7-12.
- Kartalopoulos, S.V., 1996. *Understanding neural networks and fuzzy logic – Basic concepts and application*, IEEE Press, New York.
- Karr, C.L., 1991. Design of a adaptive fuzzy logic controller using a genetic algorithm, in *Proceeding of the 4<sup>th</sup> International Conference on Genetic Algorithms*, pp. 450-457.
- Kauppi, E., Lassila, J, Teräsvirta, T., 1996. Short-term forecasting of industrial production with business survey data : experience from Finland's great depression, *International Journal of Forecasting*, vol. 12, pp. 373-381
- Kirby, H.R., Watson, S.M., Dougherty, M.S., 1997. Should we use neural networks or statistical models for short-term motorway traffic forecasting ?
- Klir, G.J., Yuan, B., 1995. *Fuzzy sets and fuzzy logic : Theory and applications*, Prentice Hall, London, UK.
- Koehl, L., Zeng, X., Vasseur, C., 1998. A method for optimizing fuzzy membership functions, *Studies in Informatics and Control*, vol. 7, no. 2, pp. 143-154.
- Koksalan, M., Erkip, N., Moskowitz, H., 1999. Explaining beer demand : a residual modeling regression approach using statistical process control, *International Journal of Production Economics*, vol. 58, pp. 256-276.
- Ku, K.W.C., Mak, M.W., Siu, W.C., 1999. Adding learning to cellular genetic algorithms for training recurrent neural networks, *IEEE Transactions on Neural Networks*, vol. 10, no. 2, pp. 239-251.
- Kuan, C.M., Liu, T., 1995. Forecasting exchange rates using feedforward and recurrent neural networks, *Journal of Applied Econometrics*, vol. 10, pp. 347-364.
- Kuo, R.J., and Xue, K.C. 1998. A decision support system for sales forecasting through fuzzy neural networks with asymmetric fuzzy weights, *Decision Support Systems*, vol. 24, pp. 105-126.
- Kuo, R.J., and Xue, K.C. 1999. Fuzzy neural networks with application to sales forecasting, *Fuzzy Sets and Systems*, vol. 108, pp. 123-143.
- Kuo, R.J. 2001. A sales forecasting system based on fuzzy neural network with initial weights generated by genetic algorithm, *European Journal of Operational Research*, vol.129, pp. 496-517.

- Lapedes, A., Farber, R., 1987. Nonlinear signal processing using neural networks : prediction and system modeling, Technical Report LA-UR-87-2662, Los Alamos National Laboratory, Los Alamos, NM.
- Lee, H.L., Sasser, M.M. , 1995. Product universality and design for supply chain management, *Production Planning and Control*, vol. 6, n° 3, pp. 270-277.
- Lewandosky, R., 1983. *La Prévision à court terme*, Edition Dunod, Paris.
- Liang, R.H., Cheng, C.C., 2002. Short-term load forecasting by a neuro-fuzzy based approach, *International Journal of Electrical Power & Energy Systems*, vol. 24, no. 2, pp. 103–111.
- Lin, C.T., Lee, C.S.G., 1994. Reinforcement structure/parameter learning for neural-network-based fuzzy logic control systems, *IEEE Transactions on Fuzzy Systems*, vol. 2, pp. 46-63.
- Lin, C.J., Lin, C.T., 1997. An ART-based fuzzy adaptive learning control network, *IEEE Transactions on fuzzy systems*, vol. 5, no. 4, pp. 477-496.
- Linstone, H.A., Turoff, M., 1975. *The delphi method : techniques and applications*, Edition Addison-Wesley, London.
- Little, J.D.C, 1998. Integrated measures of sales, merchandising, and distribution, *International Journal of Research in Marketing*, vol. 15, pp. 473-485.
- Ljung, L., 1987. *System Identification - Theory for the User*, Prentice Hall, Englewood, Cliffs, N.J..
- Makridakis, S, Andersen, A., Carbone, R., Fildes, R, Hibon, M., Lewandowski, J., Newton, E., Parzen, E., Winkler, R., 1982. The accuracy of extrapolation (time series) methods : results of a forecasting competition, *Journal of Forecasting*, vol. 1, pp. 111-153.
- Makridakis, S, Winkler, R., 1989. Sampling distribution of post-sample forecasting errors, *Applied Statistics*, vol. 38, pp. 331-342.
- Makridakis, S, 1993. Accuracy measures : theoretical and practical concerns, *International Journal of Forecasting*, vol. 9, pp. 527-529.
- Makridakis, S, 1996. Forecasting : its role and value for planning and strategy, *International Journal of Forecasting*, vol. 12, pp. 513-537.
- Malinvaud, E., 1983. *Leçons de théorie microéconomiques*, Edition Dunod, Paris, France.
- Mamdani, E.H., Assilian, S., 1975. An Experiment in Linguistic Synthesis with Fuzzy Logic Controller, *International Journal of Man - Machine Studies*, vol. 7, no. 1, pp. 1-13.
- Mangeas, M., 1997. Propriétés statistiques des modèles paramétriques non linéaires de prévision des séries temporelles : applications aux réseaux de neurones à propagation directe, Thèse de l'université Paris I.
- Maslow, A., 1970. *Motivations and personality*, Edition Harper & Row, USA.
- Massy, W.F., 1969. Forecasting the demand for new convenience products, *Journal of Marketing Research*, pp. 405-413.
- Mastorocostas, P.A., Theocharis, J.B., Kiartzis, S.J., Bakirtzis, A.G., 2000. A hybrid fuzzy modeling method for short-term load forecasting, *Mathematics and Computers in Simulation*, vol. 51, pp. 221-232.

- Mastorocostas, P.A., Theocharis, J.B., 2000b. FUNCOM : A constrained learning algorithm for fuzzy neural networks, *Fuzzy Sets and Systems*, vol. 112, no. 1, pp. 1–26.
- Mastorocostas, P.A., Theocharis, J.B., Petridis, V.S., 2001. A constrained orthogonal least-squares method for generating TSK fuzzy models : Application to short-term load forecasting, *Fuzzy Sets and Systems*, vol. 118, no. 2, pp. 215–233.
- Mc Cullough, B., 1998. Benchmarking Econometric Packages, *Journal of Applied Econometrics*, forthcoming.
- Mélard, G., 1990. *Méthodes de Préviation à Court Terme*, Edition. Ellipses, Bruxelles.
- Nguyen, D., Widrow, B., 1990. Improving the Learning Speed of 2-layer Neural Networks by Choosing Initial Value of the Adaptive Weights, *Proceeding of International Joint Conference on Neural Networks*, vol. 3, pp. 21-26.
- Mitra, P., Mitra, S., Pal, S.K., 2000. Staging of cervical cancer with soft computing, *IEEE transactions on biomedical engineering*, vol. 47 , no 7 , pp. 934 – 940.
- Mori, H., Kobayashi, H., 1996. Optimal fuzzy inference for short-term load forecasting, *IEEE Transactions on Power Systems*, vol. 11 , no 1 , pp. 390 – 396.
- Morwitz, V.G., 2001. Methods for forecasting from intentions data, in Armstrong J.S., *Principles of forecasting – A handbook for researchers and practitioners*, Kluwer Academic Press, Norwell, MA.
- Na, M.G., 1998. Design of a genetic fuzzy controller for nuclear steam generator water level control, *IEEE Transactions on Nuclear Sciences*, vol. 45, no. 4, pp. 2261-2271.
- Nam, K., Schaefer, T., 1995. Forecasting international airline passenger traffic using neural networks, *Logistics and Transportation*, vol. 31, no. 3, pp. 239-251.
- Nasr, G.E., Badr, E.A., Younes, M.R., 2002. Neural networks in forecasting electrical energy consumption: univariate and multivariate approaches, *International Journal of Energy Research*, vol. 26, no. 1, pp. 67-78.
- Nelles, O., Fisher, M., Muller, B., 1996. Fuzzy rules extraction by a genetic algorithm and constrained nonlinear optimization of membership functions, *International IEEE Conference on Fuzzy Systems FUZZ-IEEE*, New Orleans, USA.
- Nikraves, M., Adams, R.D., Levey, R.A., 2001. Soft computing : tools for intelligent reservoir characterization (IRESC) and optimum well placement (AWP), *Journal of Petroleum Science & Engineering*, vol. 29, no. 3-4, pp. 239-262.
- Oakley, N., 1994. Two scientific applications of genetic programming : stack filter and non-linear equation fitting to chaotic data, Edition Kinnear, K.E., Cambridge, Mass : MIT Press, pp. 369-389.
- Ord, K., 1996. Automatic forecasting, *The American Statistician*, vol. 50, no. 1, pp. 88-93.
- Ozaki, T., Oda, H., 1978. Non-linear time series model identification by Akaike's information criterion, in *Information and Systems*, pp. 83-91, Pergamon.
- Pagny, F., 1971. *La stratégie des produits dans l'entreprise*, Dunod, Paris, pp. 86-90.
- Pankratz, A., 1991. *Forecasting with dynamic regression models*, Edition J. Wiley & Sons, Wiley Series in Probability and Mathematical Statistics.
- Patterson, D.W., 1996. *Artificial neural networks – Theory and applications*, Prentice Hall.

- Pelliccioni, A., Poli, U., 2000. Use of neural net models to forecast atmospheric pollution, *Environmental monitoring and assessment*, vol. 65, no 1-2, pp. 297-304.
- Petridis, V., Paterakis, E., Kehagias, A., 1998. A hybrid neural-genetic multimodel parameter estimation algorithm, *IEEE Transactions on Neural Networks*, vol. 9, no. 4, pp. 862-876.
- Pokorny, M., Cermak, P., 1997. Fuzzy Models Identification and Tuning using the Genetic Algorithms and Neural Network, *EUFIT'97*, September 8-11, pp. 570-573.
- Poli, I., Jones, R.D., 1994. A neural net model for prediction, *Journal of American Statistical Association*, vol. 89, no. 425, pp. 117-121.
- Portmann, M.C., 1996. Genetic algorithms and scheduling : a state of the art and some propositions, *Proceeding of the Workshop on Production Planning and Control*, Mons, Belgium, September 9-11.
- Poulton, E.C., 1989. Bias in quantifying judgments, Hove : Erlbaum.
- Ram, C., La classification hiérarchique ascendante selon la méthode des voisins réciproques, *Les Cahiers de l'Analyse des Données*, vol. 5, pp. 135-144.
- Ranaweera, D.K., Hubele, N.F., Karady, G.G., 1996. Fuzzy logic for short term load forecasting, *International Journal of Electrical Power & Energy Systems*, vol. 18, no. 4, pp. 215-222.
- Randhawa, S.U., Camargo, M.E., Radharamanan, R., Petry, D.G., 1996. Sales forecasting using time series and neural networks, *Computers & Industrial Engineering*, vol. 31, no 1-2, pp. 421 – 424.
- Remus, W., O'Connor, M., 2001. Neural networks for time-series forecasting, in Armstrong J.S., *Principles of forecasting – A handbook for researchers and practitioners*, Kluwer Academic Press, Norwell, MA, pp. 245-256.
- Rowe, G, Wright, G., 1999. The Delphi technique as forecasting tool : issues and analysis, *International journal of forecasting*, vol. 15, pp. 353-375.
- Rudolph, G., 1994. Convergence analysis of canonical genetic algorithm, *IEEE Transaction on Neural Networks*, vol. , no. , pp. .
- Ruiz-Suarez, J.C., Mayora-Ibarra, O.A., Torres-Jimenez, J., Ruiz-Suarez, L.G., 1995. Short-term ozone forecasting by artificial neural networks, *Advances in Engineering Software*, vol. 23, pp. 143-149.
- Rumelhart, D., Hinton, G., Williams, R., 1986. Learning internal representation by error propagation, *Parallel Distributed Processing 1*, MIT Press, Cambridge.
- Runkler, T.A., 2000. Nonlinear System Identification with Global and Local Soft Computing Methods, *Wissenschaftliche Berichte FZKA*, vol. 6509 , pp. 163 – 176.
- Sakai, H., Nakajima, H., Higashihara, M., Yasuda, M., Oosumi, M., 1999. Development of a fuzzy sales forecasting system for vending machines, *Computers & Industrial Engineering*, vol. 36, no. 2, pp. 427-449.
- Sanders, N.R., Ritzman, L., 1992. The need for contextual and technical knowledge in judgmental forecasting, *Journal of Behavior decision Making*, vol. 5, pp. 39-52.
- Sanders, N.R., 1992b. Corporate forecasting practices in manufacturing industry, *Production and Inventory Management*, vol. 33, pp. 54-57.

- Sanders, N.R., Manrodt, K.B., 1994. Forecasting practices in U.S. corporations : survey results, *Interfaces*, vol. 24, no. 2, pp. 92-100.
- Saruwatari, N., Yomota, A., 1995. Forecasting system of irrigation water on paddy field by fuzzy theory, *Agricultural Water Management*, vol. 28, no. 2, pp. 163–178.
- Says, L.W., 1989. *Pooled time series analysis*, London, Sage Publications.
- Sboui, S., Rabenasolo, R., Jolly-Desodt, A.M., Dewaelle, N., 2001. Optimisation dynamique de la taille des lots d'approvisionnement : application à la filière textile. MOSIM'01, Troyes, France.
- Sboui, S., 2002. Modélisation, simulation et optimisation des approvisionnements au sein de la filière Textile-Habillement-Distribution, Thèse de l'Université des Sciences et Technologies de Lille I, France.
- Schwarz, G., 1978. Estimating the dimensions of a model, *Annals of Statistics*, vol. 6, pp. 461-464.
- Seiter, C., 1998. Plan your business future with Forecast Pro, *PC World*, January.
- Sette, S., Boullart, L., Van Langenhove, L., 2000. Building a rule set for the fiber-to-yarn production process by means of soft computing techniques, *Textile research journal*, vol. 70 , no 5 , pp. 375 – 386.
- Sharda, R., Patil, R.B., 1992. Connectionist approach to time series prediction : an empirical test, *Journal of Intelligent Manufacturing*, vol. 3, pp. 317-323.
- Simpson, P.K., 1996. *Foundations of neural networks*, IEEE Technology Update Series, Neural Networks Theory, Technology, and Applications, Edition Simpson P., New York, pp. 1-22.
- Sivanandam, S.N., Shanmugam, A., Sumathi, S., Usha, K., 2001. Development of soft computing models for data mining, *Indian Journal of Engineering & Materials Sciences*, vol. 8, no. 6, pp. 327-340.
- Sjöberg, J., Zhang, Q., Ljung, L., Benveniste, A., Delyon, B., Glorennec, J.P., Hjalmarsson, H., Judiski, A., 1995. Non-linear black box modeling in system identification : an unified overview, *Automatica*, vol. 31, no. 12.
- Smith, P., Hussein, S., Leonard, D.T., 1996. Forecasting short-term regional gas demand using an expert system, *Expert Systems with Applications*, vol. 10, pp. 265-273.
- Smith, B.L., Williams, B.M., Oswald, R.K., 2002. Comparison of parametric and nonparametric models for traffic flow forecasting, *Transportation Research. Part C, Emerging technologies*, vol. 10, no. 4, pp. 303-321.
- Szpiro, G.G., 1997. Forecasting chaotic time series with genetic algorithms, *Physical review E*, vol. 55, no. 3, pp. 2557-2568.
- Stewart, G., 1998. Prophetable software : business forecasting software is using new ideas in statistics to improve the bottom line, *Byte Magazine*, April.
- Stewart, T.R., 2001. Improving reliability of judgmental forecasts, in Armstrong J.S., *Principles of forecasting – A handbook for researchers and practitioners*, Kluwer Academic Press, Norwell, MA.
- Stock, J.H., Watson, M.W., 1996. Evidence on structural instability in macroeconomic time series relations, *Journal of Business and Economic Statistics*, vol.14, pp.11-30.

- Stuart, S., 1997. An extend review of the X11 ARIMA seasonal adjustment package, *International Journal of Forecasting*, vol. 13, pp. 567-573.
- Sugeno, M., 1985. *Industrial applications of Fuzzy Control*, Elsevier Science Pub. Co..
- Sullivan, J., Woodall, W.H., 1994. A comparison of fuzzy forecasting and Markov modelling, *Fuzzy Sets and Systems*, vol. 64, no. 3, pp. 279–293.
- Sulzberger, S.M., Tschichold-Gürman, N.N., Vestli, S.J., 1993. FUN : optimization of fuzzy rule based systems using neural networks, *IEEE Technology Update Series, Neural Networks Theory, Technology and Applications*, Edition Simpson P., NY, pp. 138-142.
- Sumathi, S., Sivanandam, S., Jagadeeswari, N., 2000. Design of soft computing models for data mining applications, *Indian journal of engineering & materials sciences*, vol. 7, no 3, pp. 107 – 121.
- Suzuki, Y, Itakura, K.I., Saga, S., Maeda, J., 2001. Signal processing and pattern recognition with soft computing, *Proceedings of the IEEE*, vol. 89 , no 9 , pp. 1297 – 1317.
- Tagliaferri, R., Pelosi, N., Ciaramella, A., Longo, G., Milano, M., Barone, F., 2001. Soft computing methodologies for spectral analysis in cyclostratigraphy, *Computers & geosciences*, vol. 27 , no 5 , pp. 535 – 548.
- Takagi, T., Sugeno, M., 1985. Fuzzy identification of systems and its application to modelling and control, *IEEE Transactions on Systems, Man and Cybernetics*, vol. 15, no. 1, pp. 116-132.
- Tang, Z., Almada, C., Fishwick, P.A., 1991. Time series forecasting using neural networks vs Box-Jenkins methodology, *Simulation*, vol. 57, n°. 5, pp. 303-310.
- Tseng, F.M., Tzeng, G.H., Yu, H.C., Yuan, B.J.C., 2001. Fuzzy ARIMA model for forecasting the foreign exchange market, *Fuzzy Sets and Systems*, vol. 118, no. 1, pp. 9–19.
- Thiria, S., Lechevalier, Y, Gascuel, O., Canu, S., 1997. *Statistique et méthodes neuronales*, Edition Dunod, Paris.
- Thomas, P., 1997. *Contribution à l'Identification de Systèmes Non Linéaires par Réseaux de Neurones*, Thèse de l'Université Henry Poincaré, Nancy 1, France.
- Thomassey, S., Vroman, P., Happiette, M., Castelain, J.M., 2001. A Comparative Test of New Mean-Term Forecasting Models Adapted to Textile Items Sales, *Studies in Informatics and Control*, vol. 10, no. 3, pp. 209-225.
- Thomassey, S., Happiette, M., Castelain, J.M., 2002a. Modèle de prévision des ventes à moyen terme avec traitement flou des variables explicatives - Application à la logistique textile, *Journal Européen des Systèmes Automatisés JESA*, vol. 36, no. 8.
- Thomassey, S., Happiette, M., Castelain, J.M., 2002b. An automatic textile sales forecast using fuzzy treatment of explanatory variables, *Journal of Textile and Apparel, Technology and Management JTAM*, Vol. 3, no. 1.
- Thomassey, S., Happiette, M., Castelain, J.M., 2002c. A short term forecasting system adapted to textile distribution, *IPMU 2002*, 8-9 Juillet, Annecy, France, pp. 1889-1893.

- Thomassey, S., Happiette, M., Castelain, J.M., 2002d. Textile items classification for sales forecasting, congrès ESS 2002, 4<sup>th</sup> European Simulation Symposium and Exhibition Simulation in Industry, 23-26 octobre 2002, Dresde, Allemagne.
- Thompson, P.A., 1990. An MSE statistic for comparing forecast accuracy across series', *International Journal of Forecasting*, vol. 6, pp. 219-227.
- Toly Chen, M.J.J., Wang, M.J.J., 1999. Forecasting methods using fuzzy concepts, *Fuzzy Sets and Systems*, vol. 105, no. 3, pp. 339 – 352.
- Tong, H., Lim, K.S., 1980. Threshold autoregression, limit cycles and cyclical data, *Journal of the Royal Statistical Society*, vol. B42, pp. 245-292.
- Tong, H., 1990. *Non-Linear Time Series : A Dynamical System Approach*, Oxford University Press, Oxford.
- Tse, D., Chan, L., 2000. Transonic airfoil design optimization using soft computing methods, *Canadian aeronautics and space journal*, vol. 46 , no 2 , pp. 65 - 73
- Tull, D.S., 1967. The relationship of actual and predicted sales and profits in new-product introductions, *Journal of Business*, vol. 40, pp. 233-250.
- Turkkan, N., Srivastava, N.K., 1995. Prediction of wind load distribution for air-supported structures using neural networks, *Canadian Journal of Civil Engineering*, vol. 22, no. 3, pp. 453-461.
- Tyebjee, T.T., 1987. Behavioral biases in new product forecasting, *International Journal of Forecasting*, vol. 3, pp. 393-404.
- Van Lith, P.F., Betlem, B.H.L., Roffel, B., 2000. Fuzzy Clustering, Genetic Algorithms and Neuro-Fuzzy Methods compared for Hybrid Fuzzy-First Principles Modeling, *ISIAC 2000*, June 11-16, Hawaii, USA.
- Vere, D.J., Griffith, G.R., 1995. Forecasting in Australia lamb industry : the influence of alternative price determination process, *Review of Marketing and Agricultural Economics*, vol. 63, pp. 408-418.
- Vishwakarma, K.P., 1994. A neural network to predict multiple economic time series, in *Proceeding of the IEEE International Conference on Neural Networks*, vol. 6, pp. 3674-3679.
- Vokurka, R.J., Flores, B.E., Pearce, S.L., 1996. Automatic feature identification and graphical support in rule-based forecasting : a comparison, *International Journal of Forecasting*, vol. 12, pp. 495-512.
- Vroman, P., 2000. *Prédiction des séries temporelles en milieu incertain : application à la prévision de vente dans la distribution textile*, Thèse de l'Université des Sciences et Technologies de Lille I, France.
- Vroman, P., Happiette, M., Vasseur, C., 2000b. Design of feedforward neural network model for textile sales forecasting, *WAC / ISIAC 2000*, Fourth bianual World Automation Congress; June 11-16, Hawaï, USA.
- Vroman, P., Rabenasolo, B., Happiette, M., Vasseur, C., 1999. Optimization of a Neural Network Structure for Textile Sales Forecasting, *IMACS/IEEE CSCC'99 International Multiconference*, July 4-8, Athens, Greece.

- Vroman, P., Happiette, M., Vasseur, C., 2001. A Hybrid Neural Model for Mean-Term Sales Forecasting of Textile Items, *Studies in Informatics and Control*, vol. 10, no 2, pp. 149-167.
- Wasserman, P.D., 1989. *Neural computing : theory and practice*, Van Nostrand Reinhold, New York.
- Weeks, E.R., Burgess, J.M., 1997. Evolving artificial neural networks to control chaotic systems, *Physical Review E*, vol. 56, no.2, pp. 1531-1540.
- Weigend, A.S., Huberman, B.A., Rumelhart, D.E., 1992. Predicting sunspots and exchange rates with connectionist networks, in : Castagli, M., Eubank, S., *Nonlinear Modeling and Forecasting* , Addison-Wesley, Redwood City, CA, pp. 395-432.
- Weigend, A.S., Gershenfeld, N.A., 1993. Results of a time series prediction competition at the Santa Fe institute, *IEEE International Conference on Neural Networks*, San Francisco, CA.
- Weiss, A.A., 1986. Arch and bilinear time series models : comparison and combination, *Journal of Business and Economic Statistics*, vol. 4, pp. 59-70.
- White, H., 1992. *Artificial neural networks : approximations and learning theory*, Blackwell, Oxford, UK.
- Willemain, T.R., Smart, C.N., Shockor, J.H., DeSautels, P.A., 1994. Forecasting in intermittent demand in manufacturing : a comparative evaluation of Croston's method, *International journal of forecasting*, vol. 10, pp. 529-538.
- Wilson, R., Sharda, R., 1994. Bankruptcy prediction using neural networks, *Decision Support System*, vol. 11, pp. 545-557.
- Winklhofer, H., Diamantopoulos, A., Witt, S., 1996. Forecasting practice : a review of empirical literature and an agenda for future research, *International journal of forecasting*, vol. 12, pp. 193-221.
- Winters, P.R., 1960. Forecasting sales by exponential weighed moving averages, *Management Science*, vol. 6, pp. 324-342.
- Witt, S.F., Witt, C.A., 1995. Forecasting tourism demand : a review of empirical research, *International journal of forecasting*, vol. 11, pp. 447-475.
- Wittink, D.R., Keil, 2000. Continuous conjoint analysis, in Gustafson, A.H., Huber, F., *Conjoint measurement : methods and applications*, New York, Springer, pp. 411-434.
- Wu, B., 1995. Model-free forecasting for nonlinear time series (with application to exchange rates), *Computational Statistics in Data Analysis*, vol. 19, pp. 433-459.
- Wu, T.P., Chen, S.M., 1999. A new method for constructing membership functions and fuzzy rules from training examples, *IEEE Transactions on Systems, Man and Cybernetics – Part B : Cybernetics*, vol. 29, no. 1, pp. 25-40.
- Xie, X.L., Beni, A., 1995. A validity measure for fuzzy clustering, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 13, no. 8, pp. 841-847.
- Yang, H.T., Huang, C.M., 1998. A new short term load approach using self organizing fuzzy ARMAX models, *IEEE Transactions on Power Systems*, vol. 13, no. 1, pp. 217-225.

- Yao, S.J., Song, Y.H., Zhang, L.Z., Cheng, X.Y., 2000. Wavelet transform and neural networks for short-term electrical load forecasting, *Energy Conversion and Management*, vol. 41, no 18 , pp. 1975 – 1988.
- Yaowen, Y., Chee, K.S., 2000. Fuzzy logic integrated genetic programming for optimization and design, *Journal of Computing in Civil Engineering*, vol. 14, no. 4, pp. 249–254.
- Yokum, T, Armstrong, J.S., 1995. Beyond accuracy : comparison of criteria used to select forecasting methods, *International journal of forecasting*, vol. 11, pp.591-597.
- Yoo, H., and Pimmel, R.L., 1999. Short-term load forecasting using a self-supervised adaptative neural network, *IEEE transactions on Power Systems*, vol. 14 (2), pp. 779-784.
- Yu, H., Liang, W., 2001. Neural network and genetic algorithm-based hybrid approach to expanded job-shop scheduling, *Computers & Industrial Engineering*, vol. 39, no. 3-4, pp. 337–356.
- Zadeh, L.A., 1965. Fuzzy sets, *Information Control*, vol. 8, pp. 338-353.
- Zadeh, L.A., 1994. Soft computing and fuzzy logic, *IEEE Software*, vol. 11, no. 6, pp. 48-56.
- Zadeh, L.A., 1996. The roles of fuzzy logic and soft computing in the conception, design and deployment of intelligent systems, *BT Technol J*, vol. 4, no. 4, pp. 32-36.
- Zhang, X., 1994. Time series analysis and prediction by neural networks, *Optimization Methods and Software*, vol. 4, pp. 151-170.
- Zhang G.B.E.P., Hu M.Y., 1998. Forecasting with artificial neural networks : the state of the art, *International journal of forecasting*, vol. 14, pp.35-62.
- Zilouchian, A., Jafar, M., 2001. Automation and process control of reverse osmosis plants using soft computing methodologies, *Desalination (Amsterdam)*, vol. 135, no. 1-3, pp. 51-59.
- Zimmerman, M.R., 1997. Forecast Pro tabs expert systems, *PC Week*, October 20, no. 58.

## Publications personnelles relatives à l'étude

### Publications dans des revues :

- Thomassey, S., Vroman, P., Happiette, M., Castelain, J.M., 2001. A Comparative Test of New Mean-Term Forecasting Models Adapted to Textile Items Sales, *Studies in Informatics and Control*, vol. 10, no. 3, pp. 209-225.
- Thomassey, S., Happiette, M., Castelain, J.M., 2002. Modèle de prévision des ventes à moyen terme avec traitement flou des variables explicatives - Application à la logistique textile, *Journal Européen des Systèmes Automatisés (JESA)*, vol. 36, no.8.
- Thomassey, S., Happiette, M., Castelain, J.M., 2002. An automatic textile sales forecast using fuzzy treatment of explanatory variables, *Journal of Textile and Apparel, Technology and Management JTAM*, Vol. 3, no. 1.
- Thomassey, S., Happiette, M., Castelain, J.M., A short and mean-term automatic forecasting system - Application to textile logistics, 2<sup>ième</sup> soumission en décembre à la revue European Journal of Operational Research (EJOR).*
- Thomassey, S., Happiette, M., Dewaele, N., Castelain, J.M., A short and mean term forecasting system adapted to textile items sales, soumis en octobre 2001 à la revue Journal of the Textile Institute.*
- Thomassey, S., Happiette, M., Castelain, J.M., Un outil global de prévision des ventes adapté à la distribution textile, Journal Européen des Systèmes Automatisés (JESA), soumis en décembre 2002.*

### Communications dans des congrès internationaux :

- Thomassey, S., Happiette, M., Castelain, J.M., 2002. A short term forecasting system adapted to textile distribution, *IPMU 2002, International Conference on Information Processing and Management of Uncertainty in Knowledge-Based Systems*, 8-9 Juillet, Annecy, France, pp. 1889-1893.
- Thomassey, S., Happiette, M., Castelain, J.M., 2002. Three complementary sales forecasting models for textile distributors, *IEEE SMC'02, International Conference on Systems, Man and Cybernetics*, 6-9 Octobre, Hammamet, Tunisia.
- Thomassey, S., Happiette, M., Castelain, J.M., 2002. Textile items classification for sales forecasting, *congrès ESS 2002, 4<sup>th</sup> European Simulation Symposium and Exhibition Simulation in Industry*, 23-26 octobre 2002, Dresde, Allemagne.

### Communications dans journées technologiques :

- Thomassey, S., Happiette, M., Rabenasolo, B., 2002. Optimiser vos achats et consommations de matières premières, 4<sup>ème</sup> journées technologiques organisées par la société LECTRA les 17 mai, 23 mai, et 31 mai 2002 respectivement à Lyon, Paris, et Cestas.

## TITRE : METHODOLOGIE DE LA PREVISION DES VENTES APPLIQUEE A LA DISTRIBUTION TEXTILE

---

### RESUME

La concurrence et la mondialisation impliquent une gestion très précise de la production et des approvisionnements des acteurs de la filière Textile-Habillement-Distribution. Face aux contraintes liées à la fabrication et à la distribution des produits (délai d'obtention relativement long et durée de vie courte des articles, ...), une telle organisation nécessite un système de prévision des ventes adapté aux incertitudes du marché et aux besoins du distributeur. Le caractère incertain des ventes est caractérisé par l'influence de nombreuses variables explicatives difficilement contrôlables et identifiées. Le distributeur doit s'appuyer sur des prévisions à moyen terme (horizon : une saison) afin d'anticiper sa production et ses premiers approvisionnements. Le réajustement de la prévision à court terme (horizon : une à trois semaines) est également nécessaire afin de corriger la planification des réassorts, tout au long de la saison.

De nombreux modèles de prévision existent. Cependant, ils sont généralement inadaptés au contexte textile. En effet, leur capacités d'apprentissage et de modélisation sont souvent limitées sur les historiques courts et perturbés des ventes textiles. L'interprétation et l'intervention de l'utilisateur sont également souvent compliquées avec les modèles classiques.

Ainsi, nous proposons un système de prévision, constitué de plusieurs modèles qui abordent des prévisions sur divers horizons et à différents niveaux d'agrégation des ventes. Ce système est basé sur des techniques issues du "soft computing" telles la logique floue, les réseaux de neurones ou les procédures évolutionnistes, autorisant le traitement de données incertaines.

Les performances de nos modèles sont ensuite évaluées et analysées sur un jeu de données réelles provenant d'un grand distributeur textile.

Enfin, dans le cadre d'un projet nommé AIDE financé par le ministère de l'économie, des finances et de l'industrie, ce système de prévision s'intègre dans un outil d'aide à la décision à destination de chacun des acteurs de la filière textile.

---

## TITLE : SALES FORECASTING METHODOLOGY APPLIED TO THE TEXTILE DISTRIBUTION

---

### ABSTRACT

Competition and globalisation imply a very accurate production and sourcing management of the Textile-Apparel-Distribution network actors. Face to the production and distribution constraints of the products (lead time relatively long and short lifetime of the items, ...), such an organization requires a sales forecasting system adapted to market uncertainties and distributor needs. The uncertain character of the sales is characterized by the influence of many not easily controllable and identified explanatory variables. The distributor must take into account mean-term forecasts (horizon : one season) in order to anticipate its production and its first provisioning. The readjustment of the short-term forecast (horizon: one to three weeks) is also necessary in order to correct the planning of the replenishments, throughout the season.

Many forecasting models exist. However, they are generally unsuited to the textile context. Indeed, their capacities of training and modelling are often limited for the reduced and disturbed historical sales data. The user understanding and intervention are also often complicated when using traditional models.

Thus, we propose a forecasting system, composed of several models which perform forecasts on various horizons and at different sales aggregation levels. This system is based on techniques resulting from soft computing such fuzzy logic, neural networks or the evolutionary procedures, authorizing the processing of uncertain data.

Performances of our models are then evaluated and analysed on real data from a important textile distributor. Lastly, within the framework of a project called AIDE, this forecasting system is integrated in a decision-making aid tool for each actor of the textile network.

---

**DISCIPLINE :** Productique – Automatique et Informatique Industrielle

---

**MOTS-CLES :** Prévision des ventes, Prédiction des séries temporelles, Soft computing, Logistique de la filière Textile-Habillement-Distribution, Logique floue, Réseau de neurones artificiel, Algorithmes évolutionnistes

---

**KEY-WORDS :** Sales forecasting, Time series prediction, Soft computing, Textile-Apparel-Distribution network logistics, Fuzzy logic, Artificial neural network, Evolutionary algorithm

---

LABORATOIRE GEMTEX-ENSAIT  
<http://www.ensait.fr>  
INSTITUT FRANÇAIS DU TEXTILE ET DE L'HABILLEMENT  
<http://www.ifth.org>

9, rue de l'ermitage – BP 30329  
F-59056 ROUBAIX Cedex 01  
2, rue de la recherche  
59650 VILLENEUVE D'ASCQ Cedex