

THESE

Présentée à

L'UNIVERSITE DE BATNA

Pour Obtenir le titre de

DOCTEUR EN SCIENCE

Spécialité

Electrotechnique

Option

Machines électriques

Par

Mordjaoui Mourad

(Ingénieur 1992 Université De Sétif, Magister 1998 Université De Skikda)

Intitulé de la thèse :

MODELISATION DES EFFETS ELECTROMAGNETIQUES

« Apport de la logique floue et neuro-floue »

Thèse soutenue le : 26 Juin 2008

Devant le jury composé de

Boudjema Bouzid	Professeur	Université De Skikda	Président
Chabane Mabrouk	Professeur	Université De Batna	Rapporteur
Azoui Boubakeur	Professeur	Université De Batna	Examineur
Dib Djallel	Maître de Conférence	Université De Tebessa	Examineur
Boukhetache Sebti	Maître de Conférence	Université De Batna	Examineur
Benalla Hocine	Professeur	Université De Constantine	Examineur

*A la mémoire de mes parents
A ma femme, mon fils Alla eddine et mes filles Nada et Hadil
à mes frères et soeurs
et à tous ceux que j'aime*

*1- " Pour faire de grandes choses, il ne faut pas être
un si grand génie, il ne faut pas être au-dessus des
hommes, il faut être avec eux"*

*2-"Un homme qui enseigne peut devenir aisément
opiniâtre, parce qu'il fait le métier d'un
homme qui n'a jamais tort"*

Montesquieu

Avant-Propos

L'ensemble des travaux présentés dans ce mémoire a été effectué au Laboratoire de recherche sur la physico-chimie des surfaces et interfaces de l'université du 20 Août 1955 de Skikda

*Monsieur **Chabane Mabrouk**, Professeur à l'Université de Batna, a inspiré et dirigé ce travail avec efficacité. Je lui exprime ma reconnaissance pour la confiance qu'il m'a témoignée. Son expérience de recherche, ses conseils, ses encouragements m'ont été très précieux et m'ont permis de bien mener mon travail.*

*Je remercie Monsieur **Boudjema Bouzid**, Professeur à l'université de Skikda de l'intérêt qu'il a porté à ce travail. Il m'a bénéficié de ces connaissances. Ces suggestions ont été déterminantes pour l'interprétation de mes résultats. Qu'il trouve ici l'expression de mes plus vifs remerciements d'avoir accepté de présider le jury.*

*Je tiens aussi à exprimer ma profonde gratitude à Monsieur **Azoui Boubakeur** Professeur à l'université de Batna, d'avoir accepté d'être membre du jury malgré ses lourdes tâches administratives. Je l'en remercie.*

*J'exprime ma profonde reconnaissance à Monsieur **Benalla Hocine**, Professeur à l'université de Constantine, **Boukhetache Sebti**, Maître de conférence à l'université de Batna et à Monsieur **Dib Djalal**, Maître de conférence à l'université de Tebessa, pour l'intérêt qu'ils ont bien voulu porter à ce travail en acceptant de l'examiner et d'en être rapporteurs.*

*Que tous les membres, collègues et amis du LRPCSI trouvent ici le témoignage de mon amitié et de ma reconnaissance, en particulier Monsieur le Professeur **Meftah Ali** directeur du laboratoire. Qu'ils trouvent ici l'expression de mes vifs remerciements.*

Enfin, je ne saurais terminer cet avant-propos sans remercier toute ma famille, qui m'a accompagné tout au long de mes études par son amour inconditionnel et son soutien constant.

Keywords:

Preisach hysteresis model, dynamic behaviour, magnetic core, neural network, Fuzzy logic, Neuro-fuzzy systems.

Abstract:

Artificial intelligence is an important area for modelling the dynamic behaviour of systems. In this work we have developed many models of hysteresis for ferromagnetic material. The first one is based on neural network capability for functions approximations. However, the identification of the scalar model is a simple training method on measured data. Our challenge of simulations is to predict the behaviour of material, but atomic level and the microscopic behaviour are not in the focus of electrical engineers.

We have also successfully developed, implemented and tested a many models of dynamic hysteresis from measured data using three different methods of fuzzy classifications area. The outputs of proposed models are closely approximates the required hysteresis cycle.

The adaptive Neuro-fuzzy inference system (ANFIS) has been applied with success in order to obtain a dynamical model of hysteresis. It has been used to model the hysteresis curve versus frequency. The identification problem of ANFIS hysteresis model can be solved by means of the knowledge of the experimental data. The proposed ANFIS model combined the neural network adaptive capabilities and the fuzzy logic qualitative approach; it can restore the dynamical behaviour of magnetic material with a little RMS error. Finally, a comparison between the ANFIS model and the dynamical Preisach Model is shown; an interesting aspect is that the ANFIS model computational time is smaller of the one required by the dynamical Preisach model.

The proposed models are an alternative and less complicated approach in determining the magnetic properties of ferromagnetic materials with good accuracy. The collection of well-distributed, sufficient, and accurately measured input data is the basic requirement to obtain an accurate model.

الكلمات الأساسية

نموذج برايزك للدارة التخلفية، السلوك الديناميكي، المواد المغناطيسية، الشبكات العصبونية، المنطق الغامض، الأنظمة الهجينة.

ملخص البحث

في هذه الأطروحة، تطرقنا إلى عدة طرق جديدة لتمثيل الدارة التخلفية للمواد المغناطيسية باستعمال الذكاء الصطناعي الذي يمثل احد المجالات الهامة لتمثيل السلوك الديناميكي للنظم. أول تمثيل يستند إلى الشبكات العصبونية ووظائفها التقريبية. إن تحديد النموذج العصبوني يتم عن طريق التدريب من خلال البيانات. إن التحدي الذي يواجهنا هو التنبؤ لسلوك المواد عن طريق المحاكاة علماً أنّ المستوى الذري و السلوك المجهرى ليس من اهتمامات المهندس الكهربائي.

لقد نجحت أيضاً في وضع، تنفيذ واختبار العديد من النماذج الديناميكية للدارة التخلفية باستخدام ثلاثة طرق مختلفة باستعمال المنطق الغامض. نواتج النماذج المقترحة بشكل وثيق تقارب الدارات التخلفية المقاسة.

تمّ تطبيق كذلك نظام هجين **Anfis** يستعمل محاسن الشبكات العصبونية ومحاسن المنطق الغامض بنجاح لتمثيل السلوك الحركي بدلالة التواتر للمواد المغناطيسية المستعملة في مجالات الهندسة الكهربائية. إنّ تحديد خصائص الشبكة يتم عن طريق وسائل المعرفة التجريبية الرئيسية للمادة و خاصة القيم الناتجة عن التجارب. النظام المقترح و باستعماله لقدرات الشبكات العصبونية و المنطق الغامض النوعي يمكنه محاكاة السلوك الديناميكي للمواد بخطأ نسبي صغير جداً و في وقت سريع مقارنة بنموذج الفيزيائي الألماني برايزك.

النماذج المقترحة هي بديل أقل تعقيداً ونهج في تحديد الخصائص المغناطيسية للمواد المغناطيسية الحديدية مع قدر جيد من الدقة يتناسب و دقة البيانات المدخلة.

Mots clés :

Modèle d'hystérésis de Preisach, comportement dynamique, pièces ferromagnétiques, réseaux de neurones, logique floue, systèmes neuro-flous.

Résumé

L'intelligence artificielle est un domaine important pour la modélisation du comportement dynamique des systèmes. Dans ce travail, nous avons développé de nombreux modèles d'hystérésis des matériaux ferromagnétiques. Le premier est fondé sur la capacité d'approximation des fonctions des réseaux de neurones. Cependant, l'identification du modèle scalaire est une simple méthode d'apprentissage sur les données mesurées. Notre défi est la simulation du comportement des matériaux utilisés dans le domaine du génie électrique, les niveaux atomiques et le comportement au niveau microscopique ne sont pas au centre de notre intérêt

Nous avons également développé avec succès plusieurs modèles dynamiques de l'hystérésis à partir de données mesurées en utilisant trois différentes méthodes de classification floue. Les résultats des modèles proposés restituent parfaitement les cycles d'hystérésis mesurés.

Nous avons développé un modèle d'hystérésis dynamique neuro-flou adaptative basé sur le système Anfis. Le modèle proposé a été validé par les résultats obtenus par le modèle du physicien allemand Preisach. Le temps de calcul du modèle ainsi que l'erreurs étaient minimales.

Les modèles proposés sont une autre approche moins compliquée pour la détermination des propriétés magnétiques des matériaux ferromagnétiques avec une bonne précision. L'exactitude des données mesurées utilisées pour l'apprentissage est la seule condition de base pour obtenir un modèle précis.

Table des matières

Liste des figures	
Liste des tableaux	
Introduction	01

Chapitre 1 : Physique du magnétisme

1.1 Introduction	04
1.1.1 Champ magnétique	04
1.1.2 Aimantation et moment magnétique	05
1.1.3 Moments magnétique d'électron. Origine du magnétisme	06
1.1.3.1 Description classique	06
1.1.3.1.1 Moment magnétique orbital	06
1.1.3.1.2 Moment magnétique du spin	06
1.1.3.1.3 Moment magnétique total	07
1.1.3.2 Description quantique	07
1.1.3.2.1 Nombre quantique principal (n)	07
1.1.3.2.2 Nombre quantique secondaire du moment angulaire orbital (l) ou azimutal	07
1.1.3.2.3 Nombre de Spin (s)	07
1.1.3.2.4 Nombre quantique du moment angulaire total (j)	08
1.1.3.2.5 Moments magnétiques quantiques	08
1.1.4 Types des matériaux magnétiques	09
1.1.4.1 Diamagnétisme	10
1.1.4.2 Paramagnétisme	10
1.1.4.3 Antiferromagnétique	11
1.1.4.4 Ferrimagnétisme	12
1.1.4.5 Ferromagnétisme	12
1.2 Théorie du ferromagnétisme	14
1.2.1 Processus d'aimantation	15
1.2.1.1 Structure du matériau et hypothèse des domaines magnétiques (P.Weiss 1907)	15
1.2.1.2 Aimantation	16
1.2.1.3 Phénomène d'hystérésis	18
1.2.1.4 Perméabilité magnétique	20
1.2.1.5 Hystérésis magnétique en régime quasi-statique	22
1.2.1.5.1 Description de l'hystérésis par une fonction d'opposition	22
1.2.1.5.2 Origine des variations de la fonction d'opposition	25
1.2.1.6 -Phénomène d'hystérésis dynamique	27
1.2.1.7 Reptation des cycles	30
1.3 Conclusion	31

Chapitre 2: Modèles d'hystérésis magnétiques

2.1 Introduction	32
2.2 Modèles d'hystérésis analytiques	32
2.2.1 Modèle de l'astroïde Stoner-Wohlfarth	37
2.2.2 Modèle de Preisach-Mayergoyz	37
2.2.3 Modèle de Jiles-Atherton	38
2.2.4 Modèle de Amir Nourdine	39
2.3 Hystérésis dynamique	41
2.3.1 Modèle de Preisach-Bertotti	41
2.3.2 Modèle de Raulet-Masson	42
2.3.3 Modèle de Kedous-Chevalier (LS)	42
2.3.4 Modèle de Jiles-Szczyglowski	43
2.3.5 Modèle de Kuczmann basé sur des techniques intelligentes	43
2.4 Modèle de Preisach	44
2.4.1 Principe du modèle	44
2.4.1.1 Définition	44
2.4.1.2 Interprétation géométrique	45
2.4.2 Propriétés du modèle	48
2.4.2.1 Effacement partiel	48
2.4.2.2 Congruence des cycles mineurs	49
2.4.2.3 Domaine d'application	49
2.4.3 Méthodes d'identification	49
2.4.3.1 Utilisation des courbes de renversement	50
2.4.3.1.a Définition des courbes de renversements	50
2.4.3.1.a.b Détermination de $P(a,\beta)$	50
2.4.3.1.a.c Formule explicite de $M(t)$	51
2.4.3.2 Méthode de Biorci et Pescetti	52
2.4.3.3 Choix d'une fonction à priori	54
2.4.3.4 Etude du modèle de Preisach avec une fonction analytique	55
2.4.3.4.a Fonction de distribution unitaire	55
2.4.3.4.b Fonction de distribution Lorentzienne	55
2.4.3.4.c Détermination du cycle d'hystérésis	57
2.5 Conclusion	60

Chapitre 3 : Logique floue et systèmes Neuro-flous

3.1 Introduction	61
3.2 Historique et définition	61
3.2.1 Degré d'appartenance	62
3.2.2 Définitions et notions sur les ensembles flous	62

3.2.2.1	Définition d'un ensemble flou	62
3.2.2.2	Support d'un ensemble flou	63
3.2.2.3	Noyau d'un ensemble flou	63
3.2.2.4	Hauteur d'un ensemble flou	63
3.2.2.5	Cardinal d'un ensemble flou	63
3.2.3	Opérations sur les ensembles flous	64
3.2.3.1	Égalité	64
3.2.3.2	Inclusion	64
3.2.3.3	Intersection	64
3.2.3.4	Union	64
3.2.3.5	Propriétés de l'union et l'intersection	65
3.2.3.6	Complément d'un sous-ensemble flou	65
3.2.3.7	Propriétés du complément d'un sous-ensemble flou	65
3.2.3.8	Propriétés des opérateurs sur les ensembles flous	65
3.2.4	Coupe de niveau α ou α - coupe	66
3.2.5	Sous-ensembles flous convexes	66
3.2.6	Produit cartésien de sous-ensemble flou	66
3.2.7	Projection d'un sous-ensemble flou	66
3.2.8	Normes et conormes triangulaires	67
3.3	Logique floue et approximation des fonctions	68
3.4	Apprentissage des systèmes flous	68
3.5	Intégration Neuro-floue	69
3.6	Définition du système neuro-flou	70
3.7	Avantages et inconvénients de la logique floue et des réseaux de neurones	71
3.8	Méthodes et combinaisons Neuro-Floues	72
3.9	Systèmes Neuro-Flous hybrides intégrés	75
3.9.1	Systèmes Neuro-Flous intégrés type Mamdani	75
3.9.2	Systèmes neuro-flous intégrés type Takagi-Sugeno	77
3.9.3	Système ANFIS (<i>Adaptive-Network-based Fuzzy Inference System</i>)	79
3.10	Commentaires	82
3.11	Conclusion	82

Chapitre 4 : Modélisation de l'hystérésis par les réseaux de neurones

4.1	Introduction	83
4.2	Historique	84

4.3 Les réseaux de neurones artificiels	84
4.3.1 Modèle de neurone	85
4.3.2 Modèles des connexions	86
4.3.2.1 Les connexions directes	86
4.3.2.2 Les connexions récurrentes	86
4.3.3 Règles d'apprentissage	87
4.3.3.1 Type d'apprentissage	88
4.3.3.2. Quelques règles d'apprentissage	88
4.4 Approximation de fonction par réseaux de neurones	89
4.5 Perceptron multicouches	90
4.5.1 Introduction	90
4.5.2 Architecture et principe	90
4.5.3 Apprentissage	91
4.5.4 Algorithme	91
4.5.5 Quelques aspects pratiques	92
4.5.5.1. Choix du réseau	92
4.5.5.2. Test d'arrêt	92
4.5.5.3 Choix du pas d'adaptation	92
4.6 Evaluation du perceptron multicouche	93
4.7 Modélisation de l'hystérésis magnétique par une Approche neuronale	93
4.7.1 Modèle développé par Dimitre makaveev (Dimitre et al, 2003)	93
4.7.2 Modèle neuronal d'hystérésis proposé	96
4.8 Conclusion	99

Chapitre 5 : Identification floue de l'hystérésis magnétique dynamique à partir des données mesurées

5.1 Introduction à l'identification des systèmes	100
5.1.1. Méthodologie d'identification floue	101
5.1.2. L'identification basée sur des données mesurées	101
5.2 Groupage des données	101
5.3 Algorithmes de groupage	102
5.3.1 Groupage flou	102
5.3.2 Techniques de groupage	102
5.3.2.1 Méthodes statiques d'adaptation	102
5.3.2.2 Méthodes dynamiques d'adaptation	102

5.4 Méthodes de coalescence floue	103
5.4.1. Notation et Concepts de base	103
5.4.2 Méthode des c-moyennes floues (FCM)	104
5.4.3 Méthode de Gustafson-Kessel (GK)	107
5.4.4 Méthode de Gath et Geva (GG)	114
5.4.5 Méthode Expertation-Maximization	122
5.5 Evaluation de la qualité de l'approximation et validation du Modèle flou	132
5.6 Critères de validations du nombre de clusters	136
5.6.1 <i>Hypervolume flou (CHF)</i>	137
5.6.2 <i>Coefficient de partition (PC)</i>	137
5.6.3 <i>Entropie de classification (CE)</i>	137
5.6.4 <i>Index de partition (SC)</i>	138
5.6.5 <i>Index de séparation (S)</i>	138
5.6.6 <i>Index de Xie et Beni (XB)</i>	138
5.6.7 <i>Index de Dunn (DI) et (ADI)</i>	139
5.7 Validation du nombre de clusters	140
* Validation du nombre de clusters pour la méthode GG	140
* Validation du nombre de clusters pour la méthode EM	141
* Validation du nombre de clusters pour la méthode GK	142
* Discussion des résultats	
5.8 validation du modèle	143
5.9 Conclusion	149

Chapitre 6 : Développement de modèles d'hystérésis neuro-flous

6.1 Introduction	151
6.2 Modèle d'hystérésis de Jiles-Atherton	152
6.2.1 Formulation	152
6.2.2 Identification des paramètres	153
6.2.2.1 Susceptibilité anhystérétique:	153
6.2.2.2 Susceptibilité initiale	153
6.2.2.3 Coercivité	153
6.2.2.4 Rémanence	153
6.3 Système neuro-flou à inférence adaptative (ANFIS)	154
6.3.1 Présentation d'ANFIS	154
6.3.2 Algorithme d'apprentissage de ANFIS	157
6.4 Approximation de l'hystérésis magnétique	159

6.4.1 Simulation	159
6.4.2 Modèle neuro-flou proposé	160
6.4.3 Résultats	166
6.5. Développement d'un modèle dynamique neuro-flou	167
6.5.1 Modèle de Preisach	167
6.5.2 Comportement dynamique du phénomène d'hystérésis	168
6.5.3 Résultats de simulation numérique	170
6.5.4 Discussion des résultats et conclusion	176
Conclusion générale	177
Références bibliographiques	179

Liste des figures

Figure 1.1 Moment magnétique	5
Figure 1.2 Diamagnétisme	10
Figure 1.3 Paramagnétisme	11
Figure 1.4 Antiferromagnétisme	12
Figure 1.5 ferrimagnétisme	12
Figure 1.6 Ferromagnétisme	13
Figure 1.7 Courbe de première aimantation	14
Figure 1.8 Structure cristalline du Fer	15
Figure 1.9 Orientation des dipôles magnétiques de la paroi	16
Figure 1.10 Processus d'aimantation et la courbe de première aimantation correspondante	18
Figure 1.11 -a- Cycle d'hystérésis, -b- Champ coercitif en fonction de la valeur maximale du champ magnétique.	19
Figure 1.12: Différents types de perméabilités, perméabilité maximale (μ_m), perméabilité initiale (μ_i), perméabilité incrémentale (μ_Δ).	21
Figure 1.13 Paroi plane sous l'effet d'un champ magnétique	22
Figure 1.14: Energie E_R en fonction de la position de la paroi	23
Figure 1.15: Aimantation obtenue par le déplacement d'une paroi soumise à un champ H pour $R(x)$ donnée	24
Figure 1.16 : Mouvement de la paroi en présence de trois impuretés: (a) configuration initiale (b) variations de E_R avec la position x de la paroi (c) évolution de la fonction d'opposition R avec x et variation d'aimantation ΔM générée en fonction du champ H appliqué.	26
Figure 1.17 : Variation du champ critique H_{CP} et du champ H en fonction de la position x de la paroi : -a- en quasi-statique -b- à fréquence moyenne -c- à fréquence élevée.	27
Figure 1.18 : Description d'un cycle pour une fréquence élevée : -a- Variation du champ critique H_{CP} et du champ appliqué H en fonction de la position x de la paroi -b- Variation d'aimantation correspondante en fonction du champ H appliqué.	30
Figure 1.19 : Evolution de la paroi sur la largeur $2b$ du cadre pour deux fréquences f_1 et f_2 ($f_2 \gg f_1$) : -a- évolution du champ en fonction de x et de f , -b- évolution de $M(H)$ avec f .	30
Figure 1.20 Reptation du cycle d'hystérésis	31
Figure 2.1 Cycle d'hystérésis avec le modèle de Rayleigh	33
Figure 2.2 Courbes de premières aimantations générées par la série polynomiale	33

Figure 2.3 Cycle d'hystérésis par le modèle de type Frolich	34
Figure 2.4 : Le cycle d'hystérésis généré par le modèle de potter.	37
Figure 2.5 : Schéma explicatif des commutateurs et du plan de Preisach	38
Figure 2.6 : Définition de l'hystéron	44
Figure 2.7 : Transducteur de Preisach	45
Figure 2.8 : Triangle de Preisach	46
Figure 2.9 Déplacement vertical de $L(t)$	47
Figure 2.10 Déplacement horizontal de $L(t)$	47
Figure 2.11.a Cycle d'hystérésis et état de déplacement de la frontière $L(t)$ correspondante	47
Figure 2.11.b Evolution de la frontière et effacement partielle de l'histoire	48
Figure 2.12 : Description des cycles mineurs	48
Figure 2.13 : Phénomène de congruence des cycles mineurs	49
Figure 2.14 : Processus d'aimantation	50
Figure 2.15 : Domaines d'intégration de l'aimantation $M(t)$	51
Figure 2.15a : Discrétisation du triangle de Preisach selon la méthode De Biorci et Pescetti	53
Figure 2.16: Triangle de Preisach	55
Figure 2.17 : Distribution de la fonction de Lorentz	56
Figure 2.18 Les contours de la fonction de Lorentz	56
Figure 2.18.a: Etat désaimanté du matériau ferromagnétique	58
Figure 2.18.b : Variation de l'excitation dans le triangle de Preisach	58
Figure 2.19.a : Courbe de première aimantation générée	58
Figure 2.19.b : Courbe de première aimantation générée par une fonction de distribution Lorentzienne	58
Figure 2.20.a : Etat de saturation positive du matériau Ferromagnétique	59
Figure 2.20.b : Evolution des frontières de Preisach pour une excitation décroissante	59
Figure 2.21.a Courbe descendante générée par une distribution unitaire	59
Figure 2.21.b Courbe descendante générée par une Fonction de distribution Lorentzienne	59
Figure 2.22.a : Cycle d'hystérésis généré par une distribution unitaire	60
Figure 2.22.b : Cycle d'hystérésis généré par une distribution Lorentzienne	60
Figure 3.1 Support, hauteur, noyau et α -coupe d'un ensemble flou.	62
Figure 3.2 Le système neuro-flou	71
Figure 3.3 Exemple de réseau de neurones pour la commande floue	73
Figure 3.4 Exemple d'association en série d'un réseau de neurone et d'un système flou	74
Figure 3.5 Exemple d'association en parallèle d'un réseau de neurone et d'un système flou.	74
Figure 3.6 Système neuro-flou type Mamdani	76
Figure 3.7 Système neuro-flou type Takagi-Sugeno	78
Figure 3.8 système neuro-flou du type ANFIS	80
Figure 3.9 Architecture ANFIS réalisant le système d'inférence floue de Tsukamoto	81
Figure 3.10 Raisonnement flou de Tsukamoto	81
Figure 4.1 Le système neuro-flou	85
Figure 4.2 Modélisation du neurone	86
Figure 4.3 Structure d'un réseau de neurones dont les connexions sont récurrentes.	87
Figure 4.4 Réseau à connexions totales	87
Figure 4.5 Réseau à connexions partielles	87
Figure 4.6 Structure du perceptron multicouches	90

Figure 4.7 Notations: (a) $B(t)$ et $H(t)$ suivant le plan de lamination ; $B_{\psi,k}^{extr}$ et B_{ψ}^{\max} de l'induction magnétique	94
Figure 4.8 FFNN avec une couche cachée	95
Figure 4.9 Cycle d'hystérésis quasi-statique	97
Figure 4.10 Performance du réseau de neurone	98
Figure 4.11 Cycle généré par le modèle neurone	98
Figure 5.1 Organigramme de la méthode FCM	106
Figure 5.2 Interprétation géométrique de la matrice de covariance floue	108
Figure 5.3 Organigramme de la méthode GK	109
Figure 5.4 Régression GK ($n_u=1, n_y=0, c=2$)	110
Figure 5.5 Régression GK ($n_u=1, n_y=1, c=2$)	110
Figure 5.6 Régression GK ($n_u=2, n_y=1, c=2$)	110
Figure 5.7 Régression GK ($n_u=2, n_y=2, c=2$)	111
Figure 5.8 Régression GK ($n_u=1, n_y=0, c=3$)	111
Figure 5.9 Régression GK ($n_u=1, n_y=1, c=3$)	111
Figure 5.10 Régression GK ($n_u=2, n_y=1, c=3$)	112
Figure 5.11 Régression GK ($n_u=2, n_y=2, c=3$)	112
Figure 5.12 Régression GK ($n_u=1, n_y=0, c=4$)	112
Figure 5.13 Régression GK ($n_u=1, n_y=1, c=4$)	113
Figure 5.14 Régression GK ($n_u=2, n_y=1, c=4$)	113
Figure 5.15 Régression GK ($n_u=2, n_y=2, c=4$)	113
Figure 5.16 Organigramme de la méthode GG	118
Figure 5.17 Résultats de classification par l'algorithme GG	119
Figure 5.18 Régression GG ($n_u=1, n_y=1, c=2$)	119
Figure 5.19 Régression GG ($n_u=2, n_y=1, c=2$)	120
Figure 5.20 Régression GG ($n_u=2, n_y=2, c=2$)	120
Figure 5.21 Régression GG ($n_u=1, n_y=1, c=3$)	120
Figure 5.22 Régression GG ($n_u=2, n_y=1, c=3$)	121
Figure 5.23 Régression GG ($n_u=2, n_y=2, c=3$)	121
Figure 5.24 Régression GG ($n_u=2, n_y=1, c=4$)	121
Figure 5.25 Régression ($n_u=2, n_y=2, c=4$)	122
Figure 5.26 Organigramme de la méthode Expertation-Maximization	126
Figure 5.26.a Résultats de classification par l'algorithme EM	127
Figure 5.27 Régression EM ($n_u=1, n_y=0, c=2$)	127
Figure 5.28 Régression EM ($n_u=1, n_y=1, c=2$)	128
Figure 5.29 Régression EM ($n_u=2, n_y=1, c=2$)	128
Figure 5.30 Régression EM ($n_u=2, n_y=2, c=2$)	128
Figure 5.31 Régression EM ($n_u=1, n_y=0, c=3$)	129
Figure 5.32 Régression EM ($n_u=1, n_y=1, c=3$)	129
Figure 5.33 Régression EM ($n_u=2, n_y=1, c=3$)	129
Figure 5.34 Régression EM ($n_u=2, n_y=2, c=3$)	130
Figure 5.35 Régression EM ($n_u=1, n_y=0, c=4$)	130
Figure 5.36 Régression EM ($n_u=1, n_y=1, c=4$)	130
Figure 5.37 Régression EM ($n_u=2, n_y=1, c=4$)	131
Figure 5.38 Régression EM ($n_u=2, n_y=2, c=4$)	131
Figure 5.39 Cycles d'hystérésis mesurés	132
Figure 5.40 : Critères de validation en fonction du nombre de cluster pour la méthode GG	140
Figure 5.41 : Critères de validation en fonction du nombre de cluster pour la méthode EM	141

Figure 5.42 : Critères de validation en fonction du nombre de cluster pour la méthode GK	142
Figure 5.43 Cycles d'hystérésis validés par les méthodes GK, EM et GG	143
Figure 5.44 Fonctions d'appartenance des antécédents obtenues les méthodes GK, EM et GG	145
Figure 5.45 Pourcentage d'erreur pour chaque cycle des méthodes GK, EM et GG	146
Figure 5.46 RMSE et VAF en fonction du cycle à identifié par les méthodes GK, EM et GG	147
Figure 5.47 Allures des règles obtenues par les trois GK, EM et GG	148
Figure 6.1 Architecture d'ANFIS	155
Figure 6.2: Algorithme D'apprentissage d'Anfis pour l'ajustement de la production des paramètres des règles	158
Figure 6.3 Champ et induction magnétique correspondante en fonction du temps	160
Figure 6.4 Sélection des entrées	161
Figure.6.5 Courbes d'erreur d'apprentissage et de test	161
Figure 6.6 Distribution des données	162
Figure 6.7 Surface d'anfis	162
Figure 6.8 Résultats d'apprentissage d'ANFIS. Système à 2 entrées	163
Figure 6.9 Etapes d'adaptation des paramètres d'ANFIS	164
Figure 6.10 Fonctions d'appartenances initiales et finales des entrées 1 et 2	166
Figure 6.11: Opérateur hystérétique élémentaire	167
Figure 6.12 : Champ coercitif mesuré en fonction de la fréquence	169
Figure 6.13: La fonction de distribution pour $K=2270$, $m=0.02$, $n=0.1$ & $H_c =55$	169
Figure 6.14 Performance d'Anfis	172
Figure 6.15 distribution des données	172
Figure 6.16 Hystérésis dynamique généré par le modèle ANFIS et la courbe d'hystérésis désirée.	173
Figure 6.17 Adaptation des paramètres de Anfis	173
Figure 6.18 Fonctions d'appartenances Initiales et finales. (a) première entrée (b) Deuxième entrée du meilleur modèle.	175

Liste des tableaux

Tableau 3.1 Comparaison entre la logique floue et les réseaux de neurones	72
Tableau 5.1 Résultats d'apprentissage en fonction de la régression et du nombre de clusters.	133
Tableau 5.2 Règles des 03 modèles flous	134
Tableau 5.3 : Centres des antécédents des trois modèles	135
Tableau 5.4 Résultats d'apprentissage et de validation des trois algorithmes	144
Tableau 6.1 Erreur d'apprentissage et d'identification des différents modèles	171
Tableau 6.2 Caractéristiques du modèle Neuro-flou	176

Introduction

Introduction générale

Introduction générale

Le présent travail traite la caractérisation des matériaux magnétiques et en particulier la modélisation du phénomène d'hystérésis magnétique par utilisation des techniques intelligentes.

Les matériaux magnétiques sont des composants de base dans la fabrication des machines électriques où il faut une maîtrise de leur comportement pour répondre aux exigences industrielles. La détermination précise du champ magnétique dans ces dispositifs est une préoccupation de l'électrotechnicien en vue d'une optimisation à la fois économique et technique. Afin d'améliorer les caractéristiques des machines électriques, les outils de simulation numérique s'avèrent particulièrement puissants car ils permettent d'étudier au préalable l'impact du choix des matériaux sur les résultats. L'utilisation de l'outil informatique a facilité l'étude et la résolution des équations aux dérivées partielles complexes (Equations de Maxwell) dans des structures à géométrie compliquée. Ainsi, La méthode des éléments finis est l'une des méthodes les plus utilisées aujourd'hui pour résoudre ces équations. Généralement, cette méthode donne des résultats satisfaisants et en particulier dans les problèmes non-linéaires.

Souvent, le matériau est soumis à des formes d'ondes très diverses imposées par l'alimentation, la géométrie du circuit magnétique, les aimants, les fuites, etc. Les modèles standard sont alors insuffisants pour prédire le comportement du circuit magnétique et l'évaluation préalable au niveau CAO. Les pertes fer restent un problème délicat pour les constructeurs de dispositifs électriques qui utilisent habituellement des formules empiriques et des facteurs correctifs approchés.

Les phénomènes magnétiques et en particulier l'hystérésis ont été la préoccupation des chercheurs du domaine pendant plusieurs décennies. La collaboration du monde scientifique (Physiciens, mathématiciens,...etc) dans l'étude et la compréhension de l'hystérésis magnétique dans les matériaux a permis le développement de plusieurs modèles sans qu'ils arrivent à une maîtrise globale de ce phénomène complexe fortement non-linéaire.

En effet, l'hystérésis est à l'origine de pertes dans le matériau au même titre que les courants de Foucault localisés qui s'y développent à une fréquence donnée. Rendre compte du phénomène hystérétique par le développement d'un modèle qualitatif permettrait une détermination exacte des différents paramètres mis en jeu dans l'étude des machines électriques.

Notre contribution consiste dans l'élaboration de modèles qualitatifs basés sur des techniques d'identifications nouvelles (Réseaux neurones, logique flou et leurs hybridations). Elle traite un aspect lié à la modélisation des matériaux magnétiques par la construction de modèles par identification.

Les différentes techniques de modélisation des systèmes décrivent l'interaction entre les variables (entrées, sorties). Ces interactions sont définies par des formalismes

mathématiques, tableaux numériques et par des logiciels composés de sous modèles inter-connectés.

La détermination des relations de dépendance entre deux groupes de variables x et y d'un objet donné constitue un des aspects essentiels des techniques de modélisation et couvre des disciplines diverses telles que l'estimation fonctionnelle (Bosq et al, 1987), la théorie de l'apprentissage (Boucheron, 1992) ou l'identification de systèmes (Soderstrom, 1989). L'objectif commun est d'estimer les variables y , sortie du système, par une quantité raisonnable, en tenant compte des entrées x correspondantes, des connaissances disponibles sur le système et d'une base de vecteurs d'apprentissage (x_i, y_i) .

Nous nous intéressons à la recherche de modèles fidèles dans le but de comprendre la caractéristique hystérétique des matériaux ferromagnétiques doux en régime statique et dynamique et de simuler avec précision le comportement des dispositifs électrotechniques. Nous choisissons de nous concentrer particulièrement sur le développement de modèles d'hystérésis par utilisation des techniques nouvelles de l'intelligence artificielle.

Dans le premier chapitre nous avons essayé de donner un bref rappel sur l'origine physique du magnétisme par la théorie classique, la théorie de la mécanique quantique et une interprétation du magnétisme à différentes échelles. Une classification des matériaux magnétiques et une description détaillée du phénomène d'hystérésis ont été décrites.

Au chapitre 2, nous avons établi de manière non exhaustive les modèles d'hystérésis existants dans le domaine de l'électromagnétisme. Ces modèles sont analysés afin de dégager celui qui est le plus pertinent pour décrire les phénomènes hystériques tant en régime quasi-statique qu'en régime dynamique. Une importance particulière est donnée au modèle de Preisach, son principe, sa caractérisation et son développement.

Dans le chapitre 3 nous avons abordé les fondements théoriques de la logique floue et des systèmes hybrides neuro-flous. Après une introduction à la logique floue, nous avons détaillé les différents modèles d'identification floue, les réseaux neuro-flous, leurs principes d'apprentissage et leurs avantages.

Au chapitre 4, nous avons basé sur les possibilités d'approximation de fonctions des réseaux de neurones pour le développement de modèles d'hystérésis. Les modèles construits sont basés sur les réseaux multicouches à rétropropagation.

Au chapitre 5, nous avons développé de modèles d'hystérésis dynamiques flous à partir de données entrée-sortie par utilisation de trois techniques différentes. La construction de tels modèles est basée sur des méthodes de classification floue. Ces méthodes appartiennent aux techniques de coalescence floue basées sur la minimisation d'une fonction objective.

Au chapitre 6 nous présentons un modèle qualitatif d'hystérésis magnétique statique et dynamique. Le modèle développé est basé sur la logique floue à inférence adaptative. Les données entrées-sorties d'apprentissage et d'identification sont recueillies à partir du modèle mathématique de Preisach. Dans ce chapitre nous détaillons la structure du modèle proposé, son architecture et les paramètres obtenus de la modélisation et de simulation.

En conclusion, nous avons mis en évidence l'importance des principes théoriques de la représentation floue et neuro-flous des systèmes hystérétiques. Nous avons également développé des modèles neurones d'hystérésis, des modèles flous et des modèles statiques et dynamiques neuro-flous. Les vecteurs entrées-sorties que nous avons utilisé pour l'apprentissage et l'identification ont été recueillies à partir de modèles mathématiques existants dans la littérature ainsi qu'aux résultats de mesures de différents cycles d'hystérésis faites par d'autres chercheurs.

Chapitre I

Physique du magnétisme

1.1 Introduction

Le magnétisme reste chargé de mystères, pourtant les phénomènes magnétiques sont connus depuis très longtemps et les matériaux magnétiques sont omniprésents dans notre environnement (Piecuch, 2007). Le but de ce chapitre est de tenter d'expliquer l'importance des matériaux magnétiques. Le champ magnétique induit une force sur toutes les particules en mouvement, d'où l'origine de toutes les forces magnétiques. A l'échelle atomique le mouvement des électrons autour des noyaux et le mouvement propre de ces mêmes électrons sont à l'origine de deux types de moments magnétiques atomiques : le moment orbital et le spin. On définira la diversité des matériaux magnétiques ; des matériaux ferromagnétiques paramagnétiques et diamagnétiques. Nous décrivons ensuite le phénomène d'hystérésis, son origine physique ainsi que les phénomènes qui l'accompagnent.

1.1.1 Champ magnétique H

La théorie magnétique emploie deux vecteurs de champ pour décrire les phénomènes magnétiques (Beattie, 1989). Le champ magnétique H et l'induction magnétique B .

Dans le vide , la relation entre ces deux grandeurs est donnée par:

$$\vec{B} = \mu_0 \vec{H} \quad (1.1)$$

où μ_0 représente la perméabilité magnétique du vide ($\mu_0 = 4\pi 10^{-7}$ H/m). Dans un matériau, la relation devient complexe. Il est nécessaire d'introduire le vecteur d'aimantation qui satisfait l'équation:

$$\vec{B} = \mu_0 (\vec{H} + \vec{M}) \quad (1.2)$$

La relation $B = f(H)$ ou $M = f(H)$ appelée processus général d'aimantation et il est représenté graphiquement par une courbe dite courbe d'aimantation. Ce processus dépend de la structure, de la géométrie et des constantes magnétiques (Bertotti, 1998) . Cependant, il n'est pas possible de calculer la courbe d'aimantation dans sa forme générale à partir des principes de bases (Craik et Tebble, 1965). Ceci représente exactement l'objectif principale de cette thèse, à savoir une reproduction précise de ces relations au moyen d'un modèle compatible avec le calcul numérique.

1.1.2 Aimantation et moment magnétique

En étudiant les expériences d'Oersted sur les champs magnétiques créés par les circuits électriques, André Marie Ampère (1775-1836) introduisit l'hypothèse des "courants ampériens", c'est-à-dire l'existence de microcirculations d'électrons dans la matière aimantée. Plus tard, on modélisa l'atome comme ayant des électrons en rotation autour du noyau, équivalent alors à des spires de courant créant un champ magnétique microscopique. On définit en électromagnétisme une grandeur caractéristique de ce dispositif: le moment magnétique :

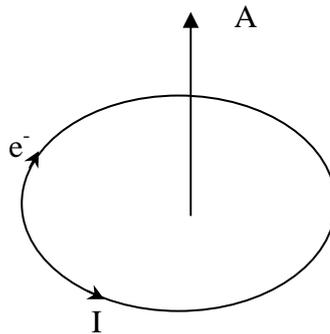


Figure 1.1: Moment magnétique

Le vecteur moment magnétique a pour sens et direction ceux du champ magnétique créé par I et pour norme :

$$\vec{m} = \vec{I} \cdot A \quad (1.3)$$

A est la surface définie par la spire.

L'aimantation \vec{M} représente la limite de la somme des moments magnétiques par une variation de volume:

$$\vec{M} = \lim_{\Delta V \rightarrow 0} \frac{1}{\Delta V} \sum_i \vec{m}_i \quad (1.4)$$

ΔV représente un volume infiniment petit qu'on peut considérer comme nul à l'échelle macroscopique, alors qu'à l'échelle microscopique ce volume contient un grand nombre d'atomes ce qui lui donne une grande importance. Cependant, si l'aimantation est uniforme, les courants des dipôles magnétiques seront éliminés et on aura un matériau neutre, alors que si l'aimantation n'est pas uniforme, les dipôles magnétiques ne seront pas éliminés donnant naissance à des courants de magnétisation même en absence de charge. Ces courants produisent un champ magnétique.

1.1.3 Moments magnétiques d'électron

1.1.3.1 Description classique

Les mouvements des électrons liés à l'atome sont à l'origine de l'aimantation. Les champs magnétiques sont produits par des charges en mouvement à l'intérieur du matériau, du point de vue de la mécanique classique, le mouvement de ces électrons crée un petit moment magnétique perpendiculaire au plan de l'orbite.

En effet, l'électron a deux types de mouvements, orbitale et de rotation sur lui-même. La contribution relative du mouvement orbital et de la rotation dépend du type de matériau à considérer. Les expériences basées sur la résonance magnétique montrent que le moment magnétique des matériaux ferromagnétiques est dû principalement à la rotation des électrons c'a'd aux spins.

1.1.3.1.1 Moment magnétique orbital

Le mouvement de l'électron autour du noyau est décrit par une trajectoire définie par une section A (figure 1.1) à l'instant τ . Par application de l'équation (1.1), le moment magnétique orbital \vec{m}_0 est exprimé par:

$$\vec{m}_0 = \frac{-e\vec{A}}{\tau} \quad (1.5)$$

\vec{m}_0 peut être aussi défini en fonction du moment orbital angulaire \vec{P}_0 par l'expression suivante :

$$\vec{m}_0 = \frac{-e\vec{P}_0}{2m_e} \quad (1.6)$$

Avec m_e la masse de l'électron.

1.1.3.1.2 Moment magnétique du spin

Le moment magnétique de spin \vec{m}_s peut être généré par un moment angulaire de spin \vec{P}_s donné par :

$$\vec{m}_s = -\frac{e\vec{P}_s}{m_e} \quad (1.7)$$

1.1.3.1.3 Moment magnétique total

Le moment magnétique total de l'électron \vec{m}_t est la somme des contributions du moment magnétique du spin et du moment magnétique orbital :

$$\vec{m}_t = \vec{m}_s + \vec{m}_o \quad (1.8)$$

L'interprétation basée sur la mécanique classique supposant que les électrons ont un mouvement orbital été incomplète. En outre, la vision aussi classique du spin en tant que "courant Ampérien" ne sert pas non plus à une étude approfondie du phénomène. Cependant, pour une explication plus descriptive du phénomène nous avons dû recourir à une interprétation basée sur la mécanique quantique.

1.1.3.2 Description quantique

Le mouvement des électrons dans le nuage électronique est responsable de l'existence d'un magnétisme dit orbital, alors que la rotation sur eux-mêmes est responsable du *magnétisme de spin*. Il n'est pas possible d'ignorer l'aspect quantique de ces phénomènes : en 1919, H. van Leeuwen prouva qu'il était impossible d'expliquer le magnétisme uniquement à l'aide de l'électrodynamique de Maxwell et de la mécanique statistique classique.

En mécanique quantique, les moments angulaires de l'électron ne sont pas continus, ils doivent obéir aux lois de la mécanique quantique, ainsi, les moments magnétiques également sont conditionnés par ces lois. Pour une description quantique des moments, nous définissons les paramètres suivants:

1.1.3.2.1 Nombre quantique principal (n)

Le nombre quantique n détermine la couche électronique. Chaque couche peut contenir au maximum $2n^2$ électrons.

1.1.3.2.2 Nombre quantique secondaire du moment angulaire orbital (l) (Azimutal)

Chaque niveau d'énergie peut être divisé en sous niveaux. Le nombre quantique secondaire du moment angulaire orbital est une mesure de la dynamique des électrons angulaire multipliée par la constante modifiée de Planck et l'excentricité de l'orbite de l'électron, il est définie par:

$$\vec{P}_0 = \vec{l}h \quad (1.9)$$

1.1.3.2.3 Nombre de Spin (s)

C'est un nombre quantique similaire au nombre quantique du moment angulaire orbital (l).

$$\vec{P}_s = \vec{S}.h \quad (1.10)$$

Pour un électron il prend la valeur $\frac{1}{2}$.

1.1.3.2.4 Nombre quantique du moment angulaire total (J)

C'est la mesure du moment angulaire total définie par:

$$\vec{P}_j = \vec{J}.h \quad (1.11)$$

Où \vec{P}_j est le moment cinétique total et J le nombre quantique du moment angulaire total, il est aussi déterminé par:

$$\vec{J} = \vec{l} + \vec{S} \quad (1.12)$$

1.1.3.2.5 Moments magnétiques quantiques

Pour la description quantique des moments magnétiques de l'électron, Remplaçons l'expression du moment angulaire orbital par utilisation du nombre quantique l de l'équation (1.9) dans l'équation (1.6) nous aurons :

$$\vec{m}_0 = \frac{-eh}{2m_e} \vec{l} \quad (1.13)$$

L'équation (1.13) exprimée en fonction du nombre quantique montre que la contribution du moment orbital dans le moment total est un multiple de la constante $eh/2m_e$. connue sous le nom du magnéton de Bohr μ_B .

Le moment magnétique orbital quantique est exprimé par :

$$\vec{m}_0 = -\mu_B \vec{l} \quad (1.14)$$

De la même façon, le moment magnétique quantique de spin, est déterminé en substituant l'équation (1.10) dans (1.7), on aura ainsi :

$$\vec{m}_s = \frac{-eh}{m_s} \vec{S} \quad (1.15)$$

En fonction du magnéton de Bohr :

$$\vec{m}_s = -2\mu_B \vec{S} \quad (1.16)$$

Avec l'expression (1.16) également nous avons le moment magnétique de spin exprimé en tant que nombre quantique. Enfin, le moment magnétique total m_t est donné par:

$$\vec{m}_t = -(\mu_B \vec{l} + 2\mu_B \vec{S}) \quad (1.17)$$

1.1.4 Types des matériaux magnétiques

Les substances et les matériaux pouvant être magnétisés par la présence d'un champ magnétique sont appelés matériaux magnétiques (Chikazumi, 1964). Il existe plusieurs types de matériaux magnétiques chacun est caractérisé par sa structure propre (Alfredo de blas del hoyo, 2005). Pour la classification des matériaux magnétiques, nous utilisons l'approche de la susceptibilité magnétique notée par χ reliant l'aimantation M du matériau au champ magnétique appliqué H :

$$\vec{M} = \chi \vec{H} \quad (1.18)$$

La susceptibilité magnétique se mesure en Henry/mètre. En effet, la susceptibilité relative par rapport à la perméabilité du vide μ_0 est donnée par :

$$\bar{\chi} = \frac{\chi}{\mu_0} \quad (1.19)$$

Substituons l'équation (1.18) dans (1.1), on aura :

$$\vec{B} = (\chi + \mu_0) \vec{H} = \mu \vec{H} \quad (1.20)$$

La valeur de la susceptibilité relative est de l'ordre de 10^{-5} pour les matériaux à faible aimantation jusqu'à 10^6 pour les matériaux à forte aimantation. Dans d'autres matériaux, la valeur de la susceptibilité peut être négative, constante où dépendante du champ appliqué H . Cependant, la susceptibilité magnétique relative dépend de la structure du matériau ce qui justifié son adoption comme critère de classification des matériaux magnétiques.

1.1.4.1 Diamagnétisme

L'effet d'un champ magnétique donne à l'ensemble du mouvement électronique une vitesse angulaire de rotation autour de la direction du champ magnétique appliqué : phénomène classique d'induction. Ce moment magnétique induit est proportionnel au champ appliqué et s'oppose à ce dernier. C'est l'origine du diamagnétisme qui est donc un phénomène tout à fait général mais qui peut être masqué par les autres phénomènes dont l'effet est plus important. Parfois, on emploie le terme de diamagnétisme parfait pour désigner le comportement des supraconducteurs qui créent en leur sein des courants induits qui s'opposent à toute variation de champ magnétique. Cette propriété est utilisée pour produire la lévitation magnétique des supraconducteurs.

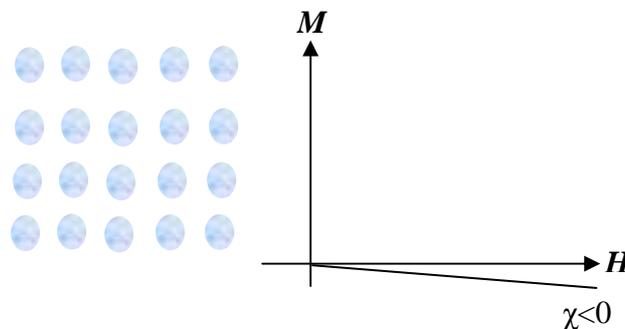


Figure 1.2 Diamagnétisme

Cependant, Les matériaux diamagnétiques ont une faible aimantation qui s'oppose à la direction du champ appliqué. Par conséquent, leurs susceptibilités sont négatives et faibles de l'ordre de -10^{-5} . On trouve les diamagnétiques dans les différents types de la matière. L'application d'un champ magnétique induit une rotation orbitale des électrons autour du noyau ce qui engendre la création d'un moment magnétique, mais par application de la loi de Lenz le courant résultant de ce moment induit s'oppose au champ appliqué.

1.1.4.2 Paramagnétisme

Lorsque les atomes possèdent leur propre moment magnétique permanent, le diamagnétisme (toujours présent) est masqué par le paramagnétisme. Sous l'effet d'un champ magnétique extérieur, ces atomes 'petits aimants permanents' s'orientent selon le champ appliqué et l'amplifient. Ce phénomène est limité par l'agitation thermique et dépend fortement de la température (loi de Curie) :

$$\vec{M} = \frac{C}{T} \vec{B} \quad (1.21)$$

Où C représente la constante de Curie.

Ce phénomène est lié à l'existence du spin de l'électron.

- Pour les atomes : Un atome dont les couches électroniques sont totalement remplies ne possède pas de moment magnétique. Lorsque les couches sont incomplètes, il y a toujours un déséquilibre qui produit un moment magnétique de spin.
- Pour les solides cela peut être très différent : les électrons externes participent aux liaisons chimiques. Dans les liaisons covalentes, les électrons appariés sont de spin opposé. Les ions des cristaux ioniques ont des couches complètes. On peut donc avoir une disparition du magnétisme propre. L'existence du paramagnétisme subsiste pour les solides composés d'atomes ayant des couches électroniques internes incomplètes : métaux de transitions et Lanthanides (terres rares) par exemple.

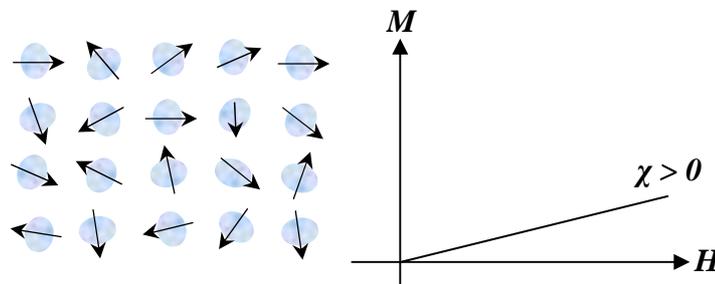


Figure 1.3 Paramagnétisme

Les matériaux paramagnétiques ont aussi une faible susceptibilité magnétique positive est constante. L'ordre de grandeur de la susceptibilité de ces matériaux est de 10^{-3} à 10^{-5} .

1.1.4.3 Antiferromagnétiques

Les matériaux antiferromagnétiques ont une faible magnétisation et une susceptibilité positive. Dans ce cas de substances, les moments magnétiques des ions du réseau cristallin sont orientés deux à deux en sens contraire. Dans un champ magnétique, et au delà de la température de Néel, il se produit une légère aimantation comme celle des paramagnétiques.

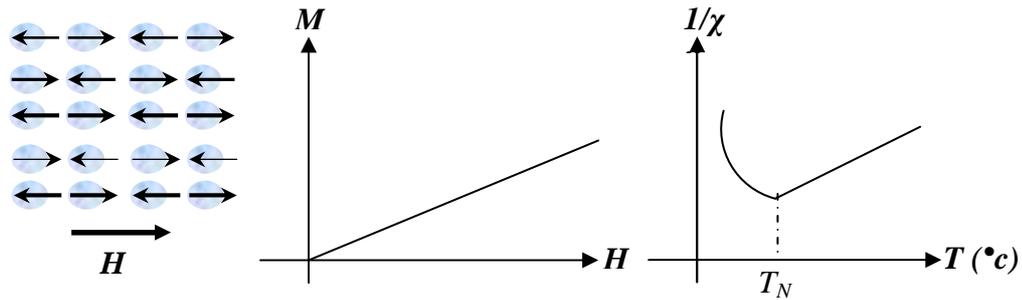


Figure 1.4 Antiferromagnétisme

1.1.4.4 Ferrimagnétisme

Le mot ferrimagnétisme est le terme proposé par Néel pour décrire le comportement magnétique des ferrites. Dans ces matériaux les ions occupent deux types de réseaux cristallins. Dans le premier type les spins sont orientés dans une même direction alors que dans le deuxième réseau cristallin leurs orientations sont telles qu'ils s'opposent aux spins du premier réseau. Comme le nombre d'ions dans les deux réseaux ne doivent pas être les mêmes, le résultat serait donc favorable pour une aimantation du matériau dans une direction déterminée. En effet, cette aimantation est appelée aimantation spontanée car elle est produite sans intervention du champ extérieur.

La configuration des spins se déforme par agitation thermique avec l'augmentation de la température ce qui diminue l'aimantation résultante. A la température de Curie (T_c), la configuration des spins devient aléatoire et l'aimantation spontanée disparaît, au dessus de cette température, la matière se comporte comme un paramagnétique.

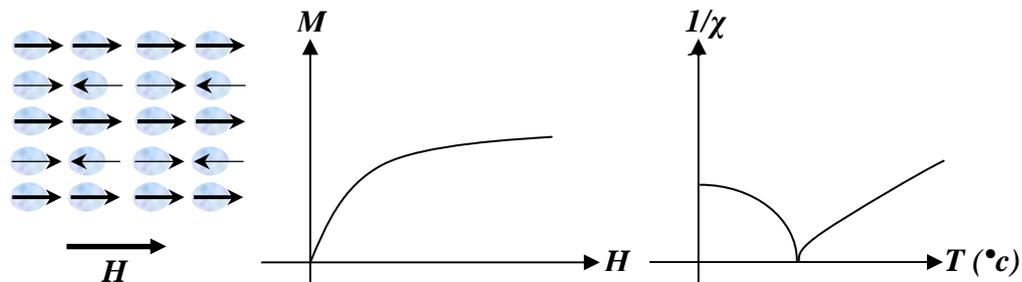


Figure 1.5 ferrimagnétisme

1.1.4.5 Ferromagnétisme

C'est la propriété qu'ont certains corps de s'aimanter très fortement sous l'effet d'un champ magnétique extérieur, et pour certains : les aimants (matériaux magnétiques durs) de garder une aimantation importante même après la disparition du champ extérieur.

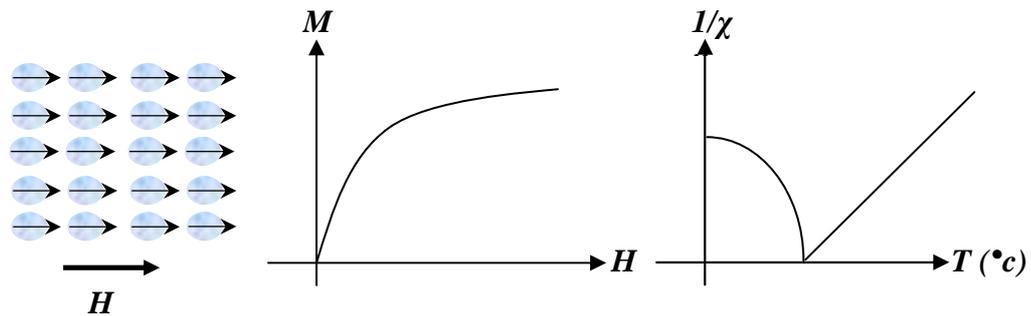


Figure 1.6 Ferromagnétisme

Le ferromagnétisme est semblable à celui du ferrimagnétisme, avec la différence que tous les spins s'orientent en parallèle et dans la même direction. Comme dans le ferrimagnétisme, sans appliquer un champ externe il apparaît une aimantation spontanée qui disparaît au-delà de la température de Curie où le matériau se comportera comme un matériau paramagnétique (Figure 1.6).

Malgré la présence de l'aimantation spontanée, les corps ferromagnétiques ne sont pas magnétisés généralement cela est dû à la présence de domaines magnétiques ayant chacun une aimantation spontanée dirigée vers une direction arbitraire dont la contribution de tous les domaines rend le matériau dans un état démagnétisé.

Si on applique un champ magnétique externe variable, l'aimantation du matériau change en décrivant une courbe dite courbe de première aimantation (figure 1.7), la zone de saturation correspond à l'aimantation spontanée. A partir de la saturation, une fois le champ appliqué diminue, l'aimantation diminue encore mais elle ne revient pas à la valeur initiale. Ce processus irréversible est appelé hystérésis magnétique.

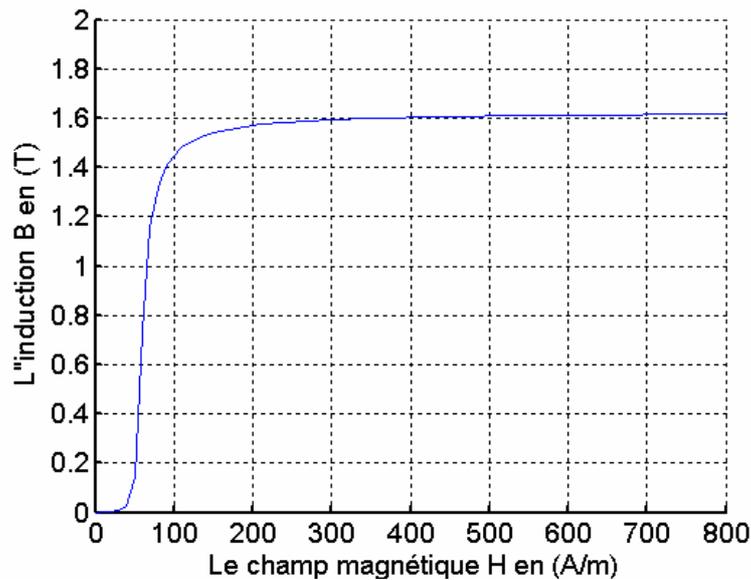


Figure 1.7 Courbe de première aimantation

L'existence de l'aimantation de saturation et de l'hystérésis est inhérente aux matériaux ferromagnétiques. Bien que peu de matériaux soient ferromagnétiques : Fer, ni, Co, Gd Dy et leurs alliages, les circuits magnétiques des machines électriques sont constitués par des matériaux ferromagnétiques. Etant donné, que l'un des objectifs de ce travail est de déterminer numériquement la caractéristique $B=f(H)$ de ces matériaux.

Le reste du chapitre sera consacré à l'étude du processus d'aimantation des matériaux ferromagnétiques et au processus donnant lieu à l'hystérésis magnétique.

1.2 Théorie du ferromagnétisme

Les matériaux magnétiques sont classés en plusieurs groupes selon leur comportement magnétique (Hakan, 2001). Il y a trois groupes principaux, les diamagnétiques, les paramagnétiques et les matériaux ferromagnétiques. Les matériaux diamagnétiques, par exemple le cuivre, ont une susceptibilité d'ordre -10^{-5} , c.-à-d. leur réponse magnétique s'oppose au champ magnétique appliqué. Les matériaux paramagnétiques, par exemple l'aluminium, ont une faible susceptibilité positive et pratiquement constante de l'ordre de 10^{-5} à 10^{-3} , leur aimantation est en alignement parallèle avec le champ appliqué. Le dernier groupe principal sont les matériaux ferromagnétiques, ils ont une grande susceptibilité de l'ordre de 50 à 10 000 on trouve dans ce groupe, le fer, le nickel et le cobalt. Cependant, il existe d'autres groupes ayant un comportement magnétique qui ressemble à celui des matériaux ferromagnétiques et ayant une susceptibilité magnétique de 10 à 10000.

1.2.1 Processus d'aimantation

L'aimantation des matériaux ferromagnétique est un processus complexe traité par plusieurs auteurs (Bozorth, 1978), (Chikazumi, 1997) et (Jiles, 1998). Dans ce chapitre, nous commencerons par l'explication de ce processus au niveau atomique du matériau.

1.2.1.1 Structure du matériau et hypothèse des domaines magnétiques (P.Weiss 1907)

Dans un atome chaque électron tourne autour de son propre axe, ce spin de l'électrostatique ayant une charge engendre un moment magnétique dit moment de spin. En effet, chaque atome est constitué de plusieurs électrons, ceux qui tournent dans un sens et ceux qui tournent dans le sens inverse. Cependant, si l'atome à un nombre d'électrons pairs, le moment résultant sera nul alors que dans le cas inverse on aura un spin où sa rotation n'est pas compensée, ce qui fait apparaître une aimantation moléculaire du matériau. Cependant, les matériaux ferromagnétiques ont un nombre important de spin dû à la présence d'électrons de valence, leurs atomes donc présentent un moment magnétique et agissent en tant que dipôles magnétiques.

Lorsqu' on applique un champ magnétique externe à un matériau ferromagnétique, les dipôles magnétiques des atomes agissent sur les dipôles des atomes voisins et s'alignent dans la direction du champ appliqué. Ce comportement interactif provoque une amplification du champ ce qui donne une aimantation très élevée même pour des faibles valeurs du champ appliqué.

Même en absence du champ appliqué, les dipôles agissent sur leurs dipôles voisins, ce qui provoque un alignement parallèle en formant une région appelée domaine magnétique. Dans un domaine, les atomes sont régulièrement ordonnés dans une structure cristalline. La figure 1.8 montre la disposition des atomes de fer dans une structure cristalline cubique avec un atome dans chaque coin du cube (Hakan, 2001).

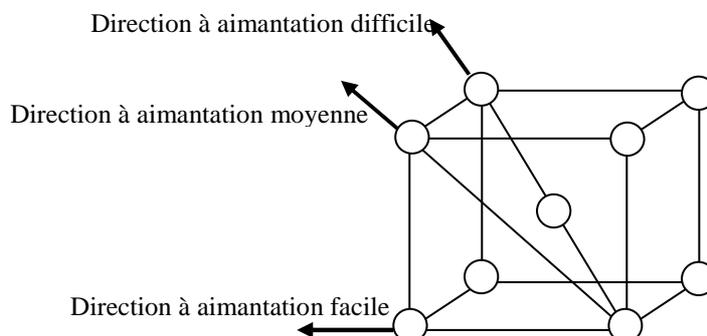


Figure 1.8 Structure cristalline du Fer

Dans le cristal les directions de l'aimantation sont limitées à trois groupes de directions possibles, définis par la structure du cristal. Dans un cristal de fer les directions d'aimantation sont, montrées par la figure 1.8, la direction à aimantation facile correspond au minimum d'énergie, c-a-d, sans application du champ externe, tous les domaines sont orientés vers cette direction. En effet, il y a six directions possibles à aimantation facile pour le fer, à l'état démagnétisé du matériau, tout les domaines sont aléatoirement distribués entre ces dernières directions de telle sorte que le matériau ne présente aucune aimantation.

Les domaines sont séparés par des régions où les dipôles changent de directions graduellement et sans interruption. Ces régions frontières s'appellent les parois de domaine ou les parois de Bloch, les directions des dipôles dans une paroi sont montrées par la figure 1.9 (Hakan, 2001).

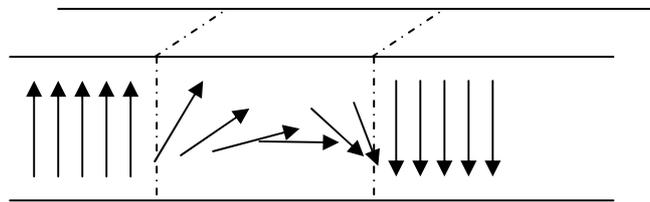


Figure 1.9 Orientation des dipôles magnétiques de la paroi

1.2.1.2 Aimantation

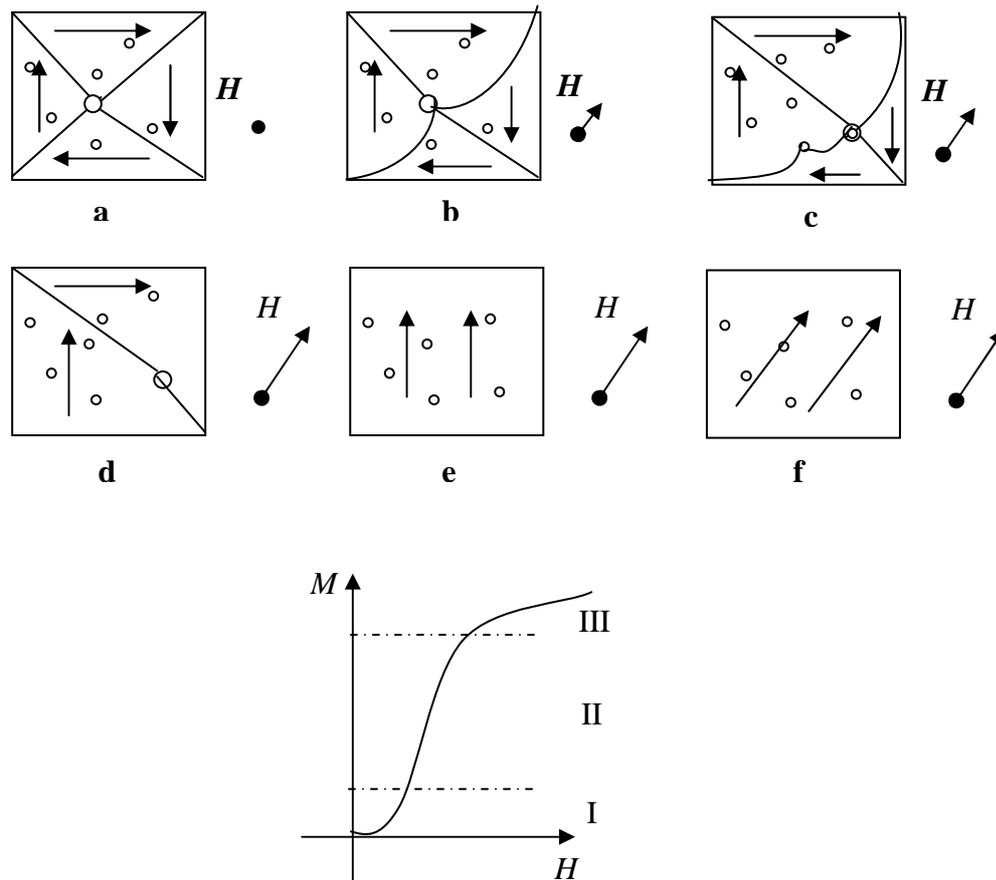
Le phénomène d'aimantation d'un matériau à partir de l'état désaimanté à l'aimantation de saturation passe par différentes étapes, à savoir, le mouvement des parois de domaines, réversible et irréversible, la rotation du domaine, réversible et irréversible. Cependant, la rotation irréversible du domaine peut se produire seulement dans un champ tournant. Au mouvement de parois de domaine, le volume d'un domaine change tandis qu'à la rotation du domaine, le volume reste fixe et la direction d'aimantation du domaine change.

Quand un champ externe est appliqué, les domaines avec des directions à aimantations faciles se développent au détriment des domaines dont leurs directions d'aimantation sont défavorablement faciles. La croissance d'un domaine implique que le domaine incorpore les dipôles des domaines adjacents et la direction de l'aimantation des dipôles incorporés sont changées en direction du domaine croissant. Ce phénomène du domaine favorable se produit pour minimiser l'énergie stockée dans la structure. Dans cette restructuration des domaines, les parois du domaine se déplacent vers les domaines avec une direction qui s'oppose au champ, le processus s'appelle mouvement des parois des domaines et se compose d'une partie réversible et une autre irréversible. Dans un matériau, il y a des défauts et des imperfections comme les vides, les régions soumis à des contraintes,...etc qui agissent et gênent le mouvement des parois de domaine. Quand le champ appliqué est faible la paroi est

gênée dans son déplacement par les zones de défauts, ce qui la déforme autour de ces zones. Si le champ est enlevé le cintrage se termine et la paroi de domaine retourne à l'emplacement original. Ce mouvement est réversible et donne seulement de faibles augmentations dans la magnétisation parce que seulement les dipôles dans le secteur de cintrage changent de direction. Quand le champ appliqué croît la paroi libère l'emplacement de défaut fait un saut à un nouvel emplacement. Ce mouvement de paroi de domaine est irréversible et la magnétisation augmente rapidement en pente, tous les dipôles dans le secteur entre l'ancien et le nouvel emplacement change de direction. Ce phénomène est connu sous le nom d'effet Barkhausen, il provoque des petits sauts dans la courbe d'aimantation. Une augmentation suffisamment élevée du champ appliqué fait disparaître tous les parois de domaine, en raison du mouvement irréversible des parois, et l'aimantation suivant la direction à aimantation facile s'aligne à la direction du champ appliqué. Un accroissement du champ appliqué cause une rotation réversible du domaine, c.-à-d. le vecteur d'aimantation tourne jusqu'à ce qu'il sera aligné avec le champ appliqué. L'augmentation de l'aimantation due à ce processus est faible et l'aimantation commence à se saturer. Quand tous les domaines sont alignés avec le champ appliqué le matériau est entièrement saturé et aucun autre accroissement de l'aimantation n'est possible.

la figure 1.10 montre une représentation simplifiée des processus d'aimantations. La courbe de première aimantation, à partir de l'état démagnétisé à la saturation, et les parties liées aux différents processus sont également montrées. Les cercles représente des emplacements de taches dans le matériau, comme des impuretés ou des imperfections dans la structure cristalline.

Le schéma 1.10 montre une région de quatre domaines quand aucun champ externe n'est appliqué, les domaines sont aléatoirement distribués dans les directions à aimantation facile et aucune aimantation n'est présente. Quand le champ augmente les domaines dans la direction de facile aimantation commence à se développer. La croissance des domaines débuts avec un cintrage des murs de domaine autour des taches des emplacements, figure 1.10 b. L'accroissement des parois des domaines est un processus réversible et donnent seulement une petite variation de l'aimantation, (partie I) dans la figure 1.10. Une autre accroissement du champ appliqué fait libérés les parois des impuretés est provoque un saut de l'aimantation vers un nouvel emplacement (figure 1.10 C et d). Ce dernier processus est irréversible et provoque une forte élévation dans la magnétisation (zone II).



**Figure 1.10 Processus d'aimantation
et la courbe de première aimantation correspondante**

Enfin, pour un champ suffisamment élevé, une rotation réversible du domaine se produit (figure 1.10 f), les domaines tournent jusqu'à ce qu'ils soient entièrement alignés avec le champ appliqué et causent une faible variation de l'aimantation, zone III dans la figure 1.10 .

1.2.1.3 Phénomène d'hystérésis

Lorsqu'on soumet un matériau ferromagnétique à un champ alternatif, il se produit un phénomène dit d'hystérésis dû au fait que les domaines du matériau présentent une certaine constante de temps avant de s'orienter (Saint Jean, 1976). Dans le cas d'un circuit bobiné sur une carcasse ferromagnétique de forme toroïdale alimenté par une source de tension sinusoïdale et après un moment transitoire, il s'établit un régime permanent caractérisé par le fait que, pour la même valeur du champ H dans un élément de volume, l'induction B y prend deux valeurs différentes, selon qu'il s'agit de la demi période croissante ou de la demi période décroissante. On dit que le matériau s'est fixé sur un cycle d'hystérésis représenté par la courbe $B(H)$ (figure 1.11.a).

L'hystérésis des matériaux ferromagnétiques doux comme le fer dépend du processus irréversible de l'aimantation et est principalement déterminé par le procédé de contournement des impuretés par les parois des domaines en mouvement (Jiles, 1998). Les déformations qui gênent la paroi du domaine en mouvement provient des imperfections du matériel dû par exemple aux dislocations, aux impuretés et aux régions soumises à des contraintes, aussi les particules de frontières contribuent aux déformation des parois (Hakan, 2001).

L'hystérésis des matériaux ferromagnétiques doux est fortement liée au champ coercitif. Un faible champ alternatif appliqué peut faire tourner réversiblement le domaine, ils ont un champ coercitif très faible donc un cycle d'hystérésis très rétréci. Quand le champ augmente dans la région dominée par les domaines à rotation irréversible, le champ coercitif augmente rapidement. Enfin quand l'aimantation s'approche de la saturation et la rotation des domaines domine, le champ coecitif atteint une valeur stable. En conclusion, un matériau pure avec des contraintes internes réduites diminue le champ coercitif et donne un cycle très étroit.

Le schéma 1.11.b montre la variation du champ coercitif en fonction de la valeur maximale du champ appliqué. Un champ magnétique périodique quasi-statique est appliqué afin de négliger les courants de foucault à un échantillon de poudre de fer pour différentes amplitudes. Un enroulement est utilisé pour mesurer la densité de flux induite dans le noyau, permet de tracer le cycle d'hystérésis (figure 1.11.a). Les forces coercitives aux différentes amplitudes appliquées sont tracées sur le schéma 1.11.b en fonction de la valeur maximale du champ.

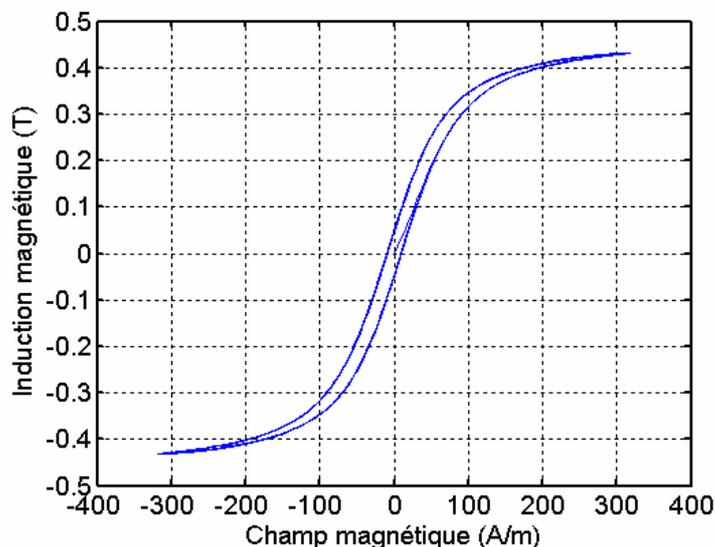


Figure 1.11.a Cycle d'hystérésis

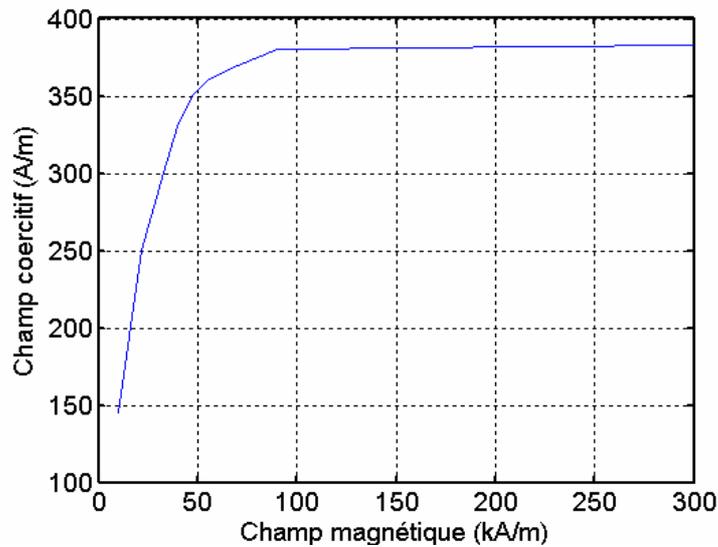


Figure 1.11.b Champ coercitif en fonction de la valeur maximale du champ magnétique

1.2.1.4 Perméabilité magnétique

La figure 1.10 montre la courbe de première aimantation d'un matériau ferromagnétique, la pente de la courbe détermine la perméabilité du matériau. Le matériau ferromagnétique est non linéaire, sa perméabilité n'est pas constante, elle varie en fonction du champ appliqué. Le comportement non-linéaire de la perméabilité est expliqué en fonction des différents types du processus d'aimantation du matériau.

Il y a divers types de perméabilités définissant le comportement du matériau ferromagnétique. Cependant, deux types sont généralement utilisées, la perméabilité initiale μ_i et la perméabilité maximale μ_m (figure 1.12). Pour les applications de faibles puissances où les champs magnétiques sont faibles on s'intéresse à la perméabilité initiale, alors que dans les applications de puissances élevées les champs sont considérables et la perméabilité maximale est la plus valide.

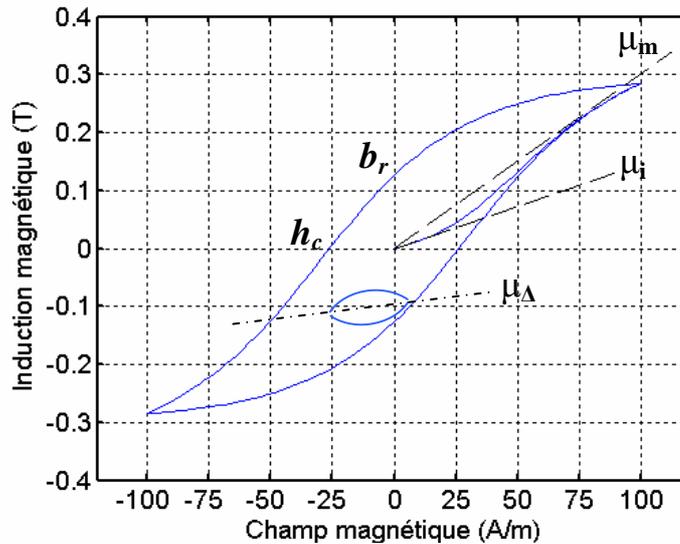


Figure 1.12: Différents types de perméabilités, perméabilité maximale (μ_m), perméabilité initiale (μ_i), perméabilité incrémentale (μ_Δ).

Dans les calculs magnétiques nous utilisons l'amplitude de la perméabilité et la perméabilité incrémentale μ_Δ . L'amplitude de la perméabilité correspond à la pente entre les bouts d'un cycle symétrique. Aux champs faibles, l'amplitude de la perméabilité coïncide avec la perméabilité initiale. La perméabilité croît d'abord très vite en fonction du champ appliqué, passe par un maximum, puis décroît; quand le champ augmente indéfiniment, la perméabilité tend vers la perméabilité du vide μ_0 (paramagnétique). Nous désignerons par μ_m la perméabilité maximum, par μ_i la perméabilité initiale (figure 1.12). Cette dernière n'est pas nulle, c'est-à-dire que la courbe de la figure 1.3 n'a pas une tangente horizontale à l'origine.

Champs faibles. Loi d'approche de la saturation

La perméabilité initiale est d'autant plus grande que la substance est plus pure chimiquement et dépourvue d'irrégularités physiques (tensions internes par exemple) (Durant, 1968). Pour des champs faibles, on peut poser

$$\mu = \mu_i + \alpha H \quad (1.22)$$

D'où

$$B = \mu_i H + \alpha H^2 \quad (1.23)$$

Où μ_i est la perméabilité initiale et α une constante. C'est la loi de Rayleigh utilisée aussi pour l'étude des cycles d'hystérésis.

On représente bien le haut de la courbe d'aimantation en posant

$$M = M_s \left(1 - \frac{a}{H} - \frac{b}{H^2} - \frac{c}{H^3} - \dots\right) + \chi_p H \quad (1.24)$$

Le dernier terme de cette équation est dû au fait qu'un paramagnétisme non sujet à la saturation se superpose toujours au ferromagnétisme. Ce terme est négligeable tant que la saturation n'est pas obtenue. Le terme en b/H^2 s'explique par l'énergie magnétocristalline, tandis que le terme en a/H serait dû d'après Néel à des inclusions non magnétiques et à des espaces vides. Il existe d'autres formules plus simples, mais moins précises, pour représenter le haut de la courbe d'aimantation; on pose parfois:

$$M = \frac{H}{a + bH} \quad (1.25)$$

Et quand H est petit:

$$\frac{1}{\mu} = a + bH \quad (1.26)$$

1.2.1.5 hystérésis magnétique en régime quasi-statique

Cette description théorique est inspirée des travaux de Laure Line Rouve (Laure.L.R, 1996) que l'on pourra consulter pour une étude très approfondie sur la physique du phénomène d'hystérésis

1.2.1.5.1 Description de l'hystérésis par une fonction d'opposition

Habituellement, l'analyse du phénomène d'hystérésis est basée sur des considérations énergétiques.

Soit une paroi plane à 180° soumise à un champ \vec{H} faisant un angle θ avec la paroi (Figure 1.13).

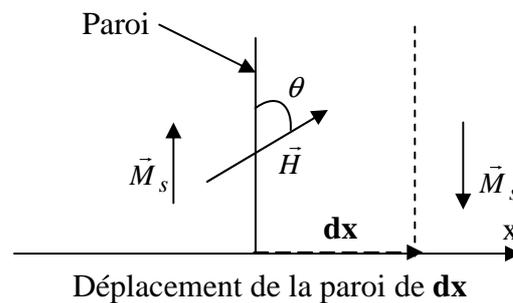


Figure 1.13 Paroi plane sous l'effet d'un champ magnétique

L'énergie interne totale E_T du matériau est donnée par la superposition de l'énergie d'interaction avec le champ \vec{H} , de l'énergie d'anisotropie magnéto cristalline E_{an} , de l'énergie magnétostatique E_m et de l'énergie de la paroi:

$$E_T = E_H + E_{an} + E_m + E_p \quad (1.27)$$

La différence entre l'énergie totale E_T et l'énergie d'interaction E_H notée E_R , indépendante de la position x de la paroi, est constituée principalement de la somme entre l'énergie magnétostatique et l'énergie de la paroi :

$$E_R = E_T - E_H = E_m + E_p \quad (1.28)$$

En effet, Le déplacement de la paroi modifié la répartition des masses magnétiques liées aux divergences locales de l'aimantation aux surfaces et aux interfaces. Une évolution possible de l'énergie E_R en fonction de la position x de la paroi est illustrée par la figure 1.14.

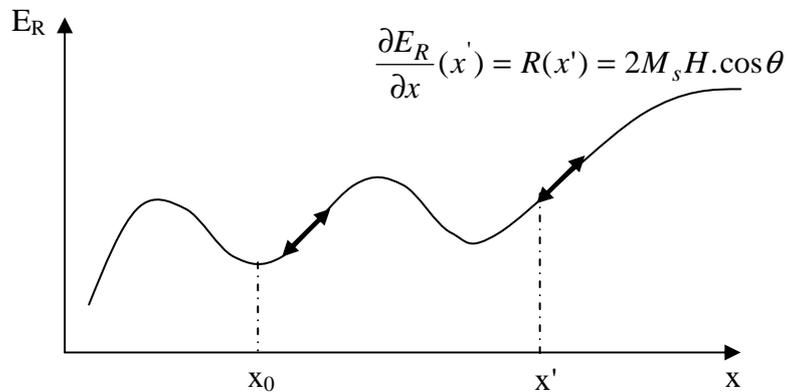


Figure 1.14: Energie E_R en fonction de la position de la paroi

L'état d'équilibre de la paroi (point x_0 figure 1.14) se produit en absence du champ appliqué est qui correspond à :

$$\frac{\partial E_R}{\partial x}(x = x_0) = 0 \quad (1.29)$$

L'application du champ H conduit à une autre position d'équilibre définie par :

$$\frac{\partial E_T}{\partial x} = 0 \quad (1.30)$$

Soit

$$\frac{\partial E_R}{\partial x} + \frac{\partial E_H}{\partial x} = 0 \quad (1.31)$$

La variation de l'énergie E_H par unité de surface de paroi pour un déplacement élémentaire dx sous l'effet du champ H vaut:

$$dE_H = -2M_s H \cos \theta dx \quad (1.32)$$

Donc:

$$\frac{\partial E_R}{\partial x} = 2M_s H \cos \theta \quad (1.33)$$

$\frac{\partial E_R}{\partial x}$ représente aussi une fonction d'opposition $R(x)$.

Tant que :

$$2M_s \cdot H \cos \theta > \frac{\partial E_R}{\partial x}$$

Une variation d'aimantation irréversible se produit jusqu'en $x = x'$ (Figure 1.14).

L'expression de la variation d'aimantation engendrée par un déplacement de longueur x par unité de surface de paroi et pour un volume total V_T est donnée par:

$$\Delta M = 2M_s \frac{dx}{V_T} \quad (1.34)$$

L'état d'équilibre de la paroi est atteint pour :

$$R(x) = 2M_s \cdot H \cdot \cos \theta \quad (1.35)$$

Cependant, la courbe $M(H)$ obtenue pour une variation donnée de la fonction d'opposition est hystérétique (Figure 1.15).

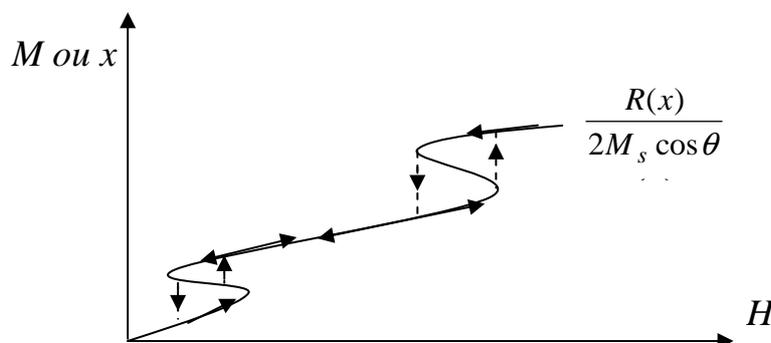


Figure 1.15: Aimantation obtenue par le déplacement d'une paroi soumise à un champ H pour $R(x)$ donnée

1.2.1.5.2 Origine des variations de la fonction d'opposition

Les variations de la fonction d'opposition $R(x)$ sont dues principalement aux variations d'énergie magnétostatique provoquées par la présence d'impuretés dans le métal et/ou par une réorganisation des masses magnétiques au moment du déplacement de la paroi. Pour plus de détails, nous allons voir comment trois impuretés de formes sphériques peuvent agir sur la variation d'aimantation associée à une paroi éloignée soumise à l'action d'un champ magnétique \vec{H} (Laure.L.R, 1996).

L'existence d'impuretés dans le matériau engendre des masses magnétiques et une variation de l'énergie magnétostatique en fonction de la position de la paroi (figure 1.16.b). Cependant, cette énergie présente des minima locaux quand la paroi se trouve sur des impuretés. La figure 1.16.c présente l'évolution de la fonction d'opposition $R(x)$ des variations $E_R(x)$ et la variation de l'aimantation correspondante $\Delta M(H)$ à partir d'un état initial donnée (Figure 1.16.a).

Au moment où les parois se débloquent et se déplacent, des nouvelles configurations apparaissent, cela est dus aux réarrangement des masses magnétiques et des domaines secondaires afin de minimiser l'énergie magnétostatique. Cependant, l'énergie magnétostatique fluctue quand la paroi se déplace et la fonction d'opposition $R(x)$ aussi ce qui correspond à la cause principale de l'hystérésis magnétique dans les tôles.

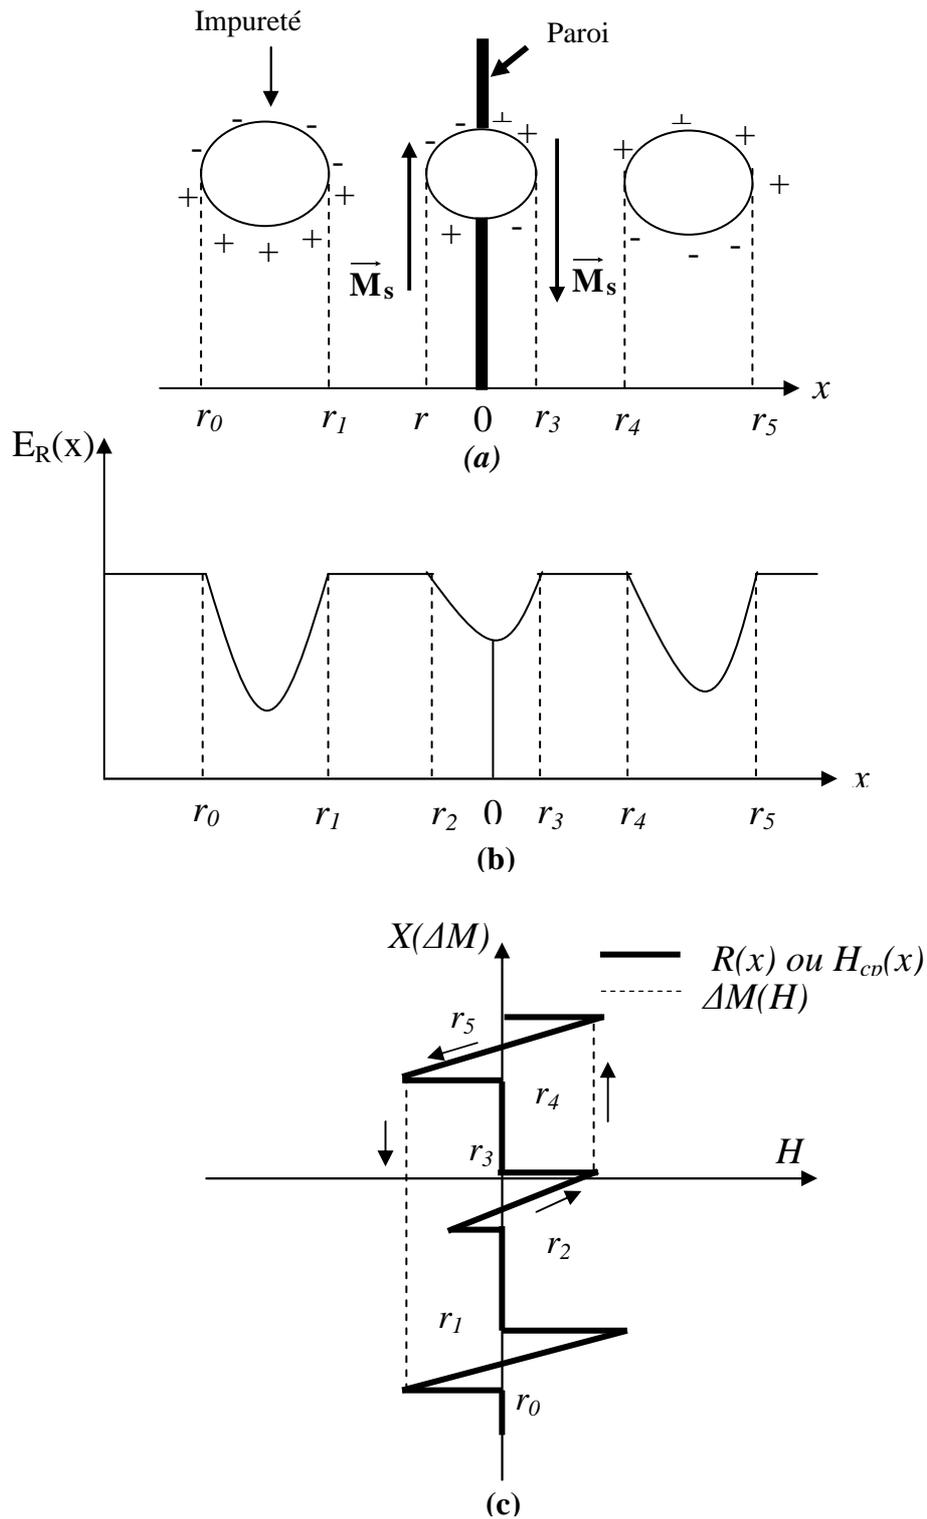


Figure 1.16 : Mouvement de la paroi en présence de trois impuretés:
 (c) configuration initiale
 (d) variations de E_R avec la position x de la paroi
 (c) évolution de la fonction d'opposition R avec x et variation d'aimantation ΔM générée en fonction du champ H appliqué.

1.2.1.6 Phénomène d'hystérésis dynamique

En quasi-statique, la paroi d'un matériau subissait un champ de blocage H_{CP} qui dépendait de sa position notée x et qui impose une succession de sauts rapides, de blocages et de progressions continues (figure 1.17.a). Lorsque la fréquence du champ appliqué augmente, la valeur du champ pendant les sauts de la paroi peut varier. La progression de la paroi avec les sauts du champ génère des courants induits (figure 1.17.b). Cependant, pour des fréquences plus élevées, le profil H_{CP} supprime certains blocages (Figure 1.17.c), la paroi évolue à la fréquence du champ ce qui engendre des courants induits plus importants. Si H est inversé ($H < H_{max}$), la paroi continue de progresser dans le même sens jusqu'à ce que H devienne inférieur au champ critique de paroi H_{CP} . Dans ce cas :

$$H_{CP} \leq H \leq H_{max} \quad \text{et} \quad \frac{\partial H}{\partial t} < 0 . \quad (1.36)$$

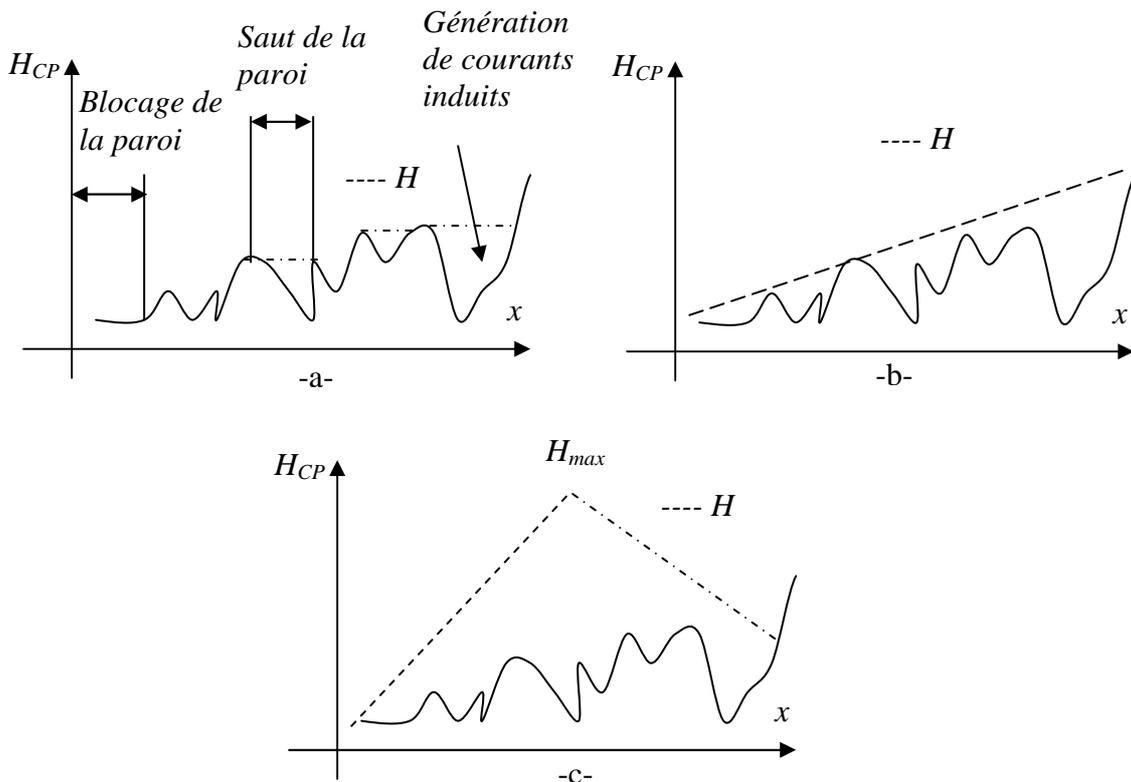


Figure 1.17 : Variation du champ critique H_{CP} et du champ H en fonction de la position x de la paroi : -a- en quasi-statique -b- à fréquence moyenne -c- à fréquence élevée.

La figure 1.18.a montre la variation du champ appliqué H et du champ critique H_{CP} en fonction de la position x de la paroi, alors que la figure 1.18.b présente les variations de l'aimantation avec le champ appliqué H

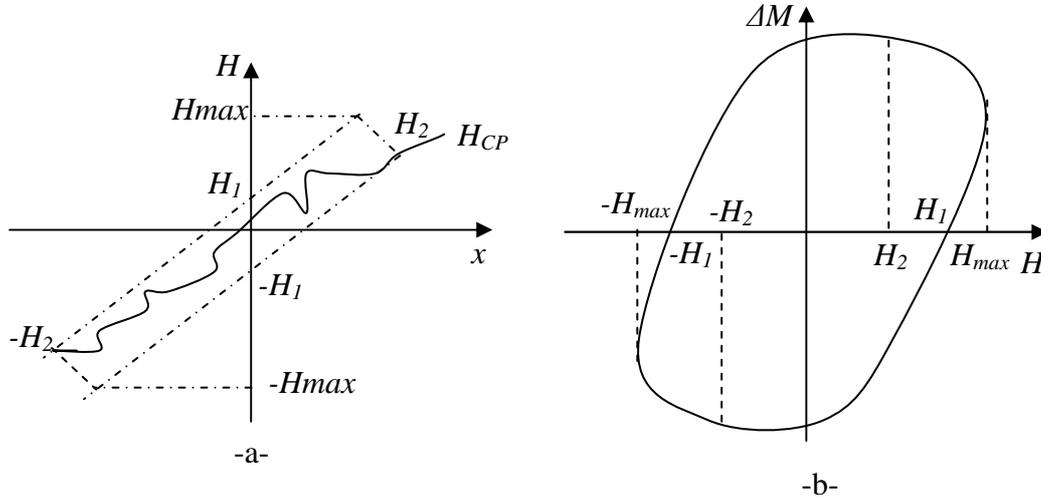


Figure 1.18 : Description d'un cycle pour une fréquence élevée : -a- Variation du champ critique H_{CP} et du champ appliqué H en fonction de la position x de la paroi -b- Variation d'aimantation correspondante en fonction du champ H appliqué.

Dans ces travaux, Kittel (Williams et al, 1950), concernant la dynamique d'une paroi à 180° isolée soumise à un champ H_S à la fréquence f a montré que les courants induits générés par le mouvement propre de la paroi provoquait un effet d'amortissement sur cette paroi suivant la loi:

$$v = \eta \cdot [H_s(t) - H_{CP}] \quad \text{quand} \quad H \geq H_{CP} \quad (1.37)$$

Avec :

v : la vitesse de la paroi

η : un facteur d'amortissement dû aux courants défini par:

$$\eta = \frac{1}{2 \cdot M_s \cdot \sigma \cdot G \cdot e} \quad (1.38)$$

Où :

M_s : aimantation de saturation

σ : la conductivité

e : l'épaisseur de la tôle

G : vaut

$$G = \frac{4}{\pi^3} \sum_{\text{impair } m} \frac{1}{m^3} \# 0.136 \quad (1.39)$$

Dans les études faites par Laure Line Rouve (Laure, 1996) dont la paroi étudiée appartenait à un monocristal en forme de cadre rectangulaire avec des cotés parallèle à deux directions de facile aimantation et des joints à 45° ne générant donc aucune

masse magnétique. H_{CP} n'est alors dû qu'à l'interaction des moments magnétiques en rotation dans la paroi avec la surface du cadre. H_{CP} est en conséquence très faible est constant sur la largeur du cadre. Il vaut H_C quand la paroi se déplace dans le sens positif et $-H_C$ dans le sens des x négatifs (figure 1.19.a).

La variation de l'aimantation en fonction du déplacement élémentaire de la paroi dx est donnée par:

$$dM = \frac{dx.M_s}{b} \quad (1.40)$$

où $2b$ est la largeur du cadre.

De l'équation 1.37 et pour une alimentation sinusoïdale $H_s(t)$, les variations temporelles de l'aimantation associée à la paroi sont données par :

$$\begin{aligned} M(t) &= M_0 && \text{pour } 0 \leq t \leq t_1 \\ M(t) &= M_0 + \frac{1}{2be\sigma G} \left[\frac{Hm}{\omega} * (\cos\alpha_1 - \cos\alpha) + H_{cp}*(t_1 - t) \right] && \text{pour } t_1 \leq t \leq t_2 \\ M(t) &= M_0 + \frac{1}{2be\sigma G} \left[\frac{Hm}{\omega} * (\cos\alpha_1 - \cos\alpha_2) + H_{cp}*(t_1 - t_2) \right] = M_1 && \text{pour } t_2 \leq t \leq t_3 \\ M(t) &= M_1 + \frac{1}{2be\sigma G} \left[\frac{Hm}{\omega} * (\cos\alpha_3 - \cos\alpha) + H_{cp}*(t_3 - t) \right] && \text{pour } t_3 \leq t \leq t_4 \end{aligned} \quad (1.41)$$

$$M(t) = M_0 \quad \text{pour } t_4 \leq t \leq T$$

Avec

$$H_s(t) = H_{max} \sin(\omega t) \quad (1.42)$$

Où H_{max} est l'amplitude du champ appliqué en surface (A/m), ω est la pulsation en (rad.s^{-1}), (t_1, t_3) sont tels que $H_C = H_{max} \sin\omega t_1 = H_{max} \sin\omega t_2$, (t_2, t_4) sont tels que $-H_C = H_{max} \sin\omega t_3 = H_{max} \sin\omega t_4$ et T est la période (s).

La figure 1.19.a représente l'évolution schématique du champ appliqué H en fonction de la position x de la paroi pour deux fréquences f_1 et f_2 ($f_2 \gg f_1$), dans le sens des x croissants.

La courbe $M(H)$ correspondante est représentée sur la figure 1.19.b pour les deux fréquences. Pour des fréquences de l'ordre de grandeur de f_1 , le champ critique H_I augmente avec la fréquence: La courbe $M(H)$ obtenue a donc son champ "coercitif" qui croît avec la fréquence.

Pour des fréquences de l'ordre de grandeur de f_2 , plus la fréquence augmente, plus $(M_1 - M_0)$ est faible. Donc la fréquence a pour effet d'atténuer la variation d'aimantation associée à une paroi isolée.

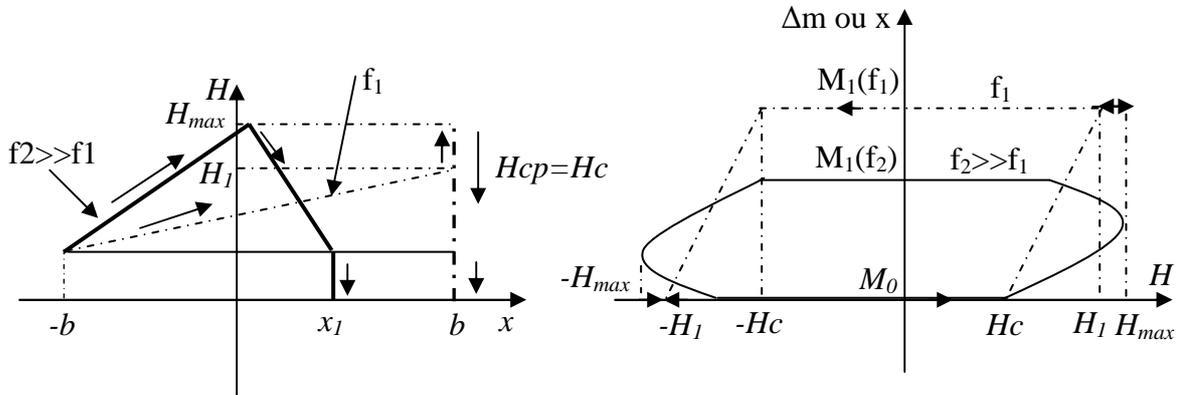


Figure 1.19 : Evolution de la paroi sur la largeur $2b$ du cadre pour deux fréquences f_1 et f_2 ($f_2 \gg f_1$) : -a- évolution du champ en fonction de x et de f , -b- évolution de $M(H)$ avec f .

En effet, la complexité augmente lorsqu'on s'intéresse à une paroi évoluant au sein du matériau réel. Cependant, à cause de la présence et la recombinaison des masses magnétiques, le champ H_{CP} était susceptible de varier en fonction de x . L'autre point important susceptible d'être mentionné est que les autres parois génèrent des courants induits localisés en se déplaçant. En conséquence, un contre-champ $H_{ci}(t)$ se crée et qui se retranche au champ appliqué $H_s(t)$. Alors le champ local qui agit sur la paroi sera:

$$H(t) = H_s(t) - H_{ci}(t) \tag{1.43}$$

L'équation de Kittel pourrait alors s'écrire selon:

$$\frac{\partial M}{\partial t} = \frac{1}{2be\sigma G} \cdot \{H_s(t) - H_{ci}(t) - H_{cp}(t)\} \text{ quand } H(t) \geq H_{CP}(t) \tag{1.44}$$

La fréquence provoque donc l'amortissement du mouvement des parois, par ailleurs, le champ local que subit une paroi est lié aux autres parois par le biais d'un contre-champ $H_{ci}(t)$ dû aux courants induits créés par ces autres parois.

1.2.1.7 Reptation des cycles

Les cycles d'hystérésis successifs entre deux valeurs maximales H_m et $-H_m$ de H subissent une translation qui croit en même temps que le numéro d'ordre du cycle. C'est ce que montre la figure 1.21, la théorie et l'expérience montrent que cette translation est proportionnelle à la racine carrée du logarithme du nombre de cycles. En répétant l'action d'un champ H_m est d'un champ $-H_m$, on peut donc obtenir une

aimantation plus grande que celle qui serait donnée par l'application unique du champ H_m indéfiniment prolongée.

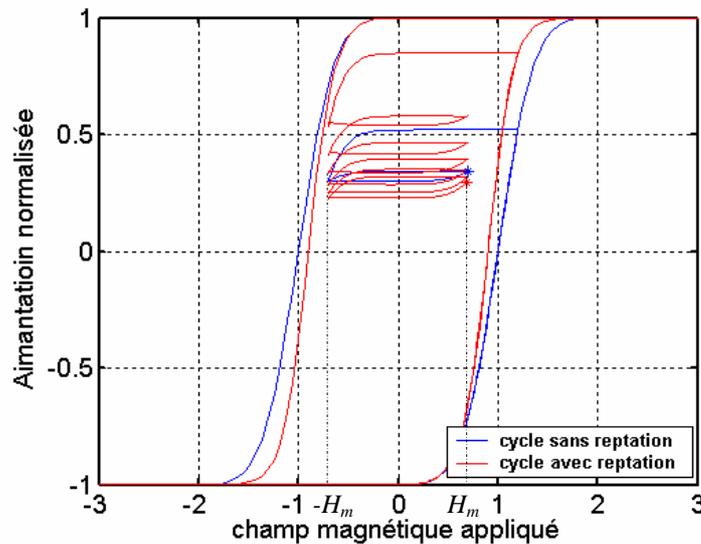


Figure 1.20 Reptation du cycle d'hystérésis (Della torre et al, 2004)

Ces phénomènes ont été étudiés par plusieurs chercheurs du domaine de magnétisme et s'interprètent on faisant intervenir la subdivision statistique en domaines élémentaires.

1.3 Conclusion

Dans ce chapitre, nous nous sommes tout d'abord intéressés à la description du phénomène d'aimantation des matériaux magnétiques et à l'origine du magnétisme. Nous avons présentés la description classique du phénomène d'aimantation magnétique et la description du point de vue de la mécanique quantique. le classement des matériaux magnétiques été aussi discutés. Dans un second temps, nous nous sommes intéressés à l'étude de la théorie du ferromagnétisme et au processus d'aimantation par la théorie des domaines. L'aimantation spontanée est une grandeur caractéristique du matériau. La définition de l'hystérésis, son origine ainsi que tout les phénomènes qui l'accompagne ont était évoqués. La forme des cycles d'hystérésis dépend de plusieurs facteurs qui devront être contrôlés.

Maintenant que nous avons définit les causes du phénomène d'hystérésis, les différents facteurs auquel il était sensible, nous allons aborder la partie modélisation et nous nous concentrons surtout sur les deux modèles les plus utilisés, modèle mathématique présenté par le physicien Allemand Preisach en 1935 (Preisach, 1935) et le modèle de Jiles-Atherton (Jiles-Atherton, 1983) basé sur des considérations énergétiques.

*Modèles d'hystérésis
magnétiques*

2.1 Introduction

Souvent la dissipation se traduit par un phénomène d'hystérésis défini comme étant le retard entre l'excitation et la réaction. Son sens a été élargi au caractère non univoque de la relation liant une excitation et une réponse, qui ne peut pas être décrite simplement à l'aide d'une fonction mathématique (Olivier, 2006).

Le phénomène d'hystérésis est observé dans plusieurs domaines des sciences: physique (ferromagnétisme, ferroélectricité, piézoélectricité, cycles mécaniques de déformations plastiques,...etc), chimie (cycles de réaction, transition de phase, adsorption,...etc), en mécanique (application d'une contrainte à un solide, frottement,...etc) et en science naturelle (Cycles de photosynthèse, ou autres processus biophysiques et biochimiques).

En génie électrique, le matériau magnétique est choisi à partir de ses caractéristiques physiques tel que sa perméabilité par exemple. En effet, le comportement de ces matériaux sous l'effet de la variation d'un champ magnétique appliqué se présente sous la forme d'un cycle, appelé cycle d'hystérésis. Ce dernier se caractérise par plusieurs paramètres et tracés remarquables définissant toutes les phénomènes ou les mécanismes irréversibles qui ont lieu lors de l'évolution de l'état du matériau (Jiles, 1991), (Mayergoyz, 1991), (Chikasumi, 1997), (Brissonneau, 1997). Donc le cycle d'hystérésis représente le tracé de l'induction magnétique en fonction du champ magnétique appliqué.

La forme du cycle d'hystérésis fournit des informations sur le mécanisme d'échange énergétique. Elle dépend du matériau lui-même, des dimensions de l'échantillon et des processus d'aimantation. Il dépend de la température et de la fréquence. En excitation alternative, en dessous d'une certaine fréquence dans le sens décroissant, l'aire du cycle observé n'évolue pas donnant ainsi un cycle quasi-statique. Par contre, l'élargissement du cycle aux fréquences élevées correspond à un cycle dynamique. En effet, plusieurs applications technologiques sont basées sur l'existence de ce cycle.

Nous proposons ci-dessous une synthèse analytique et numérique de quelques modèles d'hystérésis statiques et dynamiques développés dans la littérature.

2.2 Modèles d'hystérésis analytiques

Plusieurs formulations analytiques simples décrivant le comportement fortement non linéaire des matériaux magnétiques ont été développés. Cependant, ces modèles décrivent le phénomène par des expressions mathématiques sans tenir compte des aspects physiques du phénomène. Le premier modèle été développé par Lord Rayleigh, il décrit le phénomène d'hystérésis pour les champs faibles en exprimant la

perméabilité magnétique sur la courbe de première aimantation par une fonction linéaire du champ d'excitation ce qui conduit à une relation parabolique entre B et H sur la première portion de la courbe de première aimantation (Figure 2.1). Trois paramètres sont à identifier à partir des valeurs maximales du champ magnétique appliqué, de l'induction et de l'induction rémanente ce qui rend sa mise en œuvre facile.

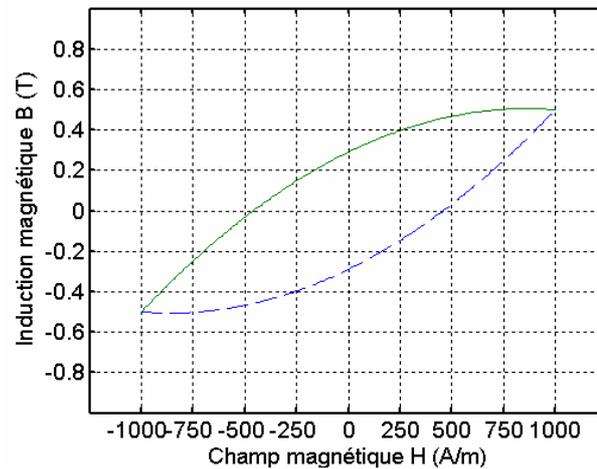


Figure 2.1 Cycle d'hystérésis avec le modèle de Rayleigh

L'inconvénient majeur de ce modèle est sa limitation aux champs faibles ce qui ne permet pas une description de la saturation.

Dans le but de décrire le comportement des matériaux ferromagnétiques, Neumann et Trutt (Truth et al, 1968) en 1968 ont proposé des séries polynomiales décrivant l'induction magnétique en fonction du champ appliqué (Figure 2.2). En 1984, Mayergoyz et al, en 1994 Nasar et Fu ont aussi fait appel aux séries polynomiales pour la description du phénomène (Mayrgoyz et al, 1984), (Nazar et al, 1994).

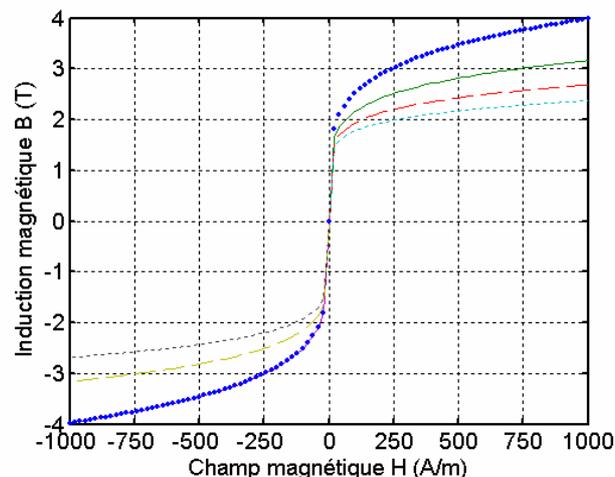


Figure 2.2 Courbes de premières aimantations générées par la série polynomiale

Ce modèle décrit seulement la courbe de première aimantation, ainsi que le phénomène de saturation. Un autre modèle analytique été proposé par Frolich décrivant ainsi la courbe de première aimantation à partir de deux paramètres caractéristiques du matériau. Afin de représenter le cycle d'hystérésis il a été amélioré par les travaux de Akbaba (Akbaba, 1991), et puis par Jufer, Apostolides (Jufer et al, 1976) et Wong (Wong, 1988)) par une prise en compte du phénomène des cycles mineurs.

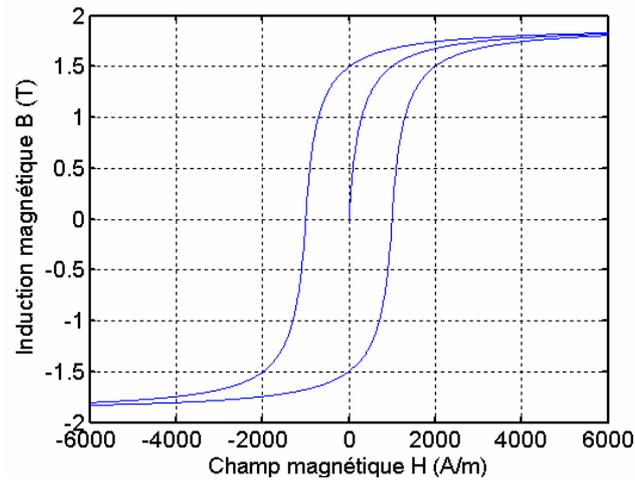


Figure 2.3 Cycle d'hystérésis par le modèle de types Frolich

L'utilisation des fonctions multiples pour la modélisation du comportement magnétique été utilisé dans le domaine de l'enregistrement magnétique. Cependant, la relation $B(H)$ peut être écrite sous forme exponentielle, trigonométrique ou hyperbolique. Ce type de modèle dénué de toute interprétation physique du phénomène permet d'approximer correctement le cycle majeur et même de décrire les cycles mineurs.

L'application à un échantillon ferromagnétique d'un champ d'excitation sinusoïdal a pour résultat une induction magnétique non sinusoïdale et de forme complexe (comportement non linéaire du matériau) qui va être représentée à l'aide des séries de Fourier basée sur des points expérimentaux de la courbe de première aimantation. Ce type de modèle permet d'approximer le cycle majeur à partir de paramètres déduits de la courbe de première aimantation sans pouvoir décrire les cycles mineurs du phénomène d'hystérésis, il est également dénué de toute interprétation du phénomène physique.

La relation $B(H)$ été aussi approximée par des fonctions auxiliaires qui consiste à la représentation de l'aimantation par une fraction de polynômes de second ordre :

$$M = \frac{a_1 H + a_2 H^2}{1 + b_1 H + b_2 H^2} \quad (2.1)$$

Les paramètres a_1 , a_2 , b_1 et b_2 fonction de M_s , M_r , de la susceptibilité initiale k , de la constante de Neel α et de la constante de Rayleigh η sont déterminés par :

$$\begin{aligned} a_1 &= k & b_1 &= \frac{k + \alpha\eta}{M_s - k\alpha} \\ a_2 &= \frac{M_s\eta + k^2}{M_s - k\alpha} & b_2 &= \frac{k + \alpha\eta}{M_s(M_s - k\alpha)} \end{aligned}$$

Le cycle majeur du phénomène d'hystérésis peut être construit à partir de deux fonctions auxiliaires $g_1(H)$ (fonction impaire) et $g_2(H)$ (fonction paire) définies par :

$$g_1(H) = \frac{B^- + B^+}{2}$$

$$g_2(H) = \frac{B^- - B^+}{2}$$

tel que B^+ et B^- représentent respectivement les branches montante et descendante du cycle d'hystérésis. L'induction magnétique B est alors déterminée par :

$$B = \begin{cases} g_1 + g_2 : \text{si } H \text{ diminue} \\ g_1 - g_2 : \text{si } H \text{ augmente} \end{cases} \quad (2.2)$$

les fonctions auxiliaires peuvent être approximées par des fractions rationnelles du second ordre.

$$g_1(H) = \mu_0 \left[H + \frac{a_1 H + a_2 H |H|}{1 + b_1 |H| + b_2 H^2} \right] \quad (2.3)$$

$$g_2(H) = \mu_0 \left[\frac{c_1 (H_s - |H|) + c_2 H H}{1 + b_1 |H| + b_2 H^2} \right] \quad (2.4)$$

Les coefficients b_1 et b_2 sont déterminés par la relation (2.1) et a_1 , a_2 , c_1 et c_2 à partir de relevés expérimentaux du cycle d'hystérésis. Une autre identification des fonctions auxiliaires a donné :

$$g_1(H) = B \cdot \tan^{-1}\left(\frac{H}{H_s}\right) \quad (2.5)$$

$$g_2(H) = \left[\frac{1}{H_s 1 + (H/H_s)^2} - \frac{\partial g_1(H)}{\partial H} \right]_{H=H_s} \quad (2.6)$$

Ce modèle analytique est facile à mettre en oeuvre grâce à la simplicité de ses fonctions auxiliaires, cependant il ne peut décrire les boucles mineures du cycle d'hystérésis et n'est valable que pour certains échantillons ferromagnétiques.

Un autre modèle d'hystérésis magnétique été proposé dans les travaux de Potter basé sur des relevés expérimentaux de l'aimantation de saturation M_s , de l'aimantation rémanente M_r , du champ de saturation H_s et du champ coercitif H_c :

$$M(H, \alpha) = M_s \left\{ \text{sign}(\alpha) - \alpha \left[1 + \tanh\left(\frac{H_c - H \text{sign}(\alpha)}{H_c} \tanh^{-1}\left(\frac{M_r}{M_s}\right)\right) \right] \right\} \quad (2.7)$$

Le facteur α vaut ± 1 sur le cycle majeur et est redéfini par (2.8) à chaque point de renversement caractérisé par H^* et par α^* . L'aimantation M sera alors calculée en fonction de H et de α^* et sera positive quand H est croissant et négative quand H est décroissant tel que $|\alpha| \leq 1$.

$$\alpha^* = - \frac{2 \text{sign}(\alpha) - \alpha \left\{ 1 + \tanh\left[\left(1 - \text{sign}(\alpha)\left(\frac{H^*}{H_c}\right)\right) \tanh^{-1}\left(\frac{M_r}{M_s}\right)\right]\right\}}{1 + \tanh\left\{\left[1 + \text{sign}(\alpha)\left(\frac{H^*}{H_c}\right)\right] \tanh^{-1}\left(\frac{M_r}{M_s}\right)\right\}} \quad (2.8)$$

Ce modèle décrit le cycle d'hystérésis à partir d'une fonction analytique paramétrée en α évoluant à chaque point de renversement (figure 2.4).

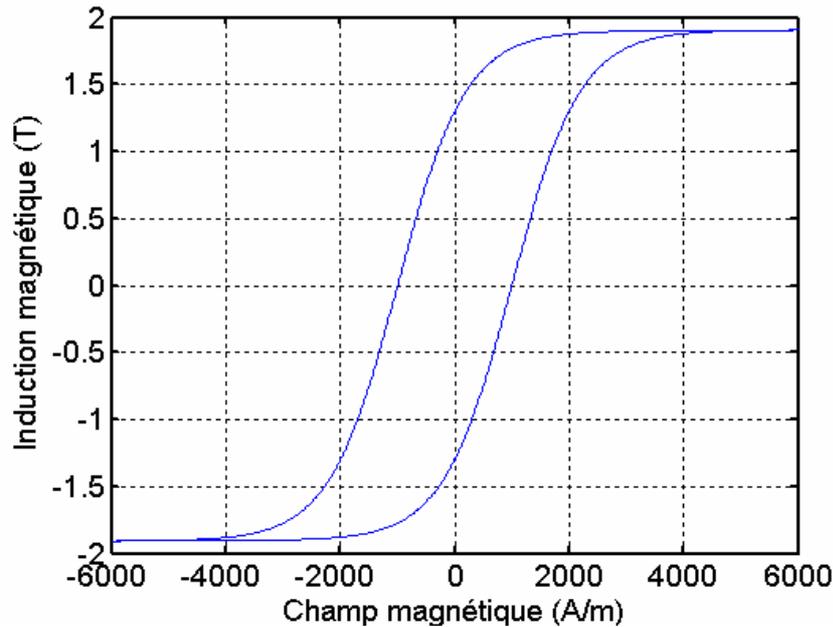


Figure 2.4 : Le cycle d'hystérésis généré par le modèle de Potter.

2.2.1 Modèle de l'astroïde (Stoner-Wohlfarth)

C'est le modèle vectoriel le plus ancien et le plus répandu dans le domaine de l'enregistrement magnétique. Il part d'un principe de compétition entre diverses tendances énergétiques principalement régies par l'anisotropie et le couplage avec le champ magnétique (Stoner et Al, 1947). Il décrit le processus de la rotation cohérente de l'aimantation dans un monocristal à anisotropie uniaxiale (Bossavit, 1995). Ce modèle est très utilisé dans la description des aimants permanents pouvant être assimilés à un ensemble de petits aimants juxtaposés quasi-isolés (Olivier, 2006). Il est peu utilisé pour les matériaux doux dont l'hystérésis statique s'explique physiquement plus par des problématiques d'accrochages et de décrochages de parois au niveau des défauts cristallins, pour la coercivité ((Goodenough, 1954), (Rodbell et al, 1956), (Friedberg et al, 1975)); et de rotations cohérentes de moments dans les domaines magnétiques, pour l'approche à saturation ((Brown, 1940), (Brown, 1941), (Néel, 1944)).

2.2.2 Modèle de Preisach-Mayergoyz

Ce modèle est basé sur le changement d'état des hystérons élémentaires distribués de manière statistique sur un plan de coercivité ascendante et descendante selon une relation p caractérisant le matériau ((Preisach, 1935), (Mayergoyz et al, 1987), (Mayergoyz et al, 1988)).

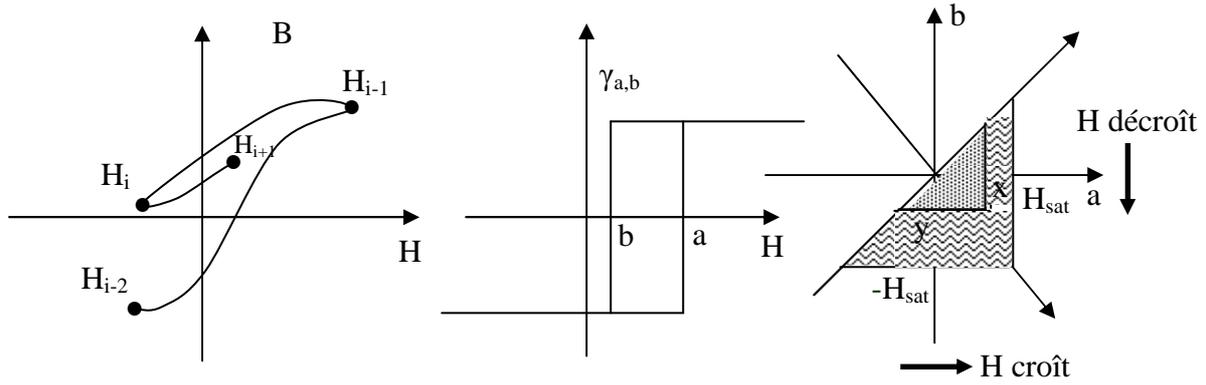


Figure 2.5 : Schéma explicatif des commutateurs et du plan de Preisach

La détermination de l'aimantation magnétique d'un matériau donné dans le plan de Preisach (figure 2.5) peut être caractérisée par les expressions suivantes:

$$\begin{aligned} \text{si } H > H_{i-1} : M(H) &= M(H_{i-1}) + 2E(H, H_{i-1}) \\ \text{si } H < H_{i-1} : M(H) &= M(H_{i-1}) - 2E(H_{i-1}, H) \end{aligned} \quad (2.9)$$

Où

$$E(x, y) = M_{sat} \iint_{\Delta(x, y)} p(a, b) da db \quad (2.10)$$

$$M = M_{sat} \left(\iint_{S^+} p(a, b) da db - \iint_{S^-} p(a, b) da db \right) \quad (2.11)$$

L'équation 2.11 est la version scalaire du modèle de Preisach-Mayergoyz. La version vectorielle du modèle utilise trois lois de probabilités couplées et est basée sur le même principe du modèle scalaire ((Mayergoyz et al, 1991), (Adly et al, 1997)). Ce modèle présente comme avantage la prise en compte de l'histoire du matériau et comme inconvénient sa limitation en place mémoire qui est à l'origine de la lourdeur des calculs, en plus des difficultés d'identifications des lois de probabilités dans le plan de Preisach ((Mayergoyz et al, 1990), (Bergqvist et al 1997), (Hong et al, 1998)). Ce modèle est souvent utilisé afin d'évaluer les pertes par hystérésis ((Dupré et al, 1997), (Dupré et al, 1998)).

2.2.3 Modèle de Jiles-Atherton

Une description correcte du phénomène d'hystérésis prend en compte la physique microscopique des parois magnétiques en présence de défauts (impuretés) et des déformations internes de la structure cristalline du matériau (Jiles et al, 1986). Jiles et Atherton supposent que l'échange d'énergie par unité de volume est égal à l'échange d'énergie magnétostatique additionné aux pertes par hystérésis. Cependant,

l'aimantation totale M du matériau est la somme d'une contribution réversible M_{rev} due aux blocages et aux déformations des parois, et d'une contribution irréversible M_{irr} provoquée par le déplacement propre des parois. Les deux contributions obéissent à des relations différentielles construites sur la base d'une aimantation anhystérique M_{anh} définie par la théorie de Langevin corrigée par la théorie de Weiss ((Jiles, 1991), (couture et al, 1992)) et d'un champ effectif H_{eff} amorti par le champ moyen de Weiss αM ($H_{eff} = H + \alpha M$) (Jiles, 1991).

$$\begin{aligned}
 M_{anh} &= M_{sat} L_g \left(\frac{H_{eff}}{a} \right) = M_{sat} \left(\coth \left(\frac{H_{eff}}{a} \right) - \frac{a}{H_{eff}} \right) \\
 \frac{dM_{irr}}{dH_{eff}} &= \frac{(M_{anh} - M_{irr})}{(k * \text{signe}(dH))} \\
 M_{rev} &= c(M_{anh} - M_{irr})
 \end{aligned} \tag{2.12}$$

α , a , k et c sont les paramètres du modèle liés respectivement à l'effet démagnétisant des voisins, l'effet désordonnant de la température ($a \approx k_B T / (\mu_0 M_{sat})$), la mobilité des parois et la déformabilité de ces mêmes parois ((Jiles et al, 1986), (Benabou, 2002)). Une fois identifiés ces paramètres, l'aimantation totale est reconstruite selon l'expression suivante :

$$\begin{aligned}
 M &= M_{rev} + M_{irr} = cM_{anh} + (1 - c)M_{irr} \\
 \frac{dM}{dH} &= \frac{\left(c \frac{dM_{anh}}{dH_{eff}} + (1 - c) \frac{dM_{irr}}{dH_{eff}} \right)}{\left(1 - \alpha c \frac{dM_{anh}}{dH_{eff}} - \alpha (1 - c) \frac{dM_{irr}}{dH_{eff}} \right)}
 \end{aligned} \tag{2.13}$$

Ce modèle ne nécessite que très peu de capacité de stockage. En revanche sa mauvaise précision en particulier dans le cas des excitations dissymétriques le place souvent derrière le modèle de Preisach.

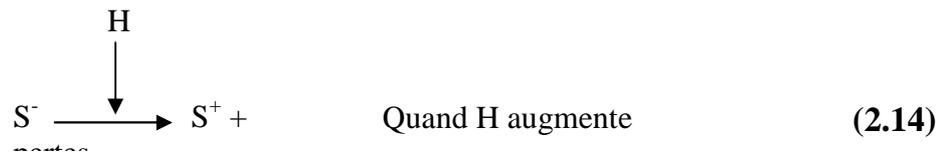
2.2.4 Modèle de Amir Nourdine

Dans les travaux de Amir Nourdine, un modèle d'hystérésis analytique été développé par utilisation d'une analogie entre les transformations des états magnétiques et les réactions chimiques (Amir, 2002). Cependant, l'aimantation est déterminée par un équilibre thermodynamique obtenu par transposition des résultats de la chimie à la physique des matériaux. Un modèle dynamique validé par la mesure sur une plage de fréquence de 0 à 1000 Hz et aussi élaboré à partir d'un modèle statique

capable de représenter les phénomènes dynamiques de l'hystérésis et des courants induits.

Le modèle en question considère deux mécanismes principaux à savoir: le retournement des moments magnétiques qui traduit les déplacements des parois, et la rotation progressive des moments qui correspond à leur changement de direction. Cependant, le retournement des moments magnétiques peut être considéré comme le basculement d'un état '+' vers un état '-' qui correspond à une modification du spin des atomes. Ceci conduit à faire une analogie avec une réaction chimique. Dans le cas par exemple des tôles à grains orientés, avec leurs structures en domaines simples, la modification de l'aimantation est due en grande partie aux mouvements des parois de Bloch à 180°. Alors, le retournement des moments magnétiques peut être considéré comme le basculement d'un état '+' vers un état '-' qui correspond à une modification du spin des atomes de Fer. Ce qui conduit à faire une analogie avec une réaction chimique.

Aussi, un matériau magnétique est composé d'atomes qui selon leur spin ont un moment positif ou négatif. On les note respectivement S^+ et S^- . Soumis à un champ magnétique extérieur, l'aimantation varie selon deux réactions irréversibles:



Par équilibre thermodynamique de (2.14) et par introduction d'une équation de conservation, l'aimantation du matériau M' due aux retournements des moments magnétiques vaut quand le champ H augmente :

$$M' = M'_{sat} \cdot \tanh[(\beta \cdot h_T / 2) \cdot \ln(\exp(H / h_T) + b) - \beta \cdot H_c / 2] \quad (2.16)$$

Où M'_{sat} est l'aimantation de saturation.

h_T : une constante

b : dépend du sens de variation du champ H , il est calculé de sorte que les formes d'ondes calculées soient continues.

H_c : Champ coercitif

β : Paramètre du modèle.

Quand au H on aura :

$$M' = -M'_{sat} \cdot \tanh[(\beta \cdot h_T / 2) \cdot \ln(\exp(-H / h_T) + b) - \beta \cdot H_c / 2] \quad (2.17)$$

Le modèle est caractérisé par quatre paramètres qui peuvent être identifiés par deux cycles centrés, l'un obtenu à saturation technique et l'autre à un niveau plus bas d'induction. Il a des performances remarquables aussi bien pour la fiabilité que pour la simplicité d'utilisation.

2.3 Hystérésis dynamique

L'ensemble des modèles cités reste des modèles statiques caractérisés par les successions des états et non pas par les temps de basculement d'un état à un autre.

Cependant, les résultats expérimentaux montrent que les cycles d'hystérésis mesurées sont fonction des dérivées temporelles et ils s'élargissent en fonction de la fréquence d'où leurs appellations par hystérésis dynamiques (Bertotti, 1998). Les modèles dynamiques sont capables de prendre en compte les courants induits et les pertes dynamiques de l'hystérésis. Ils interviennent en tenant compte de la dérivée première de l'induction et éventuellement du champ. Une équation différentielle est souvent au centre du modèle et son application est associée à un modèle statique de l'hystérésis.

2.3.1 Modèle de Preisach-Bertotti

Ce modèle est basé sur la généralisation dynamique d'un ensemble de commutateurs ((Bertotti et al, 1993), (Bernard et al, 2001)) intégrant tout type de processus d'aimantation dont le mécanisme principal est représenté par le déplacement des parois magnétiques.

Cette adaptation s'effectue par attribution aux commutateurs $\gamma_{a,b}$ d'une loi dynamique de changement d'état fonction de la dérivée temporelle du flux élémentaire par l'introduction d'un nouveau paramètre k lié à la mobilité des parois magnétiques.

$$\begin{aligned} \partial_t \gamma_{a,b} &= k(H - a) \quad \text{si } H \geq a \text{ et } \gamma_{a,b} < +1 \\ \partial_t \gamma_{a,b} &= k(H - b) \quad \text{si } H \leq b \text{ et } \gamma_{a,b} > -1 \\ \partial_t \gamma_{a,b} &= 0 \quad \text{ailleurs} \end{aligned} \quad (2.18)$$

La résultante de l'aimantation du matériau reste liée aux caractéristiques précédentes du matériau par l'intermédiaire d'une mémorisation de l'état du plan de Preisach. L'aimantation finale du matériau s'établit avec une certaine constante de temps définie par la mobilité des parois.

$$\begin{aligned}
dM_{dH} > 0 &= \iint_{\Delta(H, H_{i-1})} p(a, b) d\gamma_{a,b} dadb \\
dM_{dH} < 0 &= \iint_{\Delta(H_{i-1}, H)} p(a, b) d\gamma_{a,b} dadb
\end{aligned}
\tag{2.19}$$

En effet, la restitution des cycles dépend de la fréquence de variation du champ magnétique appliqué.

2.3.2 Modèle de Raulet-Masson

Le modèle est une contribution aux développements de modèles de comportement des matériaux utilisés dans les actionneurs électriques ((Raulet et al, 2004), (Raulet et al, 2000), (Raulet et al, 1998)). Il permet la description des effets dynamiques microscopiques dus aux mouvements des parois introduits empiriquement ((Fraisie et al, 1995), (Marthouret et al, 1995)) par une loi de comportement différentielle non-univoque. Cependant, l'introduction du modèle dans une équation de diffusion de champ magnétique permet une description complète de l'ensemble des effets dynamiques qui se produisent dans le matériau. Le modèle fait intervenir un coefficient comportemental du matériau pratiquement indépendant de la géométrie et de l'excitation du matériau utilisé.

$$\beta \cdot d_t B = (H - H_{sat}(B)) \tag{2.20}$$

L'inconvénient de ce modèle qui n'a besoin que d'un seul paramètre est l'alourdissement des calculs qui affecte l'amélioration des résultats.

2.3.3 Modèle de Kedous-Chevalier (LS)

La première approche du modèle LS est basée sur un grand nombre de cycles mesurés sur cadre Epstein. Toutefois, il a été contraint par plusieurs difficultés, c'est pourquoi une nouvelle mouture plus élaborée et précise a été développée et implantée dans le logiciel de calcul du champ Flux2D pour huit nuances de matériaux différentes (Thiery, 2005). Ce nouveau modèle présente une description du comportement physique réel d'un matériau par une approche différente tout en préservant la possibilité d'adaptation des paramètres de la mobilité des parois en cours du cycle (Chevalier et al, 2000).

$$\begin{aligned}
H(B, \partial_t B) &= H_s(B) + H_{dyn}(B, \partial_t B) \\
H_{dyn}(B, \partial_t B) &= (C_0 + C_1 * \text{signe}(\partial_t B) * B) * \partial_t B
\end{aligned}
\tag{2.21}$$

L'écriture de la contribution dynamique peut adopter une multitude de formes (Chevalier, 1999), avec possibilité de superposer les diverses composantes dans une version vectorielle (Chevalier, 2000).

2.3.4 Modèle de Jiles-Szczyglowski

Ce modèle est la version dynamique du modèle de Jiles-Atherton. Elle a été développée par J. Szczyglowski en 2001 (Salvini et al, 2001), (Szczyglowski, 2001). Le modèle consiste à compléter la définition du champ interne effectif H_{eff} par ajout d'un champ d'amortissement dynamique :

$$H_{eff} = H + \alpha M + \beta \partial_t M \tag{2.22}$$

2.3.5 Modèle de Kuczmann basé sur des techniques intelligentes

Kuczmann dans ces travaux et sur la base de la théorie de Kolmogorov-Arnold sur la capacité des réseaux de neurones artificiels d'approximer n'importe quelle fonction non-linéaire continue représentée par un ensemble discret de point mesurés, à développer un modèle d'hystérésis magnétique scalaire. Une généralisation vectorielle pour la description de l'isotropie et l'anisotropie des matériaux magnétique en deux et en trois dimensions par une méthode d'identification originale été aussi présentée. Le modèle de réseau de neurone développé se compose de deux réseaux à rétropropagation utilisant une fonction de transfert de type sigmoïde bipolaire et un heuristique type Si-Alors de connaissance de base du phénomène d'hystérésis pour la sélection du réseau de neurone (Kuczmann et al, 2001) et (Kuczmann et al, 2002). La conception du modèle nécessite la disponibilité de la courbe anhystérétique et les branches descendante ou ascendante des courbes de renversement du premier ordre. La normalisation des valeurs se fait par rapport à l'induction ou à l'aimantation de saturation et à une valeur appropriée du champ magnétique appliqué.

2.4 Modèle de Preisach

Un des modèles les plus utilisés pour représenter l'hystérésis d'un matériau magnétique, mais aussi de n'importe quel autre système hystérétique, est basé sur les travaux de F.Preisach qui ont été publiés en 1935. La définition précise du domaine d'application et des données expérimentales nécessaires à l'identification rend ce modèle séduisant, malgré une implantation numérique qui reste assez lourde.

L'approche de ce modèle est totalement intuitive, elle est basée sur la compréhension du mécanisme d'aimantation. D'après O.Bottauscio et al (Bottauscio et al, 19..), le travail de Preisach a été repris par d'autres chercheurs, notamment par Mayergoyz (Mayergoyz, 1986), cependant 60% des travaux publiés dans des revues internationales sont de type Preisach. L'idée fondamentale de ce dernier est que tout système hystérétique peut se mettre sous la forme d'une combinaison de plusieurs éléments du système hystérétique le plus simple possible: l'hystéron (Fig.2.6) ayant deux états magnétiques possibles: soit $M=+1$ ou $M=-1$. Le basculement entre ces deux états stables s'effectue de façon irréversible. Ce cycle est caractérisé par deux paramètres: ce sont les champs de basculement vers $M=+1$, noté α et celui du basculement vers $M=-1$, noté β ($\alpha \geq \beta$).

2.4.3 Principe du modèle

Cette présentation générale s'appuie principalement sur le document de cours de Bossavit (Bossavit.A et al, 1995).

2.4.3.1 Définition

Le schéma de la figure 2.1 définit l'opérateur hystérésis élémentaire $\phi_{\alpha\beta}$ appelé hystéron. Cet opérateur possède deux états stables $+1$ et -1 ; il est caractérisé par α et β , valeurs de p pour lesquelles il y a changement d'état.

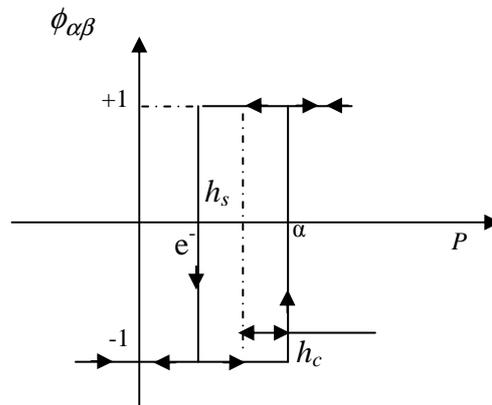


Figure 2.6 : Définition de l'hystéron

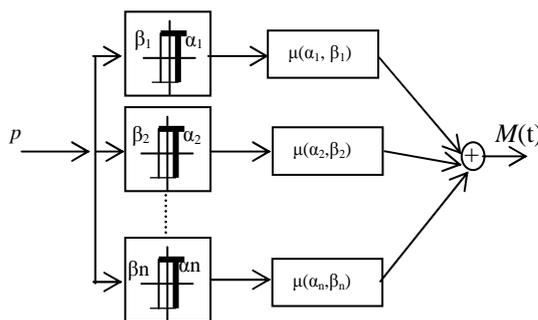


Figure 2.7 : Transducteur de Preisach

La combinaison d'un ensemble constitué d'un certain nombre d'hystérons (Fig.2.7) permet de décrire des systèmes hystérétiques complexes. Cependant, en choisissant judicieusement les hystérons, on peut aboutir à des systèmes proches de la réalité. La distribution de ces particules est caractéristique du matériau considéré et elle est décrite par une fonction de distribution des deux variables α, β appelée densité de Preisach $p(\alpha, \beta)$. L'aimantation du matériau s'écrit de manière simplifiée comme une somme sur toutes les particules élémentaires dont l'état est défini par le champ $H(t)$ appliqué:

$$M(t) = \iint_{\alpha \geq \beta} \phi_{\alpha\beta}(H(t)) \cdot p(\alpha, \beta) d\alpha d\beta \quad (2.23)$$

En magnétisme, on rattache souvent ce cycle à celui de particules mono domaine caractérisées par un champ coercitif h_c et soumises à un champ d'interaction h_i opposé au champ h_s représenté sur la figure 2.6. Les expressions donnant les relations entre les paramètres α, β, h_i et h_c sont:

$$h_c = 1/2(\alpha - \beta) \quad (2.24)$$

$$h_c = -1/2(\alpha + \beta) \quad (2.25)$$

Le modèle peut donc être vu comme la représentation statistique d'un ensemble de particules caractérisés par leur champ coercitif et le champ d'interaction qu'elles voient et il ne peut en aucun cas être rattaché à un objet physique bien identifié (Bossavit.A et al, 1995).

2.4.3.2 Interprétation géométrique

Soit le plan (α, β) de la figure 2.8 appelé triangle de Preisach. A chaque point de ce plan est associé un opérateur $\phi_{\alpha\beta}$.

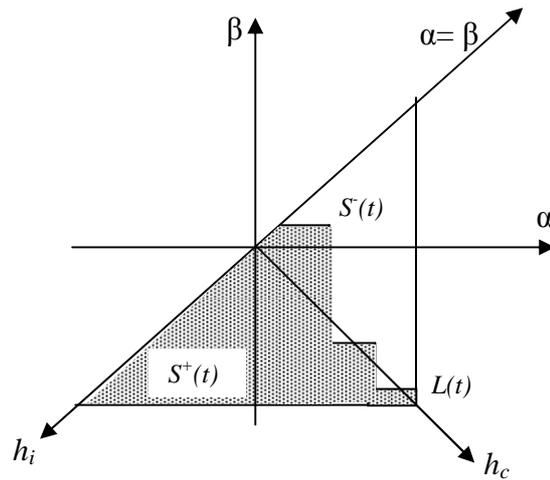


Figure 2.8 : Triangle de Preisach

A tout moment t , le plan de Preisach est divisé en deux régions: $S^+(t)$ représentant l'ensemble des points (α, β) tels que :

$$\phi_{\alpha\beta}(p(t)) = +1 \quad (2.26)$$

et $S^-(t)$, l'ensemble des points (α, β) tels que :

$$\phi_{\alpha\beta}(p(t)) = -1 \quad (2.27)$$

L'aimantation résultante s'écrit alors :

$$M(t) = \iint_{S^+(t)} P(\alpha, \beta) d\alpha d\beta - \iint_{S^-(t)} P(\alpha, \beta) d\alpha d\beta \quad (2.28)$$

Soit la ligne brisée $L(t)$ séparant les deux régions S^+ et S^- . Quand $H(t)$ varie dans le temps, les opérateurs $\phi_{\alpha\beta}$ tels que $H(t) > \alpha$ commutent à -1 (ou restent dans cet état s'ils y étaient déjà). La zone $S^+(t)$ s'étend donc par déplacement de la droite verticale $\alpha=H(t)$ de la gauche vers la droite. Cependant, quand $H(t)$ diminue, les opérateurs $\phi_{\alpha\beta}$ tels que $H(t) < \beta$ commutent à -1 (ou restent dans cet état s'ils y étaient déjà). La zone $S^-(t)$ s'étend donc par déplacement de la droite horizontale $\beta=H(t)$ de haut en bas.

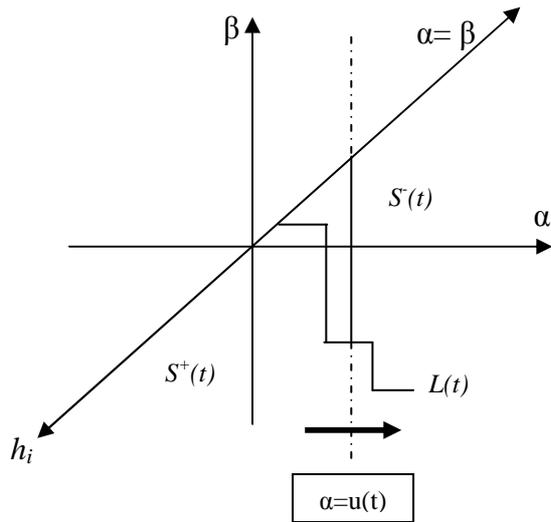


Figure 2.9 Déplacement verticale de $L(t)$

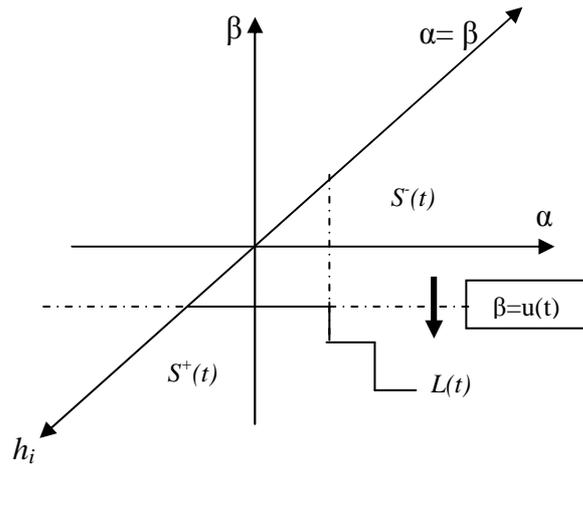


Figure 2.10 Déplacement horizontal de $L(t)$

La forme de la fonction $L(t)$ dépend des extrema de $H(t)$. Pratiquement, les cycles d'hystérésis modélisés sont fermés, alors, la fonction $H(t)$ est bornée et sa représentation finale est la suivante :

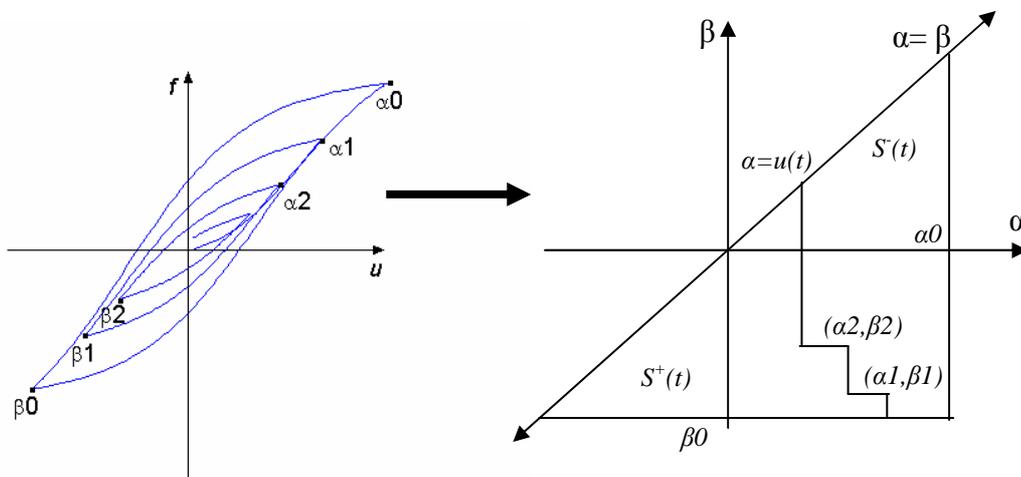


Figure 2.11.a Cycle d'hystérésis et état de déplacement de la frontière $L(t)$ correspondante.

2.4.4 Propriétés du modèle

Deux propriétés fondamentales sont nécessaires et suffisantes pour qu'un système hystérique soit décrit par le modèle de Preisach. Il s'agit de l'effet de mémoire et de la congruence (Mayergoyz, 1986)

2.4.2.1 Effacement partiel

L'évolution de la droite $L(t)$ provoque l'effacement de certaines informations. En effet, les sommets $(\alpha_i; \beta_i)$ tels que $\alpha_i \leq H(t)$ ou $\beta_i \geq H(t)$ sont effacés. A un instant t donné, la suite des extrema stockés peut être définie comme suit :

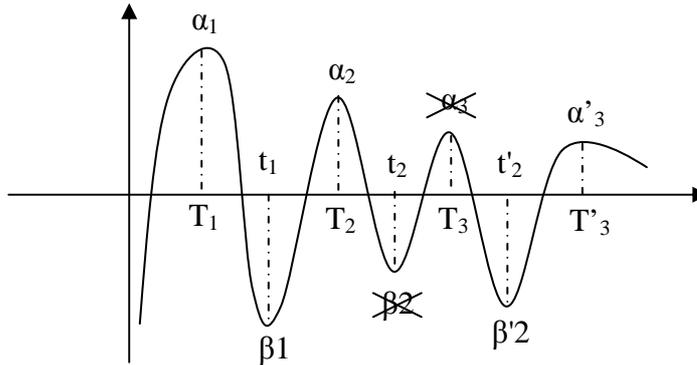


Figure 2.11.b Evolution de la frontière et effacement partiel de l'histoire

$$\begin{aligned}
 \alpha_1 &= \max\{H(t), t > 0\}, & \beta_1 &= \min\{H(t), t > T_1\} \\
 \alpha_2 &= \max\{H(t), t > t_1\}, & \beta_2 &= \min\{H(t), t > T_2\} \\
 \alpha_3 &= \max\{H(t), t > t_2\}
 \end{aligned}
 \tag{2.29}$$

L'oscillation entre T_2 et t_2' est effacée par un minimum ultérieur plus petit. Ceci se traduit par des cycles mineurs fermés et susceptibles d'être complètement gommés de l'histoire du matériau. Dans l'exemple suivant, le cycle mineur décrit quant $H(t)$ varie entre α_2 et β_2 disparaît de l'histoire- mais pas les pertes associées (figure 2.12).

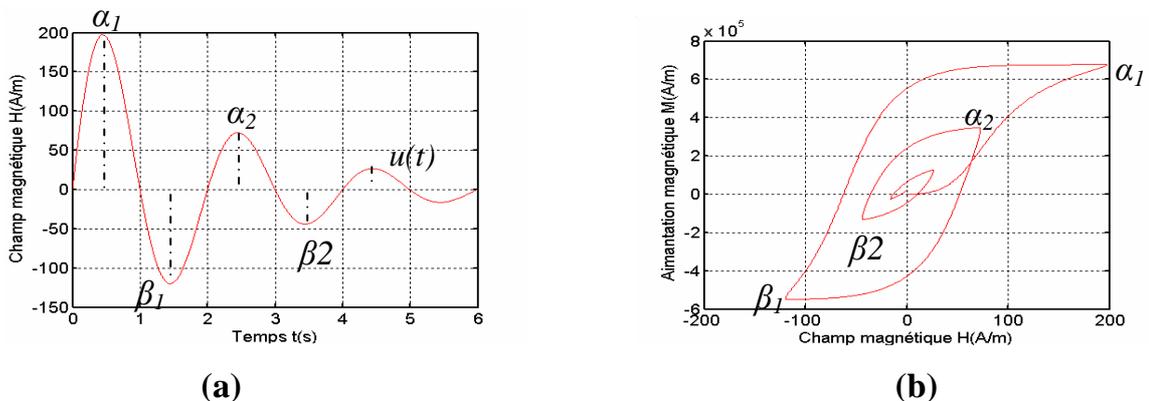


Figure 2.12 : Description des cycles mineurs

(a) : Champ magnétique amorti (b) : Cycle équivalent et cycles mineurs

Cette propriété est très intéressante, elle fait du modèle de Preisach l'outil privilégié de modélisation du phénomène d'hystérésis magnétique.

2.4.2.2 Congruence des cycles mineurs

La variation d'aimantation engendrée par une variation d'excitation ne dépend que de la surface balayée mais pas de l'état dans lequel était précédemment cette surface. Il en résulte qu'entre deux valeurs extrêmes de l'entrée, Les cycles mineurs L_1 et L_2 correspondant se superposent par translation verticale. La figure 2.13 illustre ce processus :

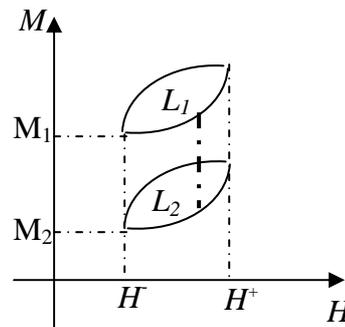


Figure 2.13 : Phénomène de congruence des cycles mineurs

2.4.2.3 Domaine d'application

Les deux propriétés énoncées sont intrinsèques au modèle de Preisach. Lorsque celui-ci est appliqué à la modélisation de l'hystérésis magnétique, on peut lui ajouter deux autres propriétés. La première repose sur la symétrie physique du phénomène d'hystérésis magnétique et la seconde concerne la représentation de l'état désaimanté et donc de la courbe de première aimantation.

2.4.3 Méthodes d'identification

Une fois le modèle est défini, il faut se pencher sur les méthodes d'identifications de ces paramètres à partir des données expérimentales. Plusieurs approches, plus ou moins générales appartenant à deux grandes familles de méthodes (numériques et analytiques), sont possibles. La première utilise les courbes de renversement du premier ordre du matériau et permet de déterminer la distribution de Preisach sans aucune hypothèse restrictive sur cette distribution. La seconde suppose une factorisation de cette distribution qui permet de réduire le nombre de données expérimentales nécessaires mais ne s'applique qu'aux matériaux doux. La dernière, utilise une expression analytique a priori de la distribution de Preisach qui est remis en question pour chaque type de matériau étudié (Bossavit et al, 1995).

2.4.3.1 Utilisation des courbes de renversement

2.4.3.1.a Courbes de renversements

Ce sont les branches de cycles mineurs rattachés au cycle majeur. On les obtient à partir d'un état donné par accroissement et décroissement entre deux valeurs de l'entrée du système. Cet ensemble de cycles expérimentaux permet théoriquement la détermination de la fonction de distribution $P(\alpha, \beta)$.

2.1.3.1.b Détermination de $P(\alpha, \beta)$

Pour la fonction M définie par $M(\alpha, \beta) = \frac{1}{2} (M_\alpha - M_{\alpha\beta})$, la fonction P peut être déterminée par double dérivation de M . Les expressions de M_α et $M_{\alpha\beta}$ sont données par :

$$M_\alpha = \iint_{S\alpha^+} P(\alpha', \beta') d\alpha' d\beta' - \iint_{S\alpha^-} P(\alpha', \beta') d\alpha' d\beta' \quad (2.30)$$

$$M_{\alpha\beta} = \iint_{S\alpha\beta^+} P(\alpha', \beta') d\alpha' d\beta' - \iint_{S\alpha\beta^-} P(\alpha', \beta') d\alpha' d\beta' \quad (2.31)$$

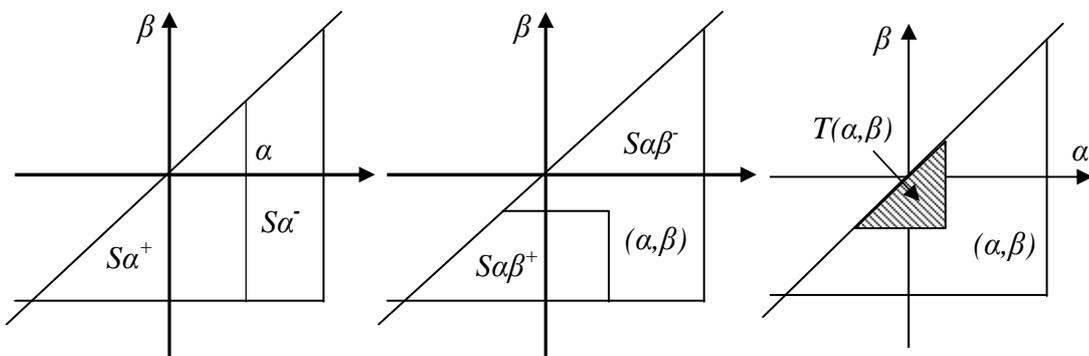


Figure 2.14 : Processus d'aimantation

Une interprétation géométrique montre que :

$$M(\alpha, \beta) = \frac{1}{2} (M_\alpha - M_{\alpha\beta}) = \iint_{T(\alpha, \beta)} M(\alpha', \beta') d\alpha' d\beta' \quad (2.32)$$

Ce qui s'écrit aussi :

$$M(\alpha, \beta) = \int_{\beta}^{\alpha} \int_{\beta}^{\alpha'} P(\alpha', \beta') d\beta' d\alpha' \quad (2.33)$$

D'où :

$$P(\alpha, \beta) = \frac{\partial^2 F}{\partial \alpha \partial \beta}(\alpha, \beta) \quad (2.34)$$

La fonction P est déterminée à partir des données expérimentales en faisant une double dérivation qui présente une source d'erreur très importante. Certains chercheurs ont construit des dispositifs de mesure capables d'évaluer directement cette distribution (Bossavit.A et al, 1995).

2.1.3.1.c Formule explicite de $M(t)$

Pratiquement, pour éviter de dériver explicitement les courbes, le calcul de la fonction $M(t)$ se fait directement par décomposition de S^+ et S^- en somme et différence de triangles $T(\alpha_i, \beta_i)$ (figure 2.15).

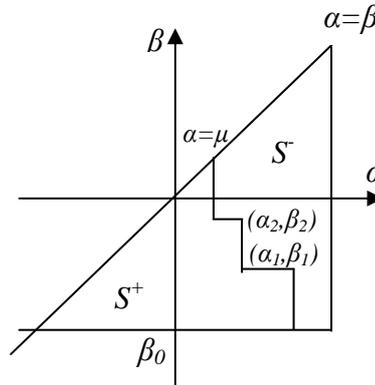


Figure 2.15 : Domaines d'intégration de l'aimantation $M(t)$

$$S^+ = T(\alpha_1, \beta_0) - T(\alpha_1, \beta_1) + T(\alpha_2, \beta_1) - T(\alpha_2, \beta_2) + \dots + T(\alpha_i, \beta_{i-1}) - T(\alpha_i, \beta_i) + \dots + T(\alpha_n, H(t)) \quad (2.35)$$

$$S^- = T(\alpha_0, \beta_0) - T(\alpha_1, \beta_0) + T(\alpha_1, \beta_1) - T(\alpha_2, \beta_1) + \dots + T(\alpha_i, \beta_i) - T(\alpha_{i+1}, \beta_i) + \dots + T(\alpha_n, \beta_n) - T(H(t), \beta_n) \quad (2.36)$$

$$M(t) = \iint_{S^+} P(\alpha, \beta) d\alpha d\beta - \iint_{S^-} P(\alpha, \beta) d\alpha d\beta \quad (2.37)$$

D'où :

$$M(t) = \iint_{T(\alpha_0, \beta_0)} P(\alpha, \beta) d\alpha d\beta + \sum_{i=1}^m \left[\iint_{T(\alpha_i, \beta_{i-1})} P(\alpha, \beta) d\alpha d\beta - \iint_{T(\alpha_i, \beta_i)} P(\alpha, \beta) d\alpha d\beta \right] + \iint_{T(u(t), \beta_n)} P(\alpha, \beta) d\alpha d\beta \quad (2.38)$$

Donc :

$$M(t) = -M(\alpha_0, \beta_0) + 2 \sum_{i=1}^n (M(\alpha_i, \beta_{i-1}) - M(\alpha_i, \beta_i) + 2M(H(t), \beta_n)) \quad (2.39)$$

C'est une formule simple utilisant directement les résultats expérimentaux. Notons que cette formule est légèrement modifiée selon l'état initial de saturation et le sens de variation de $H(t)$.

2.4.3.2. Méthode de Biorci et Pescetti

C'est une méthode simple à mettre en œuvre car elle ne nécessite que la courbe de première aimantation et le cycle majeur comme données expérimentales (Biorci et al, 1958). Elle s'appuie sur une factorisation de la fonction de distribution de Preisach sous forme :

$$P(\alpha, \beta) = P_1(\alpha) \cdot P_2(\beta) \quad (2.40)$$

Le plan de Preisach est discrétisé suivant une grille et les valeurs de P sont déterminées en chaque point de cette grille. Pour cela, on définit les fonctions :

$$M_i = \frac{1}{2M_{sat}} \int_{a_{i-1}}^{a_i} \int_{-\alpha}^{\alpha} P(\alpha, \beta) d\alpha d\beta \quad (2.41)$$

$$G_i = \frac{1}{2M_{sat}} \int_{b_j}^{b_{j-1}} \int_{|\beta|}^{H_{sat}} P(\alpha, \beta) d\alpha d\beta \quad (2.42)$$

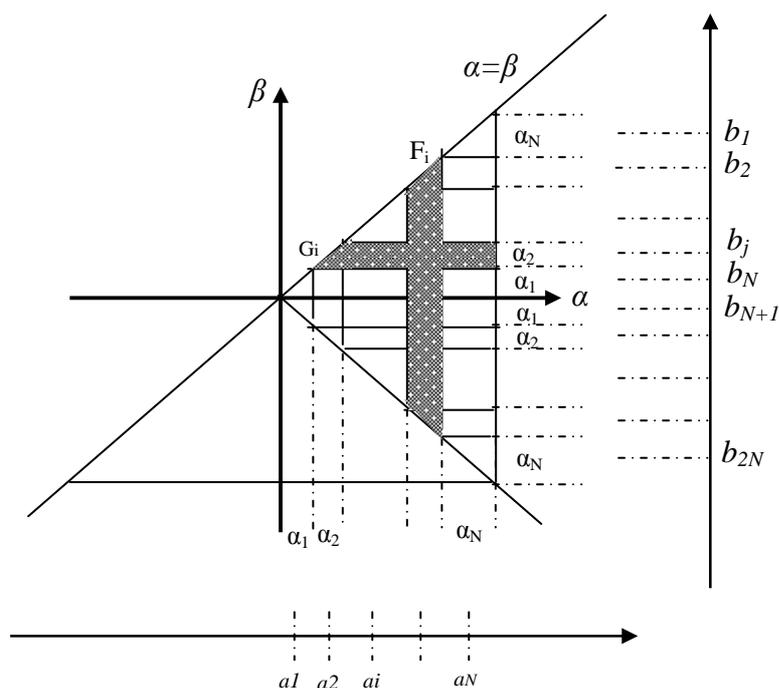


Figure 2.15a: Discretisation du triangle de Preisach selon la méthode De Biorci et Pescetti

H_{sat} et M_{sat} étant les valeurs de H et de M au point de saturation.

Partant du diagramme de Preisach, les fonctions F_i et G_j peuvent être exprimées à l'aide de la courbe de première aimantation $M_{ini}(H)$ et de la branche supérieure du cycle majeur $M_{sat}(H)$:

$$M_i = \frac{1}{2M_{sat}} (M_{ini}(a_i) - M_{ini}(a_{i-1})) \quad (2.43)$$

$$\begin{cases} \text{si } b_j \geq 0: & G_j = \frac{1}{2M_{sat}} [M_{sat}(b_{j-1}) - M_{sat}(b_j)] \\ \text{si } b_{j-1} \leq 0: & G_j = \frac{1}{2M_{sat}} \left([M_{sat}(b_{j-1}) - M_{sat}(b_j)] - [M_{ini}(-b_j) - M_{ini}(-b_{j-1})] \right) \end{cases} \quad (2.44)$$

En discrétisant les intégrales définissant M_i et G_j , on obtient un système de $3N$ équations à $3N$ inconnues qui sont $P_1(a_i)$ et $P_2(b_j)$:

$$\left\{ \begin{array}{l} M_1 = \alpha_1 \cdot P_1(a_1) \cdot [\alpha_1 \cdot P_2(a_N) + \alpha_1 \cdot P_2(b_{N+1})] \\ \dots\dots\dots \\ M_N = \alpha_N \cdot P_1(a_N) \cdot \left[\begin{array}{l} \alpha_N P_2(b_1) + \alpha_{N-1} \cdot P_2(b_2) + \dots + \alpha_1 \cdot P_2(b_N) \\ + \alpha_1 P_2(b_{N+1}) + \dots + \alpha_{N-1} \cdot P_2(b_{2N-1}) + \dots + \alpha_N \cdot P_2(b_{2N}) \end{array} \right] \end{array} \right. \quad (2.45)$$

$$\left\{ \begin{array}{l} G_1 = \alpha_N \cdot P_2(b_1) \cdot \alpha_N \cdot P_1(a_N) \\ \dots\dots\dots \\ G_{2N} = \alpha_N \cdot P_2(b_{2N}) \cdot \alpha_N \cdot P_1(a_N) \end{array} \right. \quad (2.46)$$

Après résolution du système d'équation nous obtenons les valeurs des fonctions P_1 et P_2 aux points du triangle de Preisach. Cette méthode a donné de bons résultats dans le cas de tôles à grains non orientés avec $N=10$ (Bossavit.A et al, 1995).

2.4.3.3 Choix d'une fonction à priori

Les deux méthodes précédentes conduisent à la détermination numérique de la distribution de Preisach, sans hypothèse particulière. Une autre vision consiste à chercher une forme analytique de la fonction de distribution permettant ainsi la reproduction du cycle majeur. Cependant, il n'existe pas une forme générale pour ces fonctions à cause de leurs dépendances du matériau utilisé. Le principal avantage de cette approche est le nombre réduit des paramètres pouvant être déterminées à partir de données expérimentales. En effet, l'expression de la fonction de distribution doit être remise en cause dès que l'on change de matériau.

Dans ces travaux, Bertotti utilise des distributions lorentziennes données par:

$$P_1(\alpha) = 1/(1+(\alpha/H_c - 1/2)^2) \quad (2.47)$$

et

$$P_2(\beta) = 1/(1+(\beta/H_c - 1/2)^2) \quad (2.48)$$

$$P(\alpha, \beta) = K_n \cdot \mu_0(\alpha) \cdot \mu_2(\beta) \quad (2.49)$$

Le critère d'adéquation de ces distributions et qu'elles conduisent la même surface de cycle et donc aux mêmes pertes que la mesure, même si la forme du cycle majeur n'est pas parfaitement respectée.

2.4.3.4. Etude du modèle de Preisach avec une fonction analytique

Plusieurs expressions analytiques ont été proposées pour représenter l'approximation de la fonction de distribution de Preisach (Gaussienne, Cauchienne, Lorentzienne,...etc). Les résultats de modélisation et de simulation du modèle en prenant une fonction de distribution unitaire et une fonction Lorentzienne sont présentés dans ces différentes étapes.

2.4.3.4.a Fonction de distribution unitaire

Soit la fonction de distribution unitaire :

$$P(\alpha, \beta) = 1 \quad (2.50)$$

A partir de l'équation (2.28) et pour une variation du champ d'excitation de H_1 jusqu'à H_2 , on aura :

$$M(t_i) = M(t_{i-1}) \pm 2 \iint_{\Delta} d\alpha d\beta \quad (2.51)$$

Δ : la surface formée par les particules qui ont changé d'aimantation (Fig.2.16).

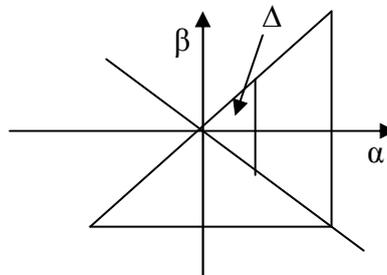


Figure 2.16: Triangle de Preisach

2.4.3.4.b Fonction de distribution Lorentzienne

Définie par :

$$p(\alpha, \beta) = \frac{K\alpha^2}{\left[a + \left(\frac{\alpha}{H_c} - b\right)^2\right] \left[a + \left(\frac{\beta}{H_c} + b\right)^2\right]} \quad (2.52)$$

Avec :

H_c : le champ coercitif.

K : coefficient de régulation.

a et b : paramètres de précision (Ouled Amor et al, 2002).

La distribution dans l'espace avec $a=1$ et $b=0.5$ est représentée dans la figure (Fig.2.17).

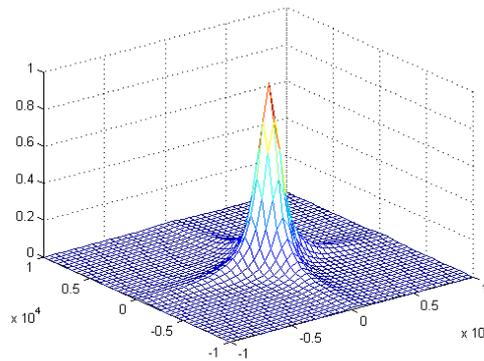


Figure 2.17 : Distribution de la fonction de Lorentz

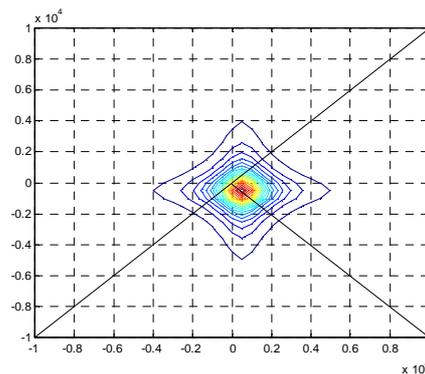


Figure 2.18 Les contours de la fonction de Lorentz

La figure (Fig.2.17) montre clairement que la fonction de Lorentz est complètement définie dans le triangle de Preisach. L'introduction de la fonction de Lorentz dans le modèle de Preisach donne :

$$M(t_i) = M(t_{i-1}) \pm 2 \iint_{\Delta} \frac{K.a^2}{\left[a + \left(\frac{\alpha}{H_c} - b \right)^2 \right] \cdot \left[a + \left(\frac{\beta}{H_c} + b \right)^2 \right]} d\alpha d\beta \quad (2.53)$$

Sachant que :

$$\int \frac{1}{(1+x^2)} dx = \text{Arctg}(x) + \text{Cste} \quad (2.54)$$

L'un des deux intégrales de l'équation (2.53) peut être calculé analytiquement ce qui réduit le temps d'exécution du programme. Pour la génération du cycle d'hystérésis dans les deux cas (Distribution unitaire, Distribution Lorentzienne), nous avons développé un programme sous logiciel Matlab qui permet une meilleure exploitation des résultats et qui présente le cycle en terme d'induction B en fonction du champ H en utilisant la relation :

$$B \cong \mu_0 M \quad (2.55)$$

Notons que la relation (2.55) n'est valable que pour les matériaux doux où on peut négliger le terme $\mu_0 H$ à cause de leurs très faibles valeurs devant l'aimantation M .

2.1.3.4.c Détermination du cycle d'hystérésis

* Courbe de première aimantation

La courbe de première aimantation est déterminée à partir de l'état initial du matériau ferromagnétique, dans cet état le domaine S^+ occupe la moitié du triangle de Preisach et l'autre moitié est occupée par le domaine S^- (fig 2.18.a). L'application d'un champ magnétique extérieur croissant de H_1 à H_2 augmente la surfaces des hystérons positifs S^+ par la surface S' (fig 2.18.b). Les figures (2.19.a) et (2.19.b) représentent respectivement la courbe de première aimantation générée par l'utilisation de la fonction de distribution unitaire et la fonction de distribution de Lorentz pour une variation du champ de 0 jusqu'à la saturation du matériau notée par H_{sat} .

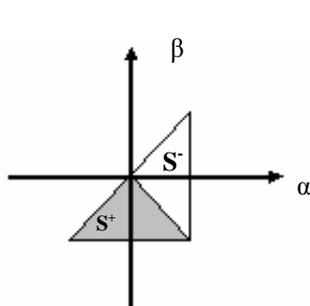


Figure 2.18.a: Etat désaimanté du matériau ferromagnétique

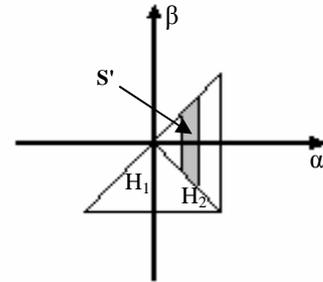


Figure 2.18.b : Variation de l'excitation dans le triangle de Preisach

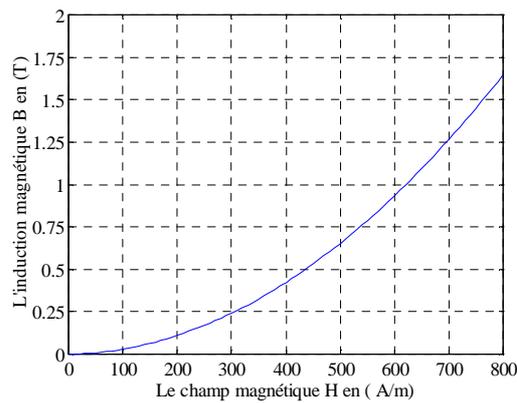


Figure 2.19.a : Courbe de première aimantation générée

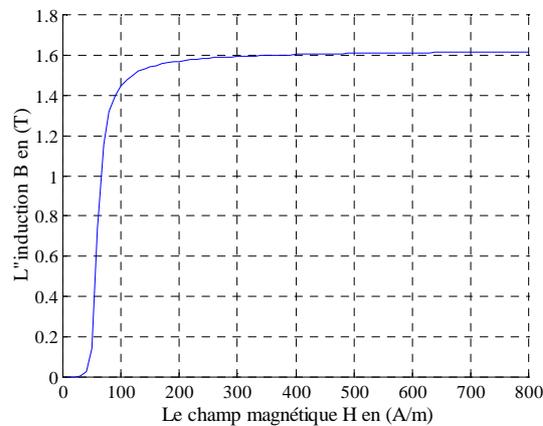


Figure 2.19.b : Courbe de première aimantation générée par une fonction de distribution Lorentzienne

*** Branche descendante du cycle**

La branche descendante du cycle est déterminée à partir de l'état de saturation positif (Basculement total de S^- en S^+). Cette situation est représentée par la figure (2.20.a). La variation du champ extérieur H dans le sens décroissant de H_{sat} à H_1 fait basculer toutes les particules élémentaires (Hystérons) appartenant à l'intervalle $H_1 \leq \beta \leq H_{sat}$ de $+1$ à -1 .

La courbe descendante est obtenue par une diminution du champ appliqué de H_{sat} à $-H_{sat}$ et elle est illustrée par les figures (2.21.a) pour une distribution unitaire et (2.21.b) pour une distribution Lorentzienne.

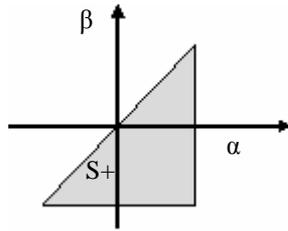


Figure 2.20.a : Etat de saturation positive du matériau ferromagnétique

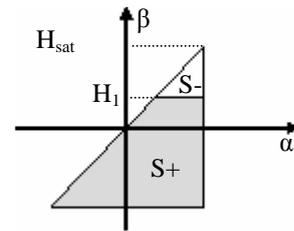


Figure 2.20.b : Evolution des frontières de Preisach pour une excitation décroissante

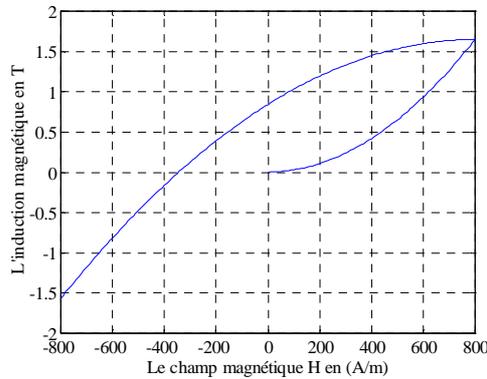


Figure 2.21.a Courbe descendante générée par une distribution unitaire

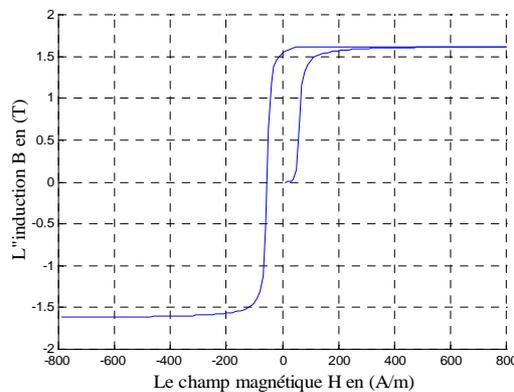


Figure 2.21.b Courbe descendante générée par une Fonction de distribution Lorentzienne

* Branche ascendante du cycle

A partir de l'état de saturation négative du matériau, et par application d'un champ croissant de $-H_{\text{sat}}$ jusqu'à H_{sat} on obtient la branche ascendante du cycle d'hystérésis de l'échantillon ferromagnétique (figure 2.22).

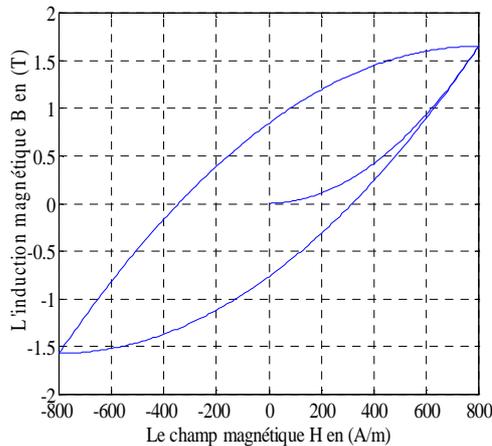


Figure 2.22.a : Cycle d'hystérésis généré par une distribution unitaire

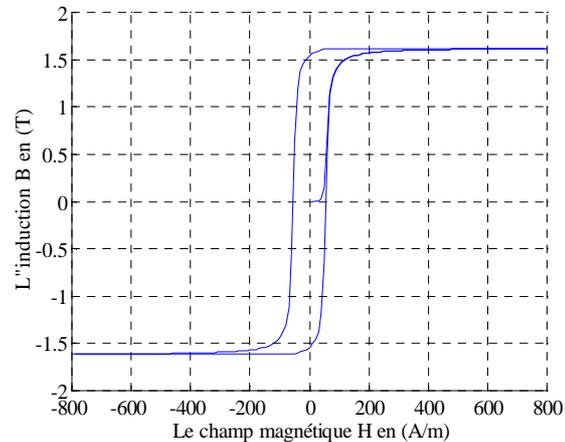


Figure 2.22.b : cycle d'hystérésis généré par une distribution Lorentzienne

Les résultats de simulation obtenus montrent une différence importante entre les deux fonctions unitaire et Lorentzienne. La fonction unitaire ne décrit pas le phénomène physique alors que la fonction de Lorentz restitue convenablement le comportement du matériau ferromagnétique. Cette différence est due au choix des paramètres H_c , du coefficient de réglage K et des paramètres de précision a et b .

La production de la forme du cycle exige une introduction des paramètres du matériau magnétique obtenus par la mesure dans la fonction de distribution ce qui montre l'importance du choix de la fonction de distribution dans le modèle étudié.

2.5 Conclusion

Le modèle de Preisach reste le modèle le plus adapté à la représentation de l'hystérésis, probablement parce qu'il correspond à la nature même des phénomènes dans les matériaux magnétiques. Il apparaît le plus adéquat sur le plan mathématique, physique et phénoménologique. De plus, c'est l'un des rares modèles dont les propriétés et le domaine d'application soient aussi clairement définis. Plusieurs approches sont disponibles dans la littérature qui permet la détermination des paramètres du modèle, mais la plus précise reste la méthode des courbes de renversements.

*Logique floue
et systèmes neuro-flous*

3.2 Introduction

Cette introduction à la théorie de la logique floue et des systèmes neuro-flous est inspirée des travaux de (Abraham, 2005), (Yann, 2001), (Arbaoui, 2006) et (Daniel, 2006) que l'on pourra consulter pour compléter les concepts de base que nous allons présenter.

La logique floue a pour but de raisonner à partir de connaissances imparfaites qui opposent à la logique classique. Elle se propose de remplacer les variables booléennes de la logique classique par des variables floues.

3.3 Historique et définition

Depuis longtemps l'homme recherche à maîtriser les incertitudes et les imperfections inhérentes à sa nature. Ceci, donc à permet l'apparition de la logique floue constituée principalement de l'apparition de la théorie des sous-ensembles flous de Lotfi Zadeh en 1965 à Berkeley et la théorie des possibilités développée en 1978. En effet, la publication par Lotfi Zadeh du livre 'Fuzzy sets' qui développe la théorie d'ensembles multi-valués et qui introduit le terme flou dans la littérature scientifique à étendu la fonction indicateur bivalent I_A d'un sous-ensemble non-flou A de X

$$I_A(x) = \begin{cases} 1 & \text{si } x \in A \\ 0 & \text{si } x \notin A \end{cases} \quad (3.1)$$

en une fonction appelée fonction d'appartenance $m_A : X \rightarrow [0, 1]$.

La combinaison des ensembles flous avec l'opérateur 'point' des fonctions d'appartenances :

$$I_{A \cap B}(x) = \min(I_A(x), I_B(x)) \quad (3.2)$$

$$I_{A \cup B}(x) = \max(I_A(x), I_B(x)) \quad (3.3)$$

$$I_{A^c}(x) = 1 - I_A(x) \quad (3.4)$$

$$A \subset B \quad \text{ssi} \quad I_A(x) \leq I_B(x) \quad \text{pour tout } x \in X \quad (3.5)$$

La valeur d'appartenance $m_A(x)$ mesure les degrés avec l'élément x appartenant à l'ensemble A .

$$m_A(x) = \text{deg rés}(x \in A) \quad (3.6)$$

3.2.1 Degré d'appartenance

C'est un nombre réel pris dans l'intervalle fermé $[0, 1]$, il mesure l'incertitude avec un objectif définit. Les degrés d'appartenances mesure l'incertitude ou la croyance par rapport à une notion vague. Cette mesure indique suivant l'univers du discours considéré et les conventions adoptées, l'appartenance à des degrés divers des individus aux sous-ensembles considérés.

On note la valeur d'appartenance d'un sous-ensemble A à un ensemble B par $S(A,B) = \text{Degrés}(A \subset B)$. La théorie des sous-ensembles offre un environnement d'ensemble théorique unifié.

La théorie des ensembles classiques interdit l'inégalité stricte exprimée par :

$$A \text{ et } 0 < S(B, A) < 1 \quad (3.7)$$

En effet soit chaque ensemble est une partie de l'autre ou alors ils sont disjoints. La théorie des ensembles flous l'autorise. Cependant, les ensembles flous peuvent être considérées comme une généralisation des ensembles classiques.

3.2.2 Définitions et notions sur les ensembles flous

3.2.2.1 Définition d'un ensemble flou

Le concept fondamental dans la théorie des ensembles flous est la notion d'ensemble flou. En effet, un ensemble flou est une classe d'objets avec une échelle continue de degrés d'appartenance. Chaque ensemble est caractérisé par une fonction d'appartenance qui attribue à chaque objet un degré d'appartenance qui s'étend entre 0 et 1 (Zadeh, 1965).

Soit un univers X , on définit un ensemble flou A dans X par l'application de μ_A de X dans l'intervalle $[0, 1]$. A tout élément $x \in X$, on associe la valeur $\mu_A(x)$ tel que

$$0 \leq \mu_A \leq 1 (\mu_A : X \rightarrow [0,1])$$

L'application μ_A est appelée fonction d'appartenance de l'ensemble flou A .

- $\mu_A(x) = 0$, x n'appartient pas à A .
- $\mu_A(x) = 1$, x appartient à A , il satisfait pleinement la propriété A .
- $\mu_A \neq 0, 1$ alors $\mu_A(x)$ est une valeur intermédiaire entre 0 et 1. x appartient à l'ensemble flou A . On dit que $x \in A$ avec le degré $\mu_A(x)$

3.2.2.2 Support d'un ensemble flou

Le support d'un ensemble flou A noté $supp(A)$ est la partie X sur laquelle la fonction d'appartenance $\mu_A(x)$ n'est pas nulle.

$$supp(A) = \{x \in X; \mu_A(x) \neq 0\}$$

3.2.2.3 Noyau d'un ensemble flou

Le noyau de A noté $Ker(A)$ est l'ensemble des éléments de X pour lesquels la fonction d'appartenance normalisée de A vaut 1.

$$Ker(A) = \{x \in X; \mu_A(x) = 1\}$$

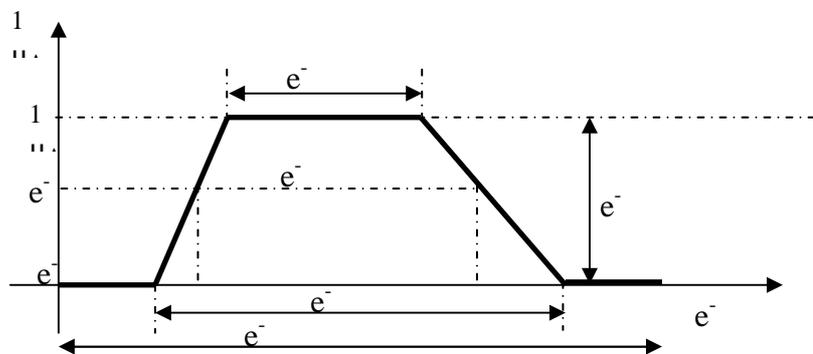


Figure 3.1 Support, hauteur, noyau et α -coupe d'un ensemble flou.

3.2.2.4 Hauteur d'un ensemble flou

La hauteur, notée $H(A)$, d'un ensemble flou A de X est le plus grand degré d'appartenance de A .

$$H(A) = \max(\mu_A(x); x \in X)$$

3.2.2.5 Cardinal d'un ensemble flou

La cardinalité d'un ensemble flou A de X est le degré global avec lequel des éléments de X appartiennent à A . Elle est définie par :

$$Card(A) = \sum_{x \in supp(A)} \mu_A(x) \quad \text{on note aussi } |A|$$

Si A est un ensemble ordinaire de X , sa hauteur est égale à 1 ; il est normalisé et identique à son support et à son noyau ; sa cardinalité est le nombre d'éléments qui le composent selon la définition classique.

3.2.3 Opérations sur les ensembles flous

Les opérations sur les ensembles flous sont des extensions des opérations connues sur les ensembles classiques. Elle permet de d'écrire des combinaisons logiques entre notions floues, c'est-à-dire de faire des calculs sur des degrés de vérité. En effet, si les valeurs d'appartenance sont restreintes aux valeurs 0 et 1, alors les opérateurs flous (Et, Ou, négation,...etc) devraient donner les mêmes résultats que ceux classiques.

3.2.3.1 Égalité

Deux ensembles flous A et B de X sont égaux ($A=B$) si leurs fonctions d'appartenance prennent la même valeur pour tout élément de X :

$$\mu_A(x) = \mu_B(x) \forall x \in X. \text{ Si } \exists x \text{ tel que } \mu_A(x) \neq \mu_B(x) \Rightarrow A \neq B$$

3.2.3.2 Inclusion

Soit deux ensembles flous, A et B de X . L'ensemble A est inclus dans l'ensemble B , ($A \subseteq B$), si leurs fonctions d'appartenance sont telles que :

$$\forall x \in X; \mu_A(x) \leq \mu_B(x)$$

L'inclusion définit une relation d'ordre.

3.2.3.3 Intersection

L'opérateur logique correspondant à l'intersection d'ensembles est le ET. Le degré de vérité de la proposition « A ET B » est le minimum des degrés de vérité de A et de B :

$$\forall x \in X; \mu_C(x) = \min(\mu_A(x), \mu_B(x))$$

3.2.3.4 Union

L'opérateur logique correspondant à l'union d'ensembles est le OU. Le degré de vérité de la proposition " A OU B " est le maximum des degrés de vérité de A et de B .

$$\forall x \in X; \mu_C(x) = \max(\mu_A(x), \mu_B(x))$$

3.2.3.5 Propriétés de l'union et de l'intersection

Propriété : $\forall A \text{ et } B \text{ de } X$

- associativité de \cap et \cup
- commutativité de \cap et \cup
- $A \cap X = A, A \cap \emptyset = \emptyset$
- $A \cup \emptyset = A, A \cup X = X$
- $A \cup B \supseteq A \supseteq A \cap B$
- $A \cup (B' \cup B'') = (A \cap B') \cup (A \cap B'')$
- $A \cup (B' \cap B'') = (A \cup B') \cap (A \cup B'')$
- $|A| + |B| = |A \cap B| + |A \cup B|$

3.2.3.6 Complément d'un sous-ensemble flou

L'opérateur logique correspondant au complément d'un sous-ensemble flou A sur un univers de discours X est défini comme le sous-ensemble flou de X de fonction d'appartenance :

$$\forall x \in X; \mu_{A^c}(x) = 1 - \mu_A(x)$$

On peut énoncer les propriétés suivantes $A^c \cap A = \emptyset$ et $A^c \cup A = X$

3.2.3.7 Propriétés du complément d'un sous-ensemble flou

Propriété: $\forall A \text{ et } B \text{ de } X$

- Loi de Morgan : $(A \cap B)^c = A^c \cup B^c, (A \cup B)^c = A^c \cap B^c$
- $(A^c)^c = A$
- $\emptyset^c = X$
- $X^c = \emptyset$
- $|A| + |A^c| = |X|$
- $(\text{supp}(A^c))^c = \text{Ker}(A)$
- $(\text{Ker}(A^c))^c = \text{supp}(A)$

3.2.3.8 Propriétés des opérateurs sur les ensembles flous

Les choix des opérateurs min pour l'intersection, max pour l'union, complémentation à 1 pour le complément permet de préserver la structure de la théorie classique des ensembles.

3.2.4 Coupe de niveau α ou α -coupe

Une coupe de niveau α ou α -coupe de l'ensemble flou A pour une valeur donnée $\alpha \in [0,1]$ est le sous-ensemble classique A_α de X défini par

$$A_\alpha = \{x; \mu_A(x) \geq \alpha\}$$

On appelle α -niveau une α -coupe telle que $\mu_A(x) = \alpha$ pour tout $x \in A_\alpha$. Et on note

$$A^\alpha = \{x; \mu_A(x) = \alpha\} \text{ On peut en déduire que } A_0 = \text{supp}(A) \text{ et } A_1 = \text{Ker}(A).$$

On peut montrer qu'un ensemble flou A peut être représenté par $C(A)$ l'ensemble de toutes ses α -coupes.

3.2.5 Sous-ensembles flous convexes

* Un sous-ensemble flou A de X des nombres réels est convexe, si pour tout couple d'éléments a et b de X , et pour tout nombre λ de $[0, 1]$ la fonction d'appartenance A vérifie :

$$\mu_A(\lambda a + (1 - \lambda)b) \geq \min(\mu_A(a), \mu_A(b))$$

* Un sous-ensemble flou A de α est convexe si toutes ses α -coupes A_α sont convexes, c-à-d si, pour tout élément a et b de A_α et pour tout nombre λ de $[0,1]$,

$$x = \lambda a + (1 - \lambda)b \text{ appartient aussi à } A_\alpha$$

3.2.6 Produit cartésien de sous-ensemble flou

Soit des sous-ensembles flous A_1, A_2, \dots, A_r respectivement définis sur X_1, X_2, \dots, X_r , on définit leur produit cartésien $A = A_1 \times A_2 \times \dots \times A_r$, comme un sous-ensemble flou de X de la fonction d'appartenance :

$$\forall x = (x_1, x_2, \dots, x_r) \in X, \mu_A(x) = \min(\mu_{A_1}(x_1), \dots, \mu_{A_r}(x_r))$$

3.2.7 Projection d'un sous-ensemble flou

Soit un sous-ensemble flou A défini sur un univers $X_1 \times X_2$, produit cartésien des deux sous-ensembles de références X_1 et X_2 .

La projection sur X_1 du sous-ensemble flou A de $X_1 \times X_2$ est le sous-ensemble flou $Proj_{X_1}(A)$ de X_1 , dont la fonction d'appartenance est définie par :

$$\forall x_1 \in X_1, \mu_{Proj_{X_1}(A)}(x_1) = \max_{x_2 \in X_2} \mu_A(x_1, x_2)$$

3.2.8 Normes et conormes triangulaires

On peut remplacer les opérations usuelles sur les sous-ensembles flous (intersection, union...) par d'autres opérateurs que le min, max et complément à 1.

* Une norme triangulaire (t-norme) est une fonction T :

$$[0, 1] \times [0, 1] \rightarrow [0, 1]$$

qui vérifie pour tout u, v et w de $[0, 1]$. La fonction T est commutative, associative et isotone.

- $T(u, v) = T(v, u)$ (Commutativité)
- $T(u, T(v, w)) = T(T(u, v), w)$ (Associativité)
- $T(u, v) \leq T(w, t)$ si $u \leq w$ et $v \leq t$ (Isotonie)
- $T(u, 1) = u$ (Élément neutre 1)

* Une conorme triangulaire (t-conorme) est une fonction \perp :

$$[0, 1] \times [0, 1] \rightarrow [0, 1]$$

qui vérifie pour tout u, v et w de $[0, 1]$. La fonction (t-conorme) est commutative, associative et isotone.

qui vérifie pour tout u, v et w de $[0, 1]$:

- $\perp(u, v) = \perp(v, u)$ (Commutativité)
- $(u, \perp(v, w)) = \perp(\perp(u, v), w)$ (Associativité)
- $\perp(u, v) \leq \perp(w, t)$ si $u \leq w$ et $v \leq t$ (Isotonie)
- $\perp(u, 0) = u$ (Élément neutre 0)

* Toute t-normes T et toutes t-conormes \perp vérifient:

$$(0, 0) = 0, T(1, 1) = 1, \perp(0, 0) = 0, \perp(1, 1) = 1$$

3.3 Logique floue et approximation des fonctions

L'analyse des propriétés d'approximation universelle des systèmes flous constitue l'un des axes de recherches théoriques les plus développés actuellement. Cependant, différents travaux se sont intéressés à la notion d'approximateur universel de façon à donner une justification théorique aux succès réalisés aux niveaux des applications (Kosko, 1992). Le lien entre approximation de fonctions et construction de systèmes flous amène à analyser les différentes possibilités d'approximation selon les différentes catégories de fonctions à approcher, que l'on retrouve de façon plus pratique en terme de relation entre entrées et sorties dans des systèmes physiques. Alors pour une fonction $W=f(V_1, V_2, \dots, V_n)$ et un niveau d'approximation ϵ il est possible de construire un ensemble fini de règles R_1, R_2, \dots, R_n du type:

- (R1) si V_1 est A_{11} et V_2 est A_{12} alors W est B_1
- (R2) si V_1 est A_{21} et V_2 est A_{22} alors W est B_2
- etc.

qui permet d'approcher f à ϵ près, quand f est une fonction continue définie sur un compact de dimension finie.

Théorème (Wang, 1995). Pour toute fonction continue réelle g sur un ensemble compact $U \subset \mathbb{R}^n$ et ϵ arbitraire, il existe un système flou f de la forme :

$$f(x) = \frac{\sum_{l=1}^M \bar{y}_l \left[\prod_{i=1}^n a_{l,i} \exp \left(- \left(\frac{x_i - \bar{x}_{1,i}}{\sigma_{l,i}} \right)^2 \right) \right]}{\sum_{l=1}^M \bar{y}_l \left[\prod_{i=1}^n a_{l,i} \exp \left(- \left(\frac{x_i - \bar{x}_{1,i}}{\sigma_{l,i}} \right)^2 \right) \right]} \quad (3,8)$$

Tel que :

$$\sup_{x \in U} |f(x) - g(x)| < \epsilon$$

où $\bar{y}_l, a_{l,i}$ et $\sigma_{l,i}$ sont les paramètres ajustables du système flou sous les contraintes suivantes :

$$\bar{y}_l \in V, a_{l,i} \in [0,1], \bar{x}_{l,i} \text{ et } \sigma_{l,i} > 0$$

Notons que ce théorème peut être étendue aux cas discret.

3.4 Apprentissage des systèmes flous

L'apprentissage et l'entraînement du système flou d'un procédé complexe utilisant des données numériques représente la principale phase d'ajustement de paramètres et de définition du modèle flou défini à priori par concertation avec les

experts du domaine. Parmi les algorithmes d'adaptation et d'apprentissage nous distinguons:

Apprentissage de systèmes flou par rétropropagation C'est la représentation du système flou comme un réseau de neurone et de lui appliquer l'algorithme de rétropropagation (Wang, 1995). En effet, à partir de la théorie de l'approximation universelle des systèmes flous et que l'on possède l'algorithme de la rétropropagation, par analogie avec les réseaux de neurones artificiels il est donc possible d'approximer n'importe quelle système. Cependant, L'intérêt par rapport aux réseaux de neurones artificiels est que l'identification floue des paramètres à une signification physique.

Apprentissage par base de règles floues : Dans ce cas, l'algorithme développé consiste à définir un système flou adaptatif basé sur des paires de données d'entrées/sorties et des règles floues linguistiques de type "Si-Alors". En effet, c'est une combinaison dans une base de règle de règles floues générées par des paires d'entrées/sorties et de règles linguistiques.

Moindres carrés orthogonaux pour les systèmes flous : Par cette technique, nous adoptons le système flou en le rendant équivalent à une série de fonctions à base floue (FBF). Cependant, le développement en série de FBFs permet d'utiliser l'algorithme des moindres carrés orthogonaux puisque le système est alors linéaire par rapport à ses paramètres ajustables.

Apprentissage de système flou par agrégation avec le plus proche voisin : Cette approche permet la configuration d'un système flou de façon optimal par l'apprentissage de ces paires d'entrées/sorties à n'importe quel degré d'acuité. Cependant, on considère au départ un système flou composé d'autant de règles floues qu'il y a de paires d'entrées-sorties. Ensuite il faut agréger les données échantillonnées entre elles par la méthodes des plus proches voisins. Il suffit ensuite de choisir le meilleur des systèmes flous pour ce groupe de données. On appelle cela aussi système flou adaptatif.

3.5 Intégration Neuro-floue

Le principal intérêt de l'intégration neuro-flou réside dans l'utilisation conjointe des principales composantes de la logique floue et des réseaux de neurones en tirant parti d'une synergie entre les deux méthodes afin d'exploiter les avantages de chacune tout en compensant ses inconvénients par l'utilisation d'une autre dont les propriétés sont complémentaires. Cependant, les systèmes neuro-flous estiment une fonction sans avoir besoin d'un modèle mathématique et apprennent par expérience par le biais de données entrées-sorties.

La logique floue aide à gérer des systèmes complexes de façon simple et facilement explicitable, la difficulté de sa mise en oeuvre réside dans la mise au point

des paramètres et des fonctions d'appartenance. Les réseaux de neurones, d'autre part, peuvent générer et affiner des règles floues à partir de données d'apprentissages (Kosko, juin 1992), (Kosko, 1992). Les ensembles flous sont considérés comme avantageux dans le domaine logique et dans la façon de gérer facilement les traitements d'ordre supérieur. La haute flexibilité est une caractéristique distinctive des RNs produite par l'apprentissage et convient, donc, mieux pour le traitement guidé par les données (Takagi, 1990). Dans (Hayashi et al, 1994).

La construction des modèles flous repose naturellement sur les connaissances symboliques des experts, exprimées sous forme de règles linguistiques. Cependant, l'utilisation des mesures du système réel de la forme entrées-sorties peut être avantageuse, notamment dans le cas où les connaissances symboliques ne sont pas disponibles ou sont incomplètes. Cependant, les réseaux de neurones permettent de modéliser des phénomènes statiques et dynamiques par utilisation des connaissances mathématiques dont on dispose sur le phénomène à modéliser.

L'intégration des systèmes neuronaux et flous conduit à une relation symbiotique dans laquelle des systèmes flous fournissent un cadre puissant pour la représentation de la connaissance experte, tandis que les réseaux de neurones fournissent des capacités d'apprentissage et des qualités requises exceptionnelles pour des implémentations matérielles efficaces du point de vue calcul. L'importance de cette intégration devient encore plus apparente en considérant leurs disparités. Les RNs ne fournissent pas un schéma solide pour la représentation de l'information, tandis que les régulateurs flous logiques ne possèdent pas de capacités pour l'apprentissage automatisé.

Le principal type d'association entre réseaux de neurones et systèmes flous est le cas où un système d'inférence flou est mis sous la forme d'un réseau multicouche, dans lequel les poids correspondent aux paramètres du système, l'architecture du réseau dépendant du type de règles et des méthodes d'inférence, d'agrégation et de défuzzification choisies. Incontestablement, la méthode la plus utilisée est ANFIS. Cette méthode implémente le modèle de TSK d'ordre zéro ou d'ordre un, sous la forme d'un réseau multi-couches, dont les paramètres ajustables sont ceux des fonctions d'appartenance ainsi que ceux de la conclusion. Cette méthode très performante est largement utilisée dans les réalisations pratiques.

3.6 Définition du système neuro-flou

Les systèmes neuro-flous sont des systèmes flous formés par un algorithme d'apprentissage inspiré de la théorie des réseaux de neurones. La technique d'apprentissage opère en fonction de l'information locale et produite uniquement des changements locaux dans le système flou d'origine (Daniel, 2006).

Dans le système neuro-flou, les règles floues codées représentent des prototypes imprécis des données d'apprentissage. Cependant, il ne devrait pas être considéré

comme un système expert. Notons, que les systèmes neuro-flous peuvent être utilisés comme des approximateurs universels (Lee et al, 2001).

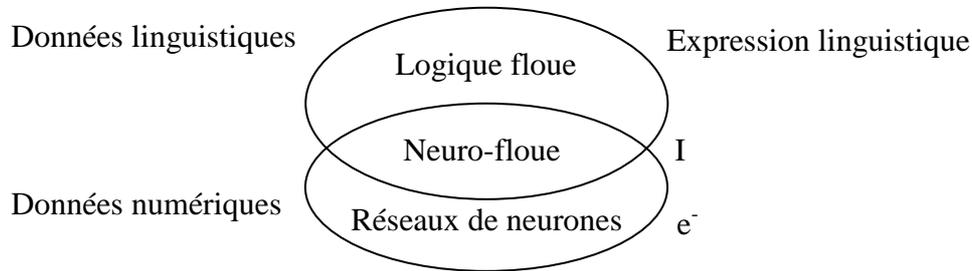


Figure 3.2 Le système neuro-flou

3.7 Avantages et inconvénients de la logique floue et des réseaux de neurones

L'intégration et l'association de la logique floue et des réseaux de neurones artificiels permettent l'exploitation des avantages des deux méthodes : la prise de décision, la souplesse et la lisibilité de la première et les capacités d'apprentissage à partir de données mesurées de la seconde.

Le tableau 3.1 montre les avantages et les inconvénients de la logique floue et des réseaux de neurones, il résume la contribution des systèmes neuro-flous. En effet, le besoin d'intégration des deux systèmes et de synthétiser les avantages et de surmonter les inconvénients des deux systèmes utilisés séparément. Cependant, les algorithmes d'apprentissages peuvent être employés pour déterminer les paramètres des systèmes flous, ce qui présente une amélioration automatique de ces derniers au moyen des méthodes spécifiques aux réseaux de neurones, mais le système reste toujours interprétable en termes de règles floues, qui est un aspect très important des systèmes neuro-flous.

Tableau 3.1 Comparaison entre la logique floue et les réseaux de neurones

<i>Réseaux de neurones</i>	<i>Logique floue</i>
<i>Avantages</i>	
<ul style="list-style-type: none"> - Le modèle mathématique non requis - Aucune connaissance basée sur les règles - Plusieurs algorithmes d'apprentissage sont disponibles 	<ul style="list-style-type: none"> - Le modèle mathématique non requis - La connaissance antérieure sur les règles peut être utilisée - Une interprétation et implémentation simple
<i>Inconvénients</i>	
<ul style="list-style-type: none"> - Boîte noire - L'adaptation aux environnements différents est difficile et le réapprentissage est souvent obligatoire - Difficulté d'utiliser une connaissance antérieure à base de règles - Aucune garantie sur la convergence de l'apprentissage 	<ul style="list-style-type: none"> - Les règles doivent être disponibles - Ne peut pas apprendre - Adaptation difficile au changement de l'environnement - Aucune méthodes formelles pour l'ajustement

3.8 Méthodes et combinaisons Neuro-Floues

Plusieurs combinaisons ont été développées depuis les années quatre vingt et sont orientées généralement vers la commande des systèmes complexes et les problèmes de classification (Daniel, 2006). En conséquence, il existe trois méthodes hybrides neuro-floues:

1-Première méthode neuro-floue :

La première méthode neuro-floue consiste au codage du système d'inférence floue sous la forme d'un réseau de neurones multicouches dans lequel les poids correspondent aux paramètres du système. L'architecture du réseau dépend du type de règle et des méthodes d'inférences, d'agrégation et de défuzzification choisies.

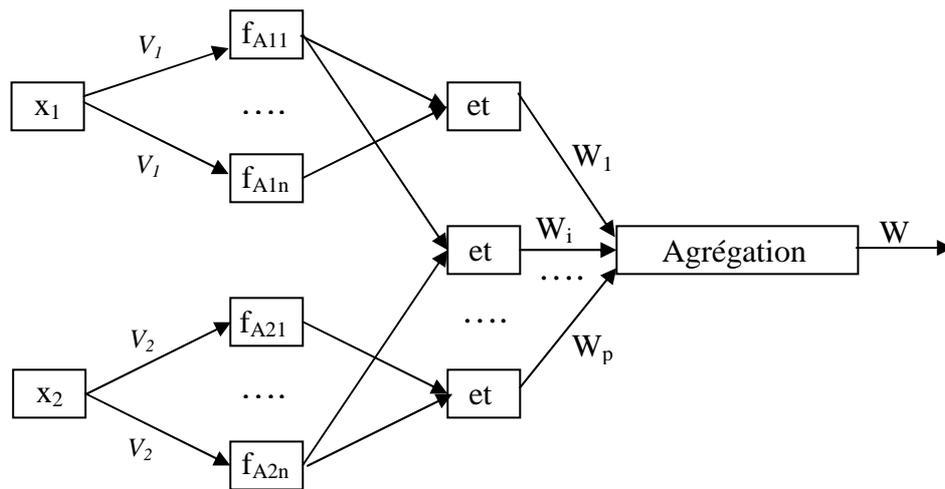


Figure 3.3 Exemple de réseau de neurones pour la commande floue

D'après la figure précédente, pour des règles de la forme :

$$\text{"SI } V_1 \text{ est } A_{1i} \text{ et } V_2 \text{ est } A_{2i} \text{ ALORS } W = W_i\text{"}$$

nous obtenons un réseau de neurones qui admet pour entrée les valeurs x_1 et x_2 prises par les variables V_1 et V_2 et dont les deux couches cachées correspondent respectivement au calcul de la valeur des fonctions d'appartenance A_{ij} pour l'entrée x_i et à celui de la valeur prise par la conjonction des conditions de chaque règle utilisant un opérateur adéquat. Les fonctions d'appartenance sont considérées comme des paramètres ajustés par les poids entrant dans la première couche cachée. Les conclusions W_i des règles sont également des paramètres ajustables par l'intermédiaire des poids associés à la dernière couche.

2-Deuxième méthode neuro-floue :

Dans cette méthode, les composantes du système de commande floue sont remplacées par des réseaux de neurones destinés essentiellement à l'apprentissage des fonctions d'appartenances, au calcul de l'inférence et à la réalisation de la phase d'agrégation et de déflouification (défuzzification). Ils peuvent réaliser l'extraction des règles floues en analysant la corrélation qui existe entre les entrées et les sorties du réseau de neurones. En effet, l'avantage de cette méthode réside dans la résolution des problèmes de détermination des fonctions d'appartenances et l'adaptation à l'environnement du système.

3-Troisième méthode neuro-floue :

Cette méthode utilise des réseaux de neurones et des systèmes flous associés en série ou en parallèle. Plusieurs variantes sont ainsi possibles :

- Le réseau de neurones fonctionne en amont du système flou. Les variantes d'entrées du système flou sont déterminées à partir des sorties du réseau de neurones (dans le cas où elles ne sont pas mesurables directement) ou encore un réseau de neurones effectue une tâche de classification ou de reconnaissance de formes, suivie d'un système flou d'aide à la décision.
- Un réseau de neurones qui fonctionne en aval du système flou, dans le but d'ajuster les sorties d'un système de commande floue à de nouvelles connaissances obtenues, les variables de sorties étant les erreurs sur les variables de sortie du système flou.

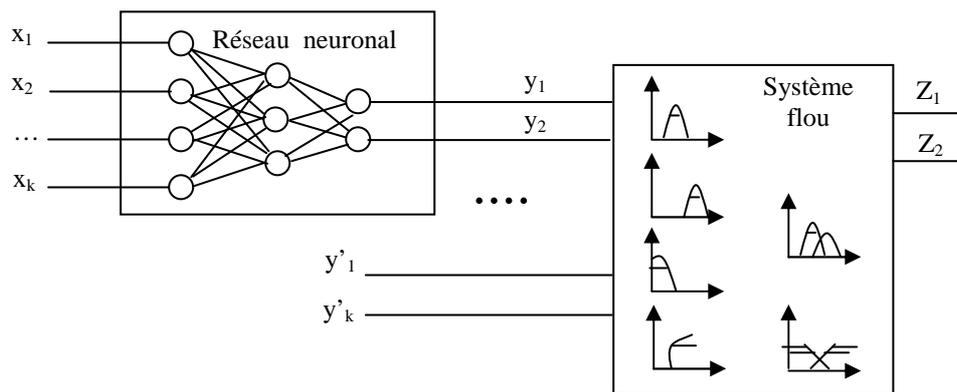


Figure 3.4 Exemple d'association en série d'un réseau de neurone et d'un système flou

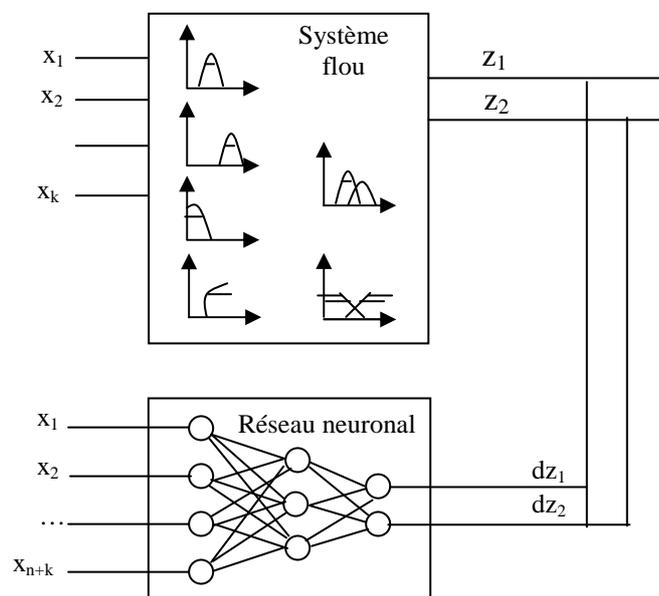


Figure 3.5 Exemple d'association en parallèle d'un réseau de neurone et d'un système flou

Il existe quatre grandes catégories de combinaisons des réseaux de neurones avec la logique floue (Daniel, 2006):

- **Réseau flou neuronal** : Dans ces réseaux, les techniques floues sont employées pour augmenter les possibilités du processus d'apprentissage et d'exécution des réseaux de neurones.

- **Système neuronal/flou simultanément** : Le réseau de neurone et le système flou fonctionnent ensemble sur la même tâche, mais sans s'influencer, c.-à-d. ni l'un ni l'autre n'est employé pour déterminer les paramètres de l'autre. Habituellement le réseau neuronal traite les entrées, ou post-traite les sorties du système flou.

- **Modèles neuro-flous coopératifs** : Le réseau de neurone est employé pour déterminer les paramètres (les règles et les ensembles flous) d'un système flou. Après la phase d'apprentissage, le système flou fonctionne sans le réseau de neurone. C'est une forme simple des systèmes neuro-flous.

- **Modèles neuro-flous hybrides** : Les approches neuro-floues modernes sont de cette forme. Un réseau neuronal et un système flou sont combinés dans une architecture homogène. Le système peut être interprété comme un réseau neuronal spécial avec des paramètres flous ou comme un système flou mis en application sous une forme distribuée parallèle.

3.9 Systèmes Neuro-Flous hybrides intégrés

3.9.1 Systèmes Neuro-Flous intégrés type Mamdani

Le système neuro-flou de type Mamdani utilise la technique d'apprentissage par rétropropagation pour apprendre les paramètres des fonctions d'appartenance. L'architecture du système neuro-flou Mamdani est illustrée par la figure 3.6:

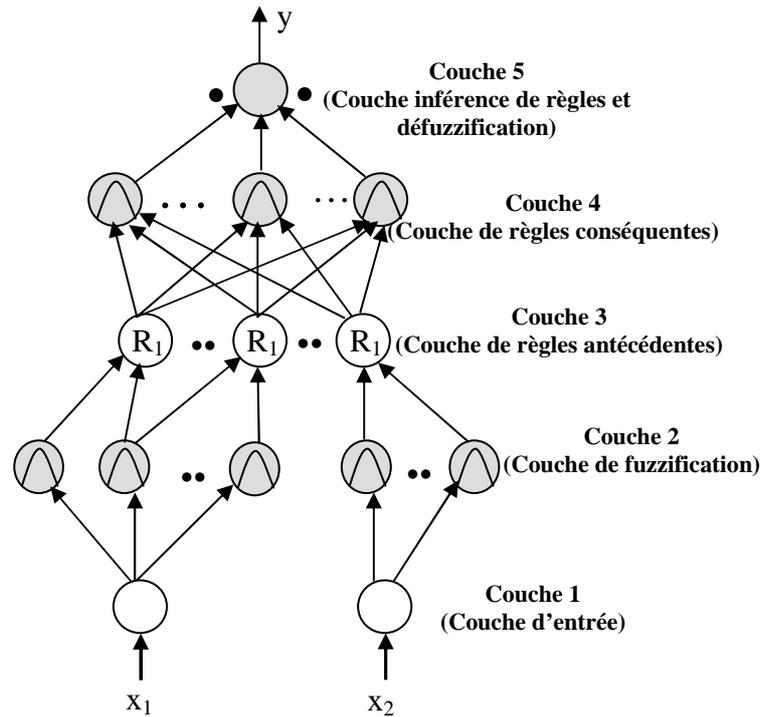


Figure 3.6 Système neuro-flou type Mamdani

Couche 1 : C'est la couche d'entrée, chaque nœud dans cette couche correspond à une seule variable d'entrée, son rôle est de transmettre les valeurs d'entrée directement à la couche suivante.

Couche 2 : c'est une couche de fuzzification, chaque nœud, dans cette couche correspond au seul label linguistique pour une des variables d'entrée dans la couche 1 c.-à-d., le lien de sortie représente la valeur d'appartenance, qui spécifie le degré avec lequel une valeur d'entrée appartient à un ensemble flou, est calculé dans la couche 2. Un algorithme de classification décide du nombre initial et des types de fonctions d'appartenance à attribuer pour chacune des variables d'entrée. Les formes finales des fonctions d'appartenances seront réglées avec précision durant l'apprentissage du réseau.

Couche 3 : c'est la couche de règles antécédentes, un nœud dans cette couche représente la partie antécédente d'une règle. D'habitude, un opérateur T-norme est utilisé dans ce nœud. La sortie d'un nœud de la couche 3 représente le sens (firing strength, en anglais) de la règle floue correspondante.

Couche 4 : Couche de règles conséquentes, ce nœud a, en fait, deux tâches : Combiner les antécédents de règles et déterminer le degré avec lequel ils appartiennent au label linguistique de sortie. Le nombre de nœuds dans cette couche est égal au nombre de règles.

Couche 5 : Couche de défuzzification, ce nœud effectue la combinaison de toutes les parties conséquentes des règles utilisant un opérateur S-norme et calcule enfin la sortie nette (non floue) après défuzzification.

3.9.2 Systèmes neuro-flous intégrés type Takagi-Sugeno

Les systèmes neuro-flous type Takagi-Sugeno utilisent une combinaison de l'algorithme de rétropropagation pour apprendre les fonctions d'appartenance et la méthode d'estimation par moindres carrés pour déterminer les coefficients des combinaisons linéaires dans les conclusions de règles. Une étape dans la procédure d'apprentissage possède deux parties : dans la première partie les entrées sont propagées et les paramètres d'une conclusion optimale sont estimés par une procédure des moindres carrés, pendant que les parties antécédentes (fonctions d'appartenance) sont supposées fixes pour le cycle courant à travers l'ensemble d'apprentissage. Dans la seconde partie, les entrées sont propagées encore une fois et, pendant cette itération, la rétropropagation est utilisée pour modifier les paramètres antécédents pendant que les paramètres conclusion restent fixés. Cette procédure est alors réitérée.

Le rôle de chaque couche du système neuro-flou type Takagi-Sugeno représenté par la figure 3.7 est comme suit :

Couches 1, 2 & 3 : Leur rôle est similaire aux couches 1,2 et 3 du système type Mamdani.

Couche 4 (normalisation sens de la règle) : Chaque nœud de cette couche calcule le rapport du sens de la ième règle par rapport à la somme des sens de toutes les règles :

$$\bar{w}_i = \frac{w_i}{w_1 + w_2}, \quad i = 1, 2, \dots \quad (3.32)$$

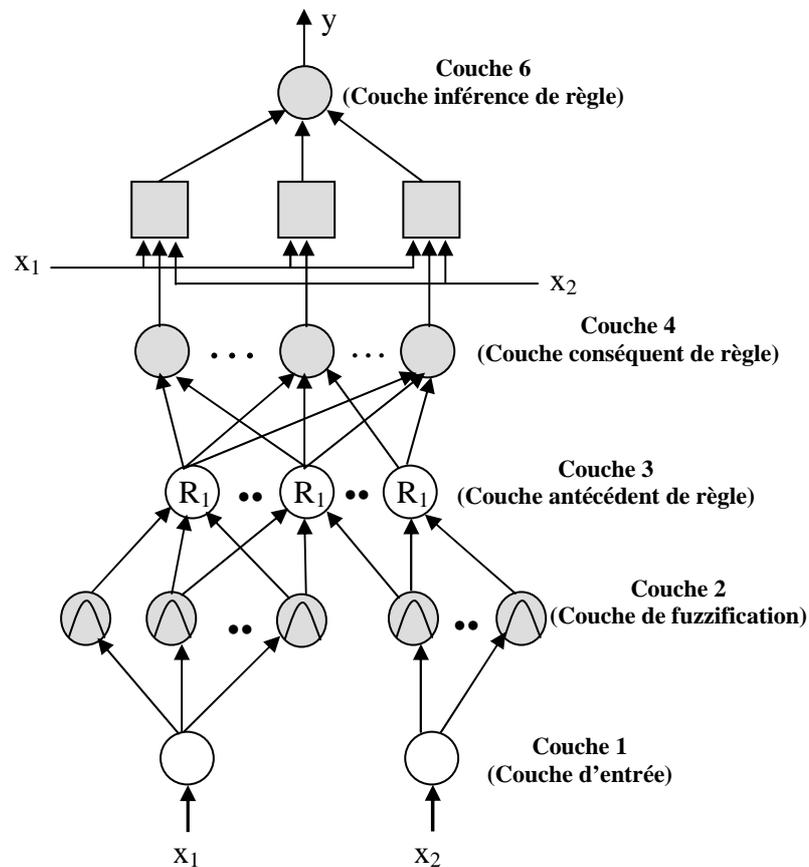


Figure 3.7 Système neuro-flou type Takagi-Sugeno

Couche 5 (couche conséquent de règle) : Chaque nœud i dans cette couche est doté d'une fonction nœud :

$$\bar{w}_i f_i = \bar{w}_i (p_i x_1 + q_i x_2 + r_i) \quad (3.33)$$

où \bar{w}_i est la sortie de la couche 4, et $\{p_i, q_i, r_i\}$ est l'ensemble des paramètres. Les paramètres conséquents sont déterminés par l'algorithme des moindres carrés moyens.

Couche 6 (couche inférence de règle) : L'unique nœud de cette couche calcule la sortie globale par addition de tous les signaux entrant :

$$\text{Sortie globale} = \sum \bar{w}_i f_i = \frac{\sum_i^n w_i f_i}{\sum_i^n w_i} \quad (3.34)$$

Dans ce qui suit, nous décrivons en bref le système intégré Anfis qui utilise les complémentarités des réseaux de neurones et des systèmes à inférences floue implémentant un SIF type Takagi-Sugeno.

3.9.3 Système ANFIS (*Adaptive-Network-based Fuzzy Inference System*)

ANFIS (acronyme pour Adaptive Network Based fuzzy Inference System) représente un système à inférence floue mis en application dans le cadre des réseaux adaptatifs. Il utilise la procédure d'apprentissage Hybride (Jang, 1993).

Cette architecture affine les règles floues obtenues par des experts humains pour décrire le comportement d'entrée-sortie d'un système complexe. Une version modifiée du modèle ANFIS (figure 3.8) est capable d'implémenter le système d'inférence floue de Tsukamoto (Tsukamoto, 1979), (Jang, 1993). La version d'origine utilise un modèle flou de type Sugeno et codifie les règles floues de la forme :

$$R_r : \text{Si } x_1 \text{ est } \mu_{j_1}^{(1)} \wedge \dots \wedge x_n \text{ est } \mu_{j_n}^{(n)} \text{ alors}$$

$$y = \alpha_0^{(r)} + \alpha_1^{(r)} x_1 + \dots + \alpha_n^{(r)} x_n$$

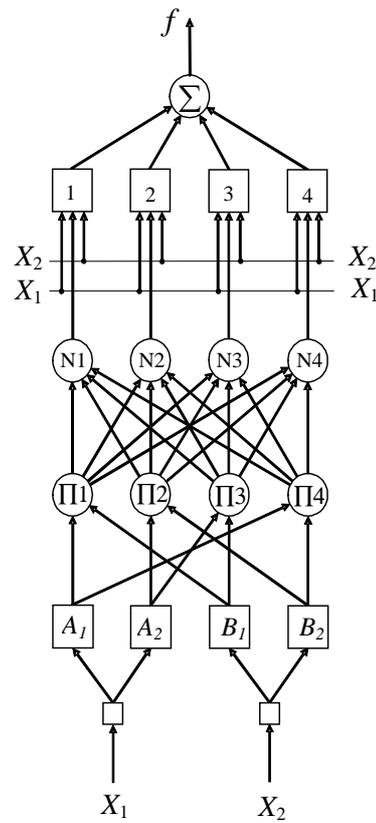


Figure 3.8 système neuro-flou du type ANFIS

La sortie globale dans le SIF de Tsukamoto, est donnée par la moyenne pondérée de chaque sortie nette de règle induite par le sens de la règle (le produit ou minimum des degrés d'adéquation avec la partie prémisse) et les fonctions d'appartenance de sortie.

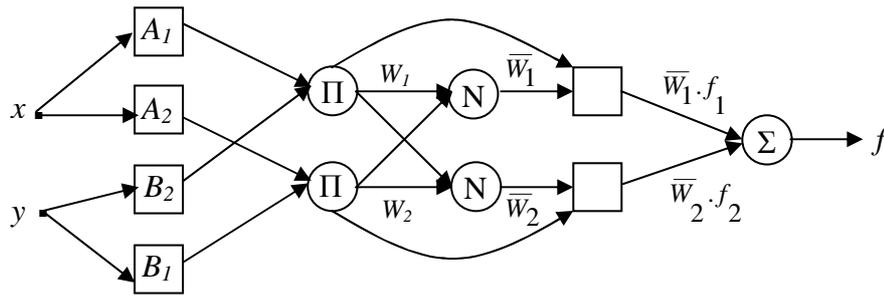


Figure 3.9 Architecture ANFIS réalisant le système d'inférence floue de Tsukamoto

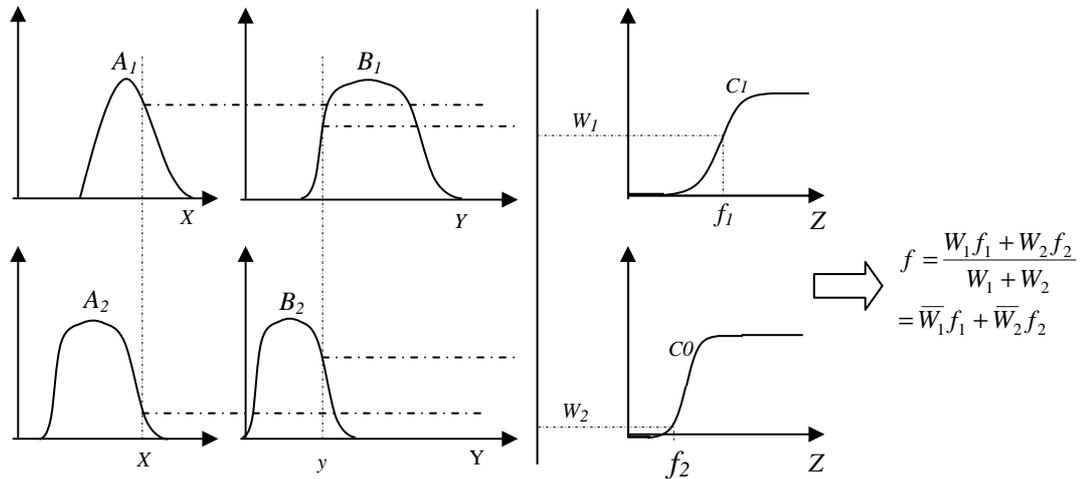


Figure 3.10 Raisonnement flou de Tsukamoto

La première couche cachée est pour la fuzzification des variables d'entrée. Des opérateurs T-normes utilisés dans la deuxième couche cachée pour calculer la partie antécédente de règle. La troisième couche normalise les sens des règles, elle est suivie de la quatrième couche où les paramètres conséquents de la règle sont déterminés. La couche de sortie calcule la sortie totale par addition de tous les signaux entrant.

Le procédé d'apprentissage du modèle ANFIS, ne se préoccupe que de l'adaptation de paramètres dans des structures fixes. En effet, chaque terme linguistique est représenté par un seul ensemble flou. La procédure d'apprentissage utilise un mélange de rétropropagation et une estimation par moindres carrés moyen. La rétropropagation est utilisée pour la mise à jour des paramètres antécédents (paramètres des règles floues) et les MCM pour mettre à jour les paramètres conséquents (coefficients des combinaisons linéaires). Si on utilise des fonctions

d'appartenance gaussiennes, le modèle ANFIS peut être comparé à un réseau à fonction de base radiale (RBF).

Notons, que le système ANFIS est implémenté dans la boîte à outils « Neuro-Fuzzy » de MATLAB. Ce modèle donne de très bons résultats en poursuite de trajectoire, approximation non linéaire, commande dynamique et traitement du signal.

3.10 Commentaires

Les modèles neuro-flous présentés sont des modèles capables d'apprendre en mode supervisé. Le processus d'apprentissage concerne seulement l'adaptation au niveau des paramètres dans des structures fixes. Pour des problèmes à large échelle, il serait trop compliqué de déterminer les structures optimales prémisse-conséquence, le nombre de règles, etc. L'utilisateur doit fournir les détails de l'architecture (type et nombre de fonctions d'appartenance pour les variables d'entrée et de sortie), le type des opérateurs flous, etc.

Parmi tous les systèmes neuro-flous, le modèle ANFIS présente la plus faible erreur moyenne quadratique (RMSE). Ceci est probablement dû à l'implémentation de règles type Takagi-Sugeno dans le modèle ANFIS comparé au système flou type Mamdani. Toutefois, il existe d'autres systèmes tel que NEFPROX plus performant que le modèle ANFIS en terme de temps de calcul. En raison du nombre plus réduit de règles, il existe aussi des structures tels que SONFIN, EFuNN et dmEFuNN aussi capables de fonctionner plus rapidement que le modèle ANFIS. Il existe, donc, un compromis entre la possibilité d'interprétation et la précision. Les SIF type Takagi-Sugeno sont plus précis mais demandent plus d'effort de calcul, alors que les SIF type Mamdani sont plus "interprétables" et exigent moins de calcul mais souvent avec un compromis sur la précision.

3.11 Conclusion

Les systèmes hybrides Neuro-floues sont utilisés principalement lorsque le modèle mathématique du système physique est difficile à élaborer, ils exploitent des règles floues tirées d'une expertise humaine pour modéliser le comportement dynamique du système. Nous avons présentés une description générale de la théorie floue et neuro-floue et nous nous sommes intéressés principalement aux systèmes qui intègrent des règles floues dans des réseaux, aux systèmes qui font l'extraction de règles floues à partir des réseaux et les systèmes qui implémentent des neurones flous. Enfin, nous avons discutés des réseaux multicouches et des systèmes flous adaptatifs qui présentent tous un puissant moyen d'approximation des fonctions.

*Modélisation de l'hystérésis par les
réseaux de neurones*

4.1 Introduction

Les matériaux magnétiques sont complexes et les phénomènes régissant leurs comportements ne sont pas entièrement maîtrisés; ils dépendent en même temps de la non-linéarité, de l'anisotropie et de l'histoire de leurs états. Cependant, leur modélisation s'avère très importante et nécessaire, pour effectuer une étude d'un système comprenant ses matériaux magnétiques (conception de machines électriques, d'enregistrement magnétique... etc.). Un des phénomènes de comportement des matériaux magnétiques est l'hystérésis magnétique définie par le retard entre l'application du champ $H(t)$ et l'apparition de l'aimantation $M(t)$.

De nos jours, les Réseaux neurologiques artificiels et les méthodes de l'intelligence artificielle développées sont très populaires dans plusieurs domaines de technologie et de recherche scientifique, toutefois la modélisation des caractéristiques d'hystérésis et des solutions des problèmes de champ électromagnétique avec ces outils mathématiques n'ont pas été utilisés encore. Ces nouvelles méthodes de calculs peuvent être utilisées dans des cas de problèmes difficiles qui ne peuvent pas être décrits par des approches mathématiques traditionnelles ou ils sont très compliqués pour les employer (Adly et al, 1998), (Horvath, 1995). Les réseaux neurologiques (NNs) peuvent être appliqués en tant que *des approximateurs universels de fonctions*, ainsi développer un modèle d'hystérésis basé sur les capacités d'approximation de fonctions d'ANNs est une bonne approche et représente une idée nouvelle.

Plusieurs approches de modélisation ont été présentées dans la littérature (Ouled Amor, 2000), (Brokate et al, 1996), (Mayergoyz, 1991), (Preisach, 1935), (Jiles et al, 1986), (Hodgdon, 1988), (Ivanyi, 1997) et (Stoner et al, 1948). Les techniques des réseaux de neurones et de l'intelligence artificiel en générale a suscité une attention particulière ces dernières années grâce à leurs capacités de modélisation des systèmes complexes dynamiques non linéaire (Dimirli et al, 2000). Dans ce contexte, plusieurs modèles ont été développés pour décrire la non-linéarité de l'hystérésis (Landman et al, 2001), (Mueller, 1985). Salvini et Al (Salvini et al, 2002), (Salvini et al, 2003) ont employé les réseaux neurones entraînés par des algorithmes génétiques afin d'obtenir un modèle dynamique à partir du modèle statique de Jiles-Atherton (JA).

Les réseaux neurales sont employés pour l'identification des paramètres du modèle de JA plutôt que de modéliser l'hystérésis lui-même. Siamak et al (Siamak et al, 2006) ont proposé deux approches alternatives pour développer un modèle d'hystérésis flou, le premier consiste à l'établissement d'une image miroir de la courbe descendante afin de modéliser les deux courbes descendante et ascendante, la seconde consiste à la modélisation des courbes descendante et ascendante séparément. Francesco Riganti et d'Alessandro salvini ont proposé une méthode d'identification de paramètres du modèle d'hystérésis de Jiles-Atherton basés sur une association des techniques heuristiques (algorithme génétique) et de logique floue (Francisco Riganti et al, 2005). Saghafifar et Al ont employé un réseau de neurone de type Elman pour la description du comportement dynamique des matériaux magnétiques (Saghafifar et al, 2001), (Saghafifar et al, 2002a et 2002b). Azzerboni et Al ont employé la logique floue pour simuler des cycles d'hystérésis des matériaux magnétiques en divisant le

plan *M-H* en cercles et carrés par utilisation d'une structure linguistique pour décrire le phénomène (Azzerboni et al, 2003). Maurizio Cirrincione a décrit une méthodologie pour l'identification de la densité de distribution de Preisach par les réseaux neurones; ils ont employé un perceptron multicouche entraîné par un algorithme de levemberg-Marquard (Maurizio Cirrincione et al, 2002). Wei et Sun dans (Wei et al, 1998) utilisent les réseaux de neurones pour l'approximation de la fonction de distribution de Preisach, alors que Kuczman décrit une méthode d'approximation de l'hystérésis magnétique par utilisation des perceptrons multicouches (Kuczmann et al, Mars 2002), (Kuczmann et al, 2002).

Les réseaux de neurones peuvent apprendre et identifier des procédés à partir des données expérimentales, ce qui les rend un procédé d'approximation universel. Dans ce chapitre, après une description théorique des réseaux connexionnistes, on s'intéressera à la modélisation de l'hystérésis statique à partir de données mesurées où générées par d'autres modèles phénoménologiques connus par l'utilisation des fonctions à base radiale et des réseaux de perceptrons multicouches.

4.2 Historique

De nombreux ouvrages ont permis de documenter l'histoire des recherches en réseaux de neurones. Traditionnellement, on fait remonter le début des travaux sur les réseaux de neurones aux travaux de McCulloch et Pitts (1943) qui montrent qu'un réseau de neurones discret, sans contrainte de topologie, peut représenter n'importe quelle fonction booléenne. Un peu plus tard (1949), Donald Hebb essayait d'expliquer les effets d'apprentissage et de mémoire à partir de groupes de cellules, il propose que les cellules apprennent à modifier l'intensité des connexions qui les relient en fonction de leur activité simultanée (Hebb, 1949). En 1958, Rosenblatt propose le premier algorithme d'apprentissage, qui permet d'ajuster les paramètres d'un neurone. En 1969, Minsky et Papert publient le livre *Perceptrons* dans lequel ils utilisent une solide argumentation mathématique pour démontrer les limitations des réseaux de neurones à une seule couche. En effet, les chercheurs se désintéressèrent des réseaux de neurones pour se tourner vers l'approche symbolique de l'intelligence artificielle (IA) qui semblait beaucoup prometteuse. En 1982, Hopfield propose des réseaux de neurones associatifs et l'intérêt pour les réseaux de neurones renaît chez les scientifiques. En 1986, Rumelhart, Hinton et Williams publient, l'algorithme de la rétropropagation de l'erreur qui permet d'optimiser les paramètres d'un réseau de neurones multicouches complexes. Depuis, de nombreuses applications ont été réalisées sur le principe des réseaux de neurones, les réseaux importants devant faire appel à des processeurs spécialisés.

4.3 Les réseaux de neurones artificiels

Du point de vue de l'ingénieur à la recherche d'une connaissance connexionniste, les réseaux de neurones artificiels sont des ensembles de neurones formels associés en couches et fonctionnant en parallèle. Chaque (neurone) processeur élémentaire calcule une sortie unique sur la base des informations qu'il reçoit. Dans un

réseau, chaque sous-groupe fait un traitement indépendant des autres et transmet le résultat de son analyse au sous-groupe suivant. L'information donnée au réseau va donc se propager couche par couche, de la couche d'entrée à la couche de sortie, en passant soit par aucune, une ou plusieurs couches intermédiaires (dites couches cachées). Les réseaux de neurones ont la capacité de stocker de la connaissance dans les poids synaptiques, obtenus par des processus d'adaptation ou d'apprentissage et de la rendre disponible à l'usage.

Les réseaux de neurones sont habituellement destinés aux applications où on dispose d'un ensemble de mesures de variables d'un processus de nature quelconque (physique, chimique, économique,...etc), et du résultat de ce processus, et on suppose qu'il existe une relation entre ces variables et ce résultat, valable dans le domaine où les mesures ont été effectuées, tout en sachant que ces dernières sont en nombre fini. En d'autre terme on cherche un modèle du processus étudié à partir des mesures dont on dispose. Cependant, on dit qu'on a effectué une modélisation « boîte noire » (Figure 4.1) pour laquelle le réseau se divise en trois parties :

1. Couche d'entrée
2. Couche de sortie, dont l'activation de ces neurones est interprétée comme étant la réponse du réseau.
3. Une ou plusieurs couches cachées, n'ayant aucun lien avec l'utilisateur.

La modélisation d'un réseau de neurone consiste donc à la description du modèle de neurone, le modèle de connexions entre ces neurones et l'équation d'adaptation ou d'apprentissage permettant le contrôle et l'ajustement des poids des connexions pour avoir une réponse optimale du réseau. Notons que les équations décrivant le comportement des neurones artificiels n'introduisent pas la notion de temps. En effet, et c'est le cas pour la plupart des modèles actuels de réseaux de neurones, nous avons affaire à des modèles à temps discret, synchrone, dont le comportement des composants ne varie pas dans le temps.

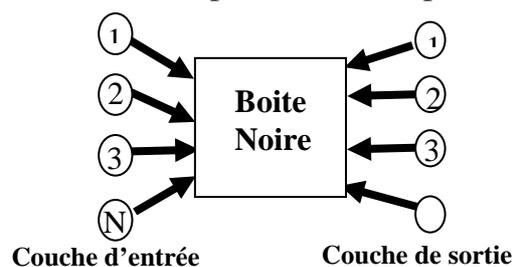


Figure 4.1 : Réseau de neurones artificiel.

4.3.1 Modèle de neurone

Le modèle de neurone est un modèle mathématique très simple dérivé d'une analyse de la réalité biologique. Généralement, le neurone est modélisé par un opérateur de sommation et un opérateur qui calcul l'état de la sortie S (Figure 4.2). En résumé, un neurone formel réalise simplement une somme pondérée de ces entrées, ajoute un seuil à cette somme et fait passer le résultat par une fonction de transfert pour obtenir sa sortie.

$$P = \sum_i w_i * x_i \quad (4.1)$$

$$S = N(P) \quad (4.2)$$

où N est la fonction d'activation du neurone ou fonction neurone, linéaire ou non.

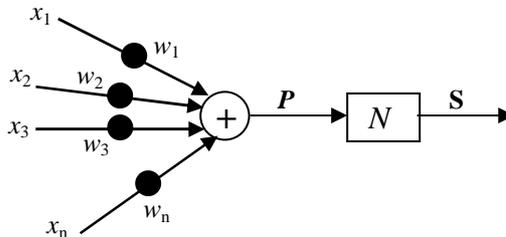


Figure 4.2 : Modélisation du neurone

Il est important de noter que le neurone manipule des données numériques et non pas symboliques. Cependant, les entrées x_i sont des sorties de neurones du même réseau ou d'un autre réseau ou encore des entrées extérieures.

4.3.2 Modèles des connexions

Les connexions entre les neurones qui composent le réseau décrivent la topologie du modèle. Selon le sens du transfert de l'information dans un réseau on peut définir deux grandes catégories de connexions :

4.3.2.1 Les connexions directes

Dans ce type de connexion, le sens de parcours de l'information ou d'activation traverse les neurones en une vague unique. Les réseaux dotés de ce type de connexions sont appelés réseaux à couches ou réseaux statiques, ils n'ont pas de véritable comportement dans le temps, et ils possèdent une ou plusieurs couches cachées. L'état de sortie de chaque neurone dépend seulement des sorties des neurones de la couche précédente.

4.3.2.2 Les connexions récurrentes

Les connexions récurrentes ramènent l'information en arrière par rapport au sens de propagation défini dans un réseau multicouche. Ces connexions sont le plus souvent locales (fig.4.3). Les réseaux de neurones dotés de cette structure de connexions sont caractérisés par des comportements dynamiques pouvant être plus ou moins complexes selon les contraintes d'architecture qu'ils comportent. Parmi les réseaux dotés de ce type de connexions on a les réseaux à compétition tels que les réseaux LVQ de Kohonen (Learning Vector Quantization), les cartes topologiques SOM de Kohonen (Self Organization Maps) et les réseaux ART de Grossberg

(Adaptative Resonance Theory) ainsi que les réseaux à connexions symétriques tels que les réseaux de Hopfield et la machine de Boltzman.

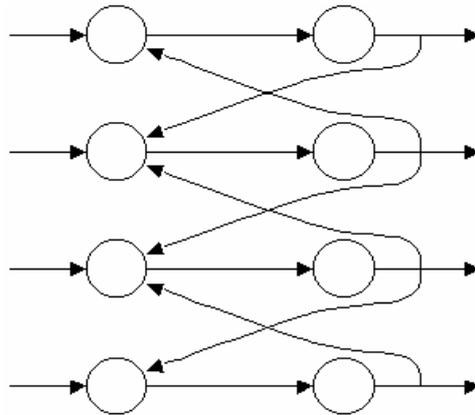


Figure 4.3 : Structure d'un réseau de neurones dont les connexions sont récurrentes.

Notons que les connexions entre les neurones peuvent être partielles (**Figure 4.5**) ou totales (**Figure 4.4**). Cependant, dans la première structure, chaque neurone entretient des relations avec un nombre réduit et localisé de neurones de la couche aval, par contre, dans la deuxième structure, chaque neurone est connecté à tous les neurones du réseau.

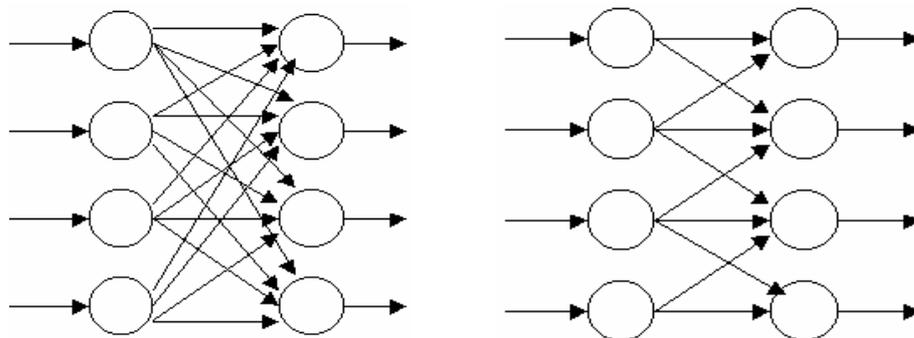


Figure 4.4 : Réseau à connexions totales. Figure 4.5 : Réseau à connexions partielles

Il existe de nombreuses autres structures de connexion possibles, mais elles n'ont pas eu à ce jour la notoriété des quelques unes que nous avons décrites au dessus.

4.3.3 Règles d'apprentissage

L'apprentissage est vraisemblablement la propriété la plus intéressante des réseaux de neurones. C'est la phase du développement d'un réseau de neurones durant laquelle le comportement du réseau est modifié jusqu'à l'obtention du comportement désiré. L'apprentissage neuronal fait appel à des exemples de comportement. Dans la majorité des algorithmes actuels, les variables modifiées pendant l'apprentissage sont les poids des connexions.

4.3.3.1 Type d'apprentissage

Au niveau des algorithmes d'apprentissage, il a été défini trois grandes classes selon que l'apprentissage est dit supervisé, non supervisé ou semi supervisé (Ouchtati, 2007).

a) Apprentissage non supervisé

Dans ce cas d'apprentissage, le but est d'atteindre l'ensemble des poids synaptiques pour lesquels le comportement du réseau est optimal. La modification et l'ajustement des poids se font en fonction d'un critère interne indépendant de la relation entre le comportement du réseau et la tâche qu'il doit effectuer. La règle d'apprentissage est en fonction du comportement local des neurones : on renforce les connexions entre le neurone ayant le mieux reconnu un exemple et les cellules d'entrée activées par cet exemple, ainsi, deux entrées proches produiront en sortie deux valeurs proches. La première règle d'apprentissage connexionniste proposée par Hebb (Hebb, 1949) était non supervisée, elle était basée sur la proportionnalité entre la modification de l'efficacité synaptique des connexions entre deux neurones et l'activité simultanée de ces deux neurones.

b) Apprentissage supervisé

Dans ce type d'apprentissage, le réseau s'adapte par comparaison entre le résultat qu'il a calculé, en fonction des entrées fournies, et la réponse attendue en sortie. Ainsi, le réseau va se modifier jusqu'à ce qu'il trouve la bonne sortie, c'est-à-dire celle attendue, correspondant à une entrée donnée. Cependant, dans l'apprentissage supervisé par renforcement, le réseau doit apprendre la corrélation entrée/sortie via une estimation de son erreur. Il tend à maximiser un index de performance qui lui est fourni. Généralement, les règles d'apprentissage supervisé sont des formes de descente du gradient.

c) Apprentissage semi supervisé

Le mode semi supervisé suppose qu'un comportement de référence précis n'est pas disponible, mais qu'en revanche, il est possible d'obtenir des indications qualitatives (correct/incorrect) sur les performances du réseau.

4.3.3.2. Quelques règles d'apprentissage

Plusieurs règles d'apprentissage peuvent être envisagées mais les premières règles sont celles utilisées dans le perceptron de Rosenblatt (Rosenblatt, 1960) et Adaline (Adaptive Linear Neuron) de Widrow Hoff (Widrow et al, 1960), elles reposent toutes deux sur la minimisation d'un critère d'erreur quadratique instantanée. Les architectures des réseaux proposées dans les deux cas sont très voisines. Dans le réseau Adaline, le neurone est linéaire : $N(P)=P$, alors que la caractéristique dans le Perceptron est une fonction Echelon : $N(P)=Ech(P-\theta)$, où θ est un seuil. L'apprentissage se fait avec superviseur, c'est à dire que l'on présente un vecteur à l'entrée du réseau et en même temps on fournit la sortie désirée. Pour un seul neurone, à chaque pas d'apprentissage, l'erreur quadratique à minimiser est donc

$$E = (y - y_{\text{désirée}})^2 \quad (4.3)$$

Les deux règles présentent l'inconvénient des algorithmes de type stochastique en ce qui concerne la convergence. Par ailleurs, il est évident que minimiser l'erreur quadratique instantanée n'est pas identique à minimiser l'erreur quadratique moyenne calculée sur toute la base d'apprentissage, et que ce dernier critère est plus performant. Dans ce cas, il faut utiliser des méthodes de moindres carrés bien connues en automatique et en traitement du signal, ces méthodes sont plus rapides et plus sûres en convergence, mais plus lourdes du point de vue calcul. Les réseaux simples ne peuvent résoudre que des problèmes simples de classification. Pour des problèmes plus complexes, il faut organiser la décision en plusieurs étapes (réseau à plusieurs couches). Aujourd'hui, l'algorithme de rétro propagation du gradient est l'aboutissement de l'évolution du modèle à couches des réseaux de neurones. Cet algorithme constitue une solution mathématique aux problèmes rencontrés par le modèle du perceptron, c'est le modèle le plus utilisé, qui permet d'obtenir les résultats les plus satisfaisants dans beaucoup de domaine d'application (modélisation des processus non linéaires, la commande des processus, la reconnaissance de forme...etc).

Notons qu'il existe d'autres règles d'apprentissage, issues de domaines scientifiques très divers, tels que l'analyse numérique (moindres carrés, gradients, méthode de Newton), la physique statistique ou la chimie (recuit simulé, machine de Boltzman), l'algorithmique (arbres de décision, diagramme de Voronoï) ou encore la biologie (colonnes corticales, algorithmes génétiques).

4.4 Approximation de fonction par réseaux de neurones

Si l'on ne sait pas modéliser précisément un phénomène physique mais que l'on aimerait disposer d'une simulation, on peut recourir à l'approximation de fonction. Cependant, les réseaux de neurones à trois couches doté de l'algorithme de la rétropropagation de gradient sont capables d'approximer n'importe quelle fonction f avec une mesure d'erreur au carré inférieure à toute performance $\epsilon > 0$. En effet, la fonction f inclut toutes les relations qui peuvent apparaître dans une application pratique (continues et discontinues). Notons que le théorème de l'approximation universel des réseaux multicouches à rétropropagation ne donne aucune indication sur le nombre de neurones dans la couche cachée et d'autre part, il présente le réseau à une couche cachée comme un minimum (Claude, 1992).

Ce qui fait la différence des réseaux de neurones avec les autres méthodes d'approximation (série de Fourier, fonctions splines, polynômes...) c'est leur parcimonie : pour l'approximation d'une fonction ils auront beaucoup moins de paramètres que les autres approximateurs (Yann, 1998).

4.5 Perceptron multicouches

4.5.1 Introduction

En 1969 : M. Minsky et S. Papert (Comon, 1991) publient un ouvrage qui met en exergue les limitations théoriques du perceptron. Limitations alors connues, notamment concernant l'impossibilité de traiter par ce modèle des problèmes non linéaires. Ils étendent implicitement ces limitations à tous modèles de réseaux de neurones artificiels. Plusieurs techniques ont été proposées pour dépasser ces limites, parmi ces techniques on cite celle qui consiste à recoder le problème posé pour le rendre linéaire ou bien recoder l'entrée du perceptron de manière qu'elle corresponde à une distorsion non-linéaire de l'espace (les réseaux RBF). Malgré leur intérêt, aucune de ces techniques ne peut se comparer avec la popularité des réseaux avec rétropropagation de l'erreur, qui constituent une part importante des applications des réseaux de neurones.

4.5.2 Architecture et principe

Le perceptron multicouches est une extension du perceptron monocouche, avec une ou plusieurs couches cachées entre l'entrée et la sortie. L'idée principale est de grouper des neurones dans une couche. En place ensuite bout à bout plusieurs couches et connecte complètement les neurones de deux couches adjacentes (**Figure 4.6**). Les entrées des neurones de la deuxième couche sont donc en fait les sorties des neurones de la première couche. Les neurones de la première couche sont reliés au monde extérieur et reçoivent tous le même vecteur d'entrée. Ils calculent alors leur sorties qui sont transmises aux neurones de la deuxième couche, etc. Les sorties des neurones de la dernière couche forment la sortie du réseau.

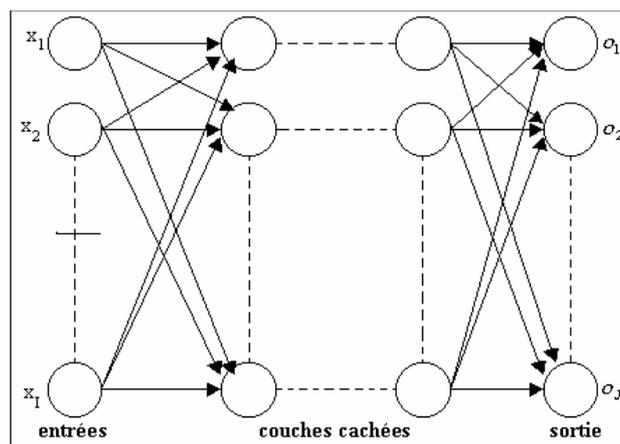


Figure 4.6 Structure du perceptron multicouches.

Les fonctions d'activation utilisées dans ce type de réseaux sont principalement les fonctions à seuil ou sigmoïdes ajustables dans le but de modifier la fonction calculée. Il peut résoudre des problèmes non-linéairement séparables et des problèmes logiques plus compliqués. Il suit aussi un apprentissage supervisé selon la règle de correction de l'erreur.

4.5.3 Apprentissage

Le perceptron multicouches utilise un apprentissage supervisé, c'est à dire pour apprendre, le réseau doit connaître la bonne réponse afin de pouvoir calculer un signal d'erreur, ce dernier permet de corriger l'intensité des connexions. L'idée de base est simple, le réseau apprend en essayant de diminuer son erreur à chaque itération, il le fait en changeant l'intensité des connexions en sens inverse du signal d'erreur. Chaque cellule de la couche externe calcule son signal d'erreur, puis elle considère que les cellules de la couche cachée sont responsables de son erreur de manière proportionnelle à ce qu'elles l'ont poussée à la commettre. Pour les cellules de la couche cachée le signal d'erreur ne peut être calculé directement, il doit être évalué en fonction de l'erreur des cellules de la couche de sortie. Chaque cellule de la couche cachée considère que son erreur peut s'estimer par la moyenne des erreurs qu'elle a fait commettre aux cellules de la couche de sortie, l'importance de l'erreur dépend de l'intensité de la connexion entre la cellule cachée et la cellule de sortie, il faut donc pondérer l'erreur par l'intensité reliant la cellule de la couche cachée à la cellule de la couche de sortie, c'est à dire que le signal d'erreur est multiplié par l'intensité de la connexion puis il est renvoyé à la cellule de la couche cachée en réutilisant les mêmes connexions mais dans le sens inverse, d'où le nom de rétro propagation.

4.5.4 Algorithme

L'algorithme de la rétropropagation est un algorithme de gradient itératif conçu pour minimiser un critère quadratique d'erreur entre la sortie obtenue d'un réseau multicouche et la sortie désirée (Claude, 1992). Cette minimisation est réalisée par une configuration des poids adéquate. L'erreur est la différence entre la valeur désirée pour le neurone de sortie et sa valeur calculée par propagation. En effet, l'algorithme nécessite une fonction continue, non-linéaire et différentiable comme fonction de transfert du neurone.

L'algorithme du rétropropagation du gradient de l'erreur se résume aux étapes suivantes :

- Initialisation des poids de connexions à des valeurs aléatoires de faible grandeur;
- Présentation d'un couple (entrée, sortie désirée) de la base d'apprentissage ;
- Présentation de la forme d'entrée sur la couche d'entrée du réseau ;
- Calcul par propagation de la sortie obtenue ;
- Calcul des différents signaux d'erreur des différentes couches ;
- Mise à jour des matrices de connexions ;
- Tant que l'erreur est trop importante, retourner à l'étape 2

L'algorithme de la rétropropagation de gradient, bien que très simple à implanter, nécessite un certain savoir-faire pour une utilisation efficace. En effet, la

convergence de l'algorithme n'est pas prouvée et de multiples variables sont à ajuster précisément en fonction du problème traité.

4.5.5 Quelques aspects pratiques

4.5.5.1. Choix du réseau

La détermination et le choix du réseau optimal pour un processus donné sont des problèmes ouverts, malgré l'existence de quelques travaux, qui permettent pour une vaste classe de réseaux, de déterminer l'architecture optimale. Mis à part les couches d'entrée et de sortie, l'analyste doit décider du nombre de couches intermédiaires ou cachées. Sans couche cachée, le réseau n'offre que de faibles possibilités d'adaptation ; avec une couche cachée, il est capable, avec un nombre suffisant de neurones, d'approximer toute fonction continue. Une seconde couche cachée prend en compte les discontinuités éventuelles. Cependant, on ne sait pas comment construire le réseau, ni combien de neurones sont nécessaires dans la couche cachée, ni combien de liens synaptiques. En effet, si le réseau possède un très grand nombre de poids et de neurones, le réseau est trop souple et si ce nombre est trop petit, le réseau est trop rigide et présente des mauvaises performances. Pour résoudre ce problème plusieurs techniques ont été proposées, la plus intéressante est d'ajuster la taille du réseau (nombre de couches cachées, nombre de neurones par chaque couche, et nombre de poids) pendant la phase d'apprentissage, afin que sa complexité soit adaptée au problème à résoudre.

4.5.5.2. Test d'arrêt

La détermination du critère d'arrêt est cruciale dans la mesure où la convergence peut passer par des minima locaux. En effet, le test d'arrêt est la mesure des performances du réseau pour savoir si la convergence du réseau est atteinte. D'une façon générale, on cherche à arrêter l'algorithme si l'erreur E est minimale c'est à dire si le gradient de l'erreur est proche de zéro.

Généralement, le test d'arrêt est effectué en découpant la base de données en deux parties, une base d'apprentissage (BA) et une base de test (BT), et en alternant des étapes d'apprentissage sur la (BA) et de mesure de performances sur la (BT) jusqu'à atteindre des résultats satisfaisants.

4.5.5.3 Choix du pas d'adaptation

L'apprentissage par des algorithmes de rétro-propagation nécessite la détermination du paramètre d'ajustement des poids synaptiques à chaque itération. En effet, le pas d'adaptation doit être choisi avec soin si on veut une vitesse de convergence suffisante, sans toutefois entraîner de risque d'instabilité de l'algorithme.

4.6 Evaluation du perceptron multicouche

Les réseaux de neurones servent aujourd'hui à toutes sortes d'applications dans divers domaines, ils ont un impact considérable et leur importance grandissant dans le futur.

Cependant, Les réseaux de neurones multicouches dotés de l'algorithme de rétro propagation du gradient sont les modèles connexionnistes les plus étudiés et utilisés à ce jour, les champs d'application de ces réseaux sont très vastes : classification ((Burel, 1991), (Lorquet, 1992)), identification de processus ((Narendra et al, 1991), (Cottrell, 1993)) et prédiction de séries temporelles, commande de processus et de robot, traitement d'image (Burel, 1991), et de parole. Ce sont des modèles robustes et dont les entrées et les sorties peuvent indépendamment être choisies, ce qui permet de traiter diverses classes de problèmes. En effet, lors de la réalisation d'une application utilisant un réseau de neurones multicouches entraîné par l'algorithme de rétro propagation, il faut prendre en considération les points suivants:

- La mise en œuvre de cet algorithme est coûteuse en temps de calcul ce qui rend son application inconfortable pour de nombreux problèmes de taille raisonnable.
- L'apprentissage par rétropropagation peut se trouver piégé dans des minima locaux, et ne peut pas donner la bonne réponse. Pour remédier ce problème, on peut entraîner le réseau à partir de plusieurs choix initiaux de poids pour ne garder que le meilleur ou bien ajouter un bruit aléatoire puis relancer l'apprentissage.

Aujourd'hui, les perceptrons multicouches sont les réseaux utilisés par les développeurs d'applications. Les résultats théoriques sur le mécanisme de comportement de ces réseaux sont encore très pauvres, mais des résultats satisfaisants ont été mis en valeur dans des domaines d'application très divers.

4.7 Modélisation de l'hystérésis magnétique par une Approche neuronale

4.7.1 Modèle développé par Dimitre Makaveev (Dimitre et al, 2003)

Dans les travaux de Dimitre Makaveev on trouve 03 modèles d'hystérésis vectorielle basés sur les réseaux de neurones multicouches à rétropropagation de l'erreur. Le premier modèle vectoriel nécessite un grand nombre de paires de données d'apprentissage, le deuxième est mieux adapté pour le calcul des pertes fer dans les machines électriques et un troisième modèle spécifique qui dépend du type d'aimantation à considérée.

Cependant, dans une machine électrique, la variation du champ magnétique et de l'induction dans le plan de lamination (figure 4.7.a) du FeSi utilisé sont données par :

$$\mathbf{H}(t)=|H(t)|\exp(j\varphi^H(t)) \quad (4.4)$$

et

$$\mathbf{B}(t)=|B(t)|\exp(j\varphi^B(t)) \quad (4.5)$$

La majorité des modèles d'hystérésis proposés dans la littérature (Mayergoyz, 1991), (Della-tore, 1998) et (Vernescu-Spornic et al, 2000)) sont limités dans la description du phénomène et en particulier dans le cas des modèles bidimensionnels d'aimantation arbitraire où il n'existe pas d'information suffisante sur l'applicabilité et l'exactitude de ces divers modèles (c.-à-d., modèles des cercles et des ellipses). La principale difficulté est la détermination de l'état réel du matériau en tenant compte de l'histoire de son excitation magnétique ((Mayergoyz, 1991) et (Friedmann et al, 2000)).

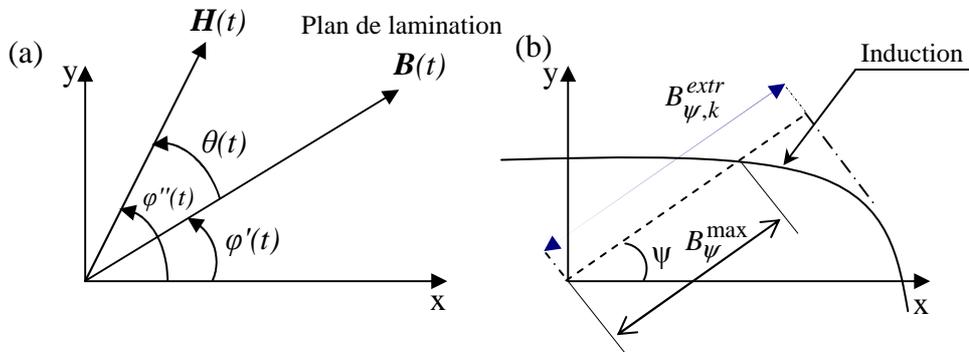


Figure 4.7 Notations: (a) $B(t)$ et $H(t)$ suivant le plan de lamination ; $B_{\psi,k}^{extr}$ et B_{ψ}^{max} de l'induction magnétique

Dans les travaux de Mayergoyz, l'équation :

$$B_k = f(B_k^{extr}, H_k^{extr}, H_k) \quad (4.6)$$

se réduit dans le cas des cycles mineurs à :

$$B_k = B_k^{extr} + f(H_k^{extr}, H_k) \quad (4.7)$$

Le mécanisme de mémoire par lequel les extrema passés $H_{\psi,k}^{extr}$ des projections du vecteur d'entrée H_k dirigé le long de toutes les directions possibles Ψ peut influencer l'évolution du vecteur de sortie B_k contenant l'état mémoire du vecteur du matériau (Mayergoyz, 1991). Basé sur ce mécanisme de mémoire, le modèle vectoriel de Preisach–Mayergoyz est construit par la superposition des contributions des sous-modèles scalaires de Preisach placés le long de toutes les directions Ψ (Mayergoyz, 1991). l'entrée de chaque sous-modèle scalaire est donc, la projection du vecteur d'entrée H_k sur la direction Ψ du sous-modèle scalaire. En effet, Le modèle

n'est pas identifié par des mesures de l'aimantation vectorielle ce qui limite son exactitude.

Dimitre propose l'utilisation d'un réseau de neurone de propagation directe (figure 4.8) afin de surmonter les difficultés rencontrées dans le modèle de Preisach-Mayergoyz. Dans ce cas, la sortie du système y_k d'un tel réseau est déterminée par les poids de ses entrées u_i combinées avec une fonction non linéaire sigmoïde d'activation g :

$$y_k = \tilde{g} \left(\sum_{j=0}^N w_{kj}^{(2)} g \left(\sum_{i=0}^n w_{ji}^{(1)} u_i \right) \right) \quad k = 0, 1, \dots, m \quad (4.8)$$

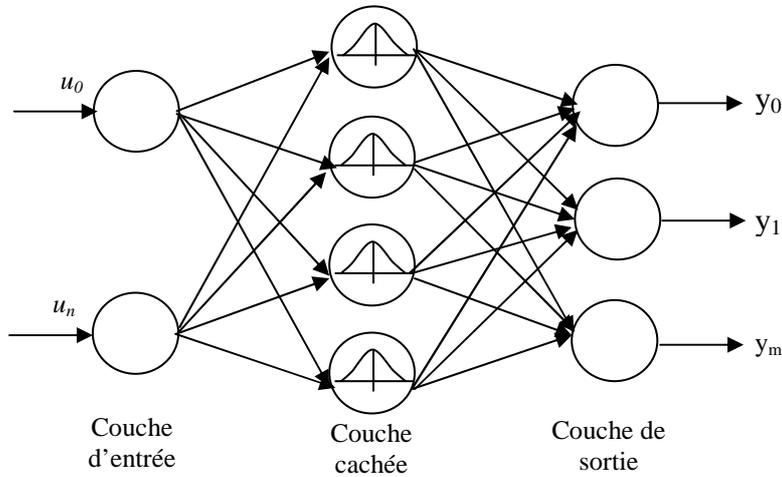


Figure 4.8 FFNN avec une couche cachée

L'entrée du modèle proposé par Dimitre et à tout instant l'amplitude $|H_k|$ et la phase φ_k^H de l'intensité du champ magnétique \mathbf{H}_k , le long de l'extremum $H_{\psi_p, k}^{extr}$ de la projection de \mathbf{H}_k et de l'induction correspondante $B_{\psi_p, k}^{extr}$ le long de l'ensemble des directions $\psi_p, p=1, \dots, P$. La sortie du modèle neuronal est l'amplitude de l'induction $|B_k|$ et le déphasage θ_k (Figure 4.7).

$$(|B_k|, \theta_k) = FFNNX(|H_k|, \varphi_k^H, H_{\psi_1, k}^{extr}, B_{\psi_1, k}^{extr}, \dots, H_{\psi_P, k}^{extr}, B_{\psi_P, k}^{extr}) \quad (4.9)$$

Le modèle est ainsi capable d'approximer la relation entre \mathbf{H}_k et \mathbf{B}_k pour une aimantation vectorielle arbitraire en tenant compte du mécanisme de mémoire du modèle de Mayergoyz. L'exactitude d'approximation du modèle augmente avec l'utilisation de plusieurs directions différentes. En effet, l'inconvénient majeur de ce modèle est que le FFNN exige un ensemble de données d'apprentissage dans tout l'intervalle de variation possible de l'aimantation vectorielle qui n'est pas facile à obtenir.

La construction du modèle **B** vers **H** se fait de la même façon que celui de **H** vers **B** déjà discuté auparavant. Ce sont des modèles qui ne prévoient pas les cycles mineurs pour toute direction projetée Ψ . Dans ce cas là, chaque valeur extrême $H_{\Psi,k}^{extr}$ correspond à une valeur extrême $B_{\Psi,k}^{extr}$. Nous pouvons ainsi construire un FFNN avec $|B_k|$ et φ_k^B en entrée, le long des valeurs de $B_{\Psi,k}^{extr}$ pour l'ensemble P de directions Ψ_p (Figure 4.7.b). La sortie du modèle est $|H_k|$ et θ_k :

$$(|H_k|, \theta_k) = FFNN(|B_k|, \varphi_k^B, B_{\Psi_1,k}^{extr}, \dots, B_{\Psi_p,k}^{extr}) \quad (4.10)$$

Ce deuxième modèle présente un modèle vectoriel arbitraire d'hystérésis précis pour les inductions convexes. Les modèles proposés par Dimitré ont été validés par des résultats expérimentaux sur un échantillon d'acier non-orienté de FeSi (Dimitré et al, 2003), (Dimitré et al, 2002). (Dimitré et al, 2001a). (Dimitré et al, 2001b). .

4.7.2 Modèle neuronal d'hystérésis proposé

Les réseaux de neurones à propagation directe (FFNN) avec au moins une couche cachée (figure 4.8) ont la propriété d'approximateurs universels des fonctions non-linéaires multivariées (Bishop, 1995). Les sorties y_k d'un tel réseau sont déterminées par les poids de ses entrées u_i , combinées avec une fonction nonlinéaire sigmoïde d'activation g (une activation linéaire \tilde{g} est employé pour la couche de sortie)(Equation 4.8):

Le nombre de couches cachées joue un rôle crucial dans le contrôle de la capacité du réseau de neurone. Cependant, si le nombre de neurone est trop petit, alors le réseau possède trop peu de paramètres et ne peut capter toutes les dépendances qui servent à modéliser et prédire le comportement du matériau magnétique utilisé dans notre cas. A l'inverse, si l'on choisit un nombre important de neurones dans la couche cachée, le nombre de paramètres du modèle augmente et il devient possible pendant la phase d'optimisation des paramètres, de modéliser certaines relations engendrées par des fluctuations statistiques propres à l'ensemble d'apprentissage utilisé. dans le cas d'une seule couche cachée. Les poids $w_{ji}^{(k)}$ sont déterminés par apprentissage du réseau neurone, de sorte que la différence soit minimale entre les sorties du réseau et les sorties du système réel, pour des entrées données. Un ensemble de paires de données d'apprentissage sur tout l'intervalle de données d'entrées-sorties sont employées pour le processus d'apprentissage du réseau, comme les réseaux de neurones sont capables d'effectuer des interpolations non-linéaires précises, mais ne devront pas être utilisés pour l'extrapolation. Afin de s'assurer que le réseau de neurones s'en tient aux relations fondamentales de dépendance, sa performance est déterminée par l'utilisation d'un autre ensemble de données entrées-sorties mesurées (générée par un modèle existant) qui n'ont pas été utilisées dans l'apprentissage. L'ensemble approprié de données pour la procédure d'apprentissage, le nombre de

couches cachées et le nombre de neurone utilisés sont déterminées expérimentalement pour une généralisation du réseau.

Dans le cas de la modélisation de l'hystérésis statique, le FFNN peut être employé pour approximer une fonction du type (Equation 5.6). en effet, le réseau utilisé peut être également employer pour la prédiction et la modélisation des aimantations circulaires et et elliptiques (Dimitré et al, 2002).

Le modèle d'hystérésis magnétique basé sur les réseaux de neurones est construit comme suit : à tout instant, l'entrée du modèle est l'amplitude du champ magnétique $H(t)$ et l'induction correspondante $B(t)$ le long de la direction de lamination du matériau utilisé. La sortie du modèle neuronal est l'amplitude de l'induction $B(t)$. (figure.4.9)

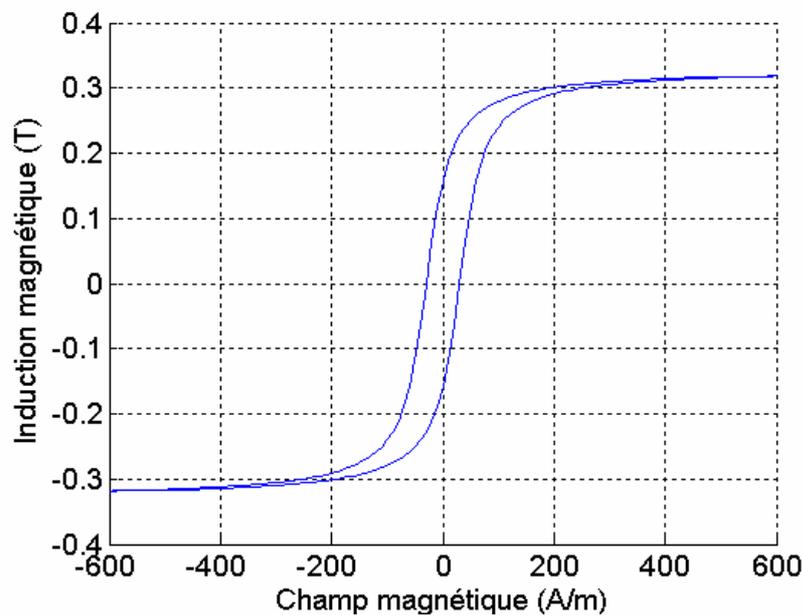


Figure 4.9 Cycle d'hystérésis quasi-statique

Le modèle est ainsi capable d'approximer la relation entre $H(t)$ et $B(t)$ pour une aimantation donnée. L'exactitude d'approximation du modèle augmente avec la détermination de la structure optimale du modèle de réseau de neurone. En effet, l'inconvénient majeur de ce modèle est que le FFNN exige un ensemble de données d'apprentissage dans tout l'intervalle de variation possible de l'aimantation qui n'est pas facile à obtenir. Cependant, si nous disposons de ce nombre important de données mesurées (obtenue à partir de modèles valide), et si le réseau est entraîné d'une manière correcte, on aura un modèle d'hystérésis très précis.

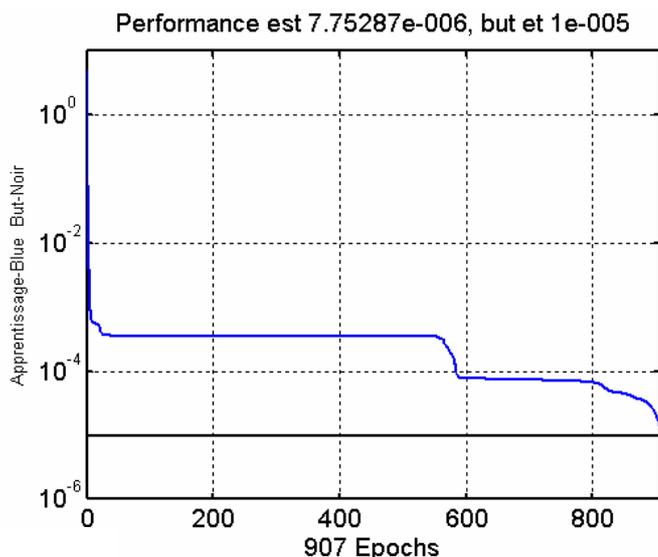


Figure 4.10 Performance du réseau de neurone

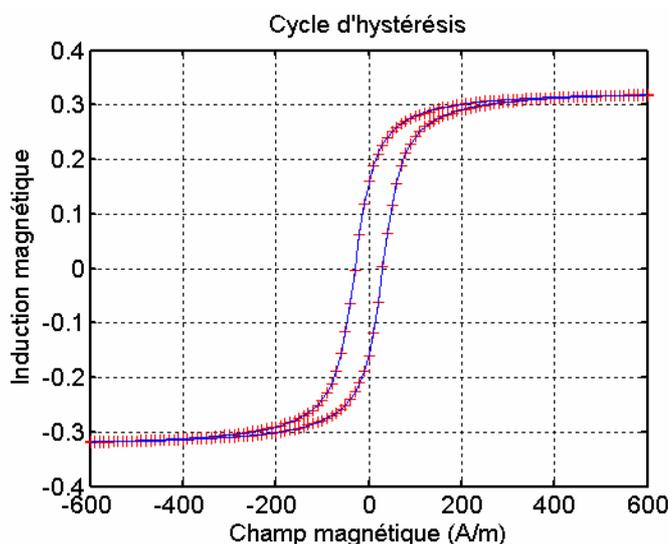


Figure 4.11: Cycle généré par le modèle neurone

La méthode précédente a un inconvénient, en effet, la mesure de données d'apprentissage du modèle doit être faite par un dispositif de test bien précis afin de minimiser l'introduction de données bruitées. La construction du modèle $B(t)$ vers $H(t)$ se fait de la même façon que celui de $H(t)$ vers $B(t)$.

Notons que le modèle proposé peut être facilement généralisé dans le cas de l'hystérésis vectorielle circulaire et elliptique. L'apprentissage du FFNN devrait employer un ensemble de données plus grand. Notons que l'apprentissage par des données d'aimantation circulaire et elliptique seulement n'est pas suffisant.

Le réseau FFNN avec 02 entrées est entraîné et testé pour plusieurs cycles générés par le modèle statique d'hystérésis proposé par Paiboon Nakmahachalasint (Paibon et al, 2002), Le FFNN a été entraîné par un algorithme de gradient conjugué. L'exactitude

est bonne et peut être adaptée aux conditions de l'application du modèle par une diminution ou par une augmentation de la taille des données d'apprentissage.

4.8 Conclusion

Basé sur les possibilités d'approximation de fonctions par des réseaux de neurones à rétro-propagation un modèle d'hystérésis quasi-statique est présenté. Le modèle proposé exige un grand nombre de données entrée-sortie pour son apprentissage. En effet, le modèle de réseau de neurone de l'hystérésis magnétique peut être facilement généralisé et adapté pour la simulation de l'aimantation magnétique en régime alternatif. Le choix du modèle spécifique, ses paramètres et de la structure du réseau dépend des types d'aimantation à considérer. La meilleure précision sera atteinte par utilisation d'une structure de réseau complexe et/ou l'utilisation d'un nombre important de données d'apprentissage. Des algorithmes standard des réseaux de neurones sont à employer.

*Identification floue de l'hystérésis
Magnétique dynamique à
Partir des données mesurées*

5.1 Introduction à l'identification des systèmes

Notre travail concerne un aspect lié à la modélisation des matériaux magnétiques par des techniques d'identifications floues. Le modèle d'un système décrit la relation entre ses variables d'entrées et de sorties caractérisée par des formules mathématiques. Cependant, les systèmes sont décrits graphiquement (tableaux), par des expressions mathématiques sous formes d'équations différentielles dans le domaine de l'ingénierie appelées modèles mathématiques (Ljung et al, 1994) et finalement dans le cas des systèmes complexes on développe des logiciels composés de d'autres sous-modèles interconnectés décrivant ainsi le système complet (Mariela, 2003).

Le deuxième moyen d'identification et de modéliser un système à partir de l'expérimentation et de l'observation de son comportement. Dans ce cas les entrées et les sorties du processus son analysées dans le but d'inférer un modèle (graphique, mathématique,...etc). En effet, le principal inconvénient de cette technique réside dans la difficulté de proposer un modèle décrivant exactement le système réel. Cependant, pour des considérations liées à l'utilisation du modèle, nous pouvons acceptés un tel modèle sans tenir compte de sa précision.

La modélisation des systèmes par des techniques d'identification est basée sur les trois principaux éléments suivant (Ljung, 1997) :

- Un ensemble de données mesurées associées aux variables d'entrée et de sortie du système.
- Un ensemble de structures de modèles
- Ajustement du modèle et sa validation.

En plus des modèles cités précédemment, il existe des modèles basés sur les réseaux de neurones artificiels, sur la logique floue et sur les systèmes neuro-flous discutés dans le chapitre trois de cette thèse. Ce sont des modèles de structure plus simple présentant une relation directe entre la variable d'entrée et la sortie, basés sur l'apprentissage du comportement du système à partir des données entrée-sortie mesurées. Cependant, le développement de modèles par les approches de l'intelligence artificielle peut se faire à partir de la connaissance préalable et des données mesurées du dispositif à identifier. En effet, dans l'identification floue (Babuska, 1998) des systèmes, une fois la structure du modèle est fixée, la performance de la méthode de modélisation peut être réglée en ajustant les paramètres (Grisales, 2007).

Dans les paragraphes suivants, nous décrivons les différentes étapes de sélection de la structure d'un modèle flou et les techniques de détermination de ces paramètres à partir de données entrée-sortie dans le but de modéliser le comportement hystérique dynamique des matériaux utilisés dans la construction des machines électriques.

5.1.1 Méthodologie d'identification floue

Pour la prédiction du comportement d'un système en vue de sa modélisation par des techniques floues, on doit tout d'abord déterminer sa structure et puis on estime ces paramètres par minimisation au sens des moindres carré d'un critère non-linéaire de la façon suivante :

$$\{\alpha_1, \dots, \alpha_r, \theta_1, \dots, \theta_r\} = \arg \min \sum_{k=1}^n \left(y_k - \sum_{i=1}^r \lambda_i(z_k, \alpha_i) \theta_i^T W_k \right)^2 \quad (5.1)$$

Avec,

n : nombre de paires de données (x_k, y_k) , $k=1, \dots, n$.

z_k : variables de l'antécédent.

W_k : variables du conséquent.

α_i et θ_i^T : vecteurs des paramètres de l'antécédent et du conséquent.

$\lambda_i(z)$: degré normalisé d'accomplissement de la règle i des bases de r règles.

Les méthodes d'optimisation utilisées sont les techniques d'optimisation globale des paramètres, à savoir les algorithmes génétiques, les algorithmes du rétro propagation du gradient et les algorithmes de la classification floue dans l'espace des entrées-sorties.

Dans les prochaines sections, nous nous intéressons en particulier, aux méthodes de construction de modèles flous à partir des données entrée-sortie du système en utilisant des techniques de classification flou.

5.1.2 L'identification basée sur des données mesurées

L'objectif principal est l'obtention d'un modèle flou à partir des données numériques obtenues par expérimentation sur le système à modéliser. L'objectif des entrées appliquées au système est de parcourir l'ensemble de l'espace dans lequel on recherche à modéliser le comportement du système (Grisales, 2007). La modélisation floue à partir des données entrée-sortie peut être basée sur des prototypes ou sur un ajout progressif de fonctions d'appartenances et enfin sur des techniques de classification floue, dans laquelle les règles du modèle flou peuvent être extraites à partir de la conformation de groupes de données (classes) dans l'espace produit d'entrée-sortie.

5.2 Groupage des données

La résolution des problèmes de groupage est principalement la recherche de données susceptibles d'appartenir à des catégories ou classes différentes. Les techniques de classification sont capables d'attribuer une classe à un sous-ensemble de forme inconnue ou de refuser de lui attribuer une classe si la forme inconnue est très

éloignée des formes utilisées pour l'apprentissage. Les performances de la technique de classification dépendent essentiellement du prétraitement effectué sur les données brutes.

5.3 Algorithmes de groupage

La mise en œuvre d'algorithmes de groupages pour les systèmes flous repose essentiellement sur l'expertise humaine et la disponibilité de données mesurées décrivant le phénomène. Cependant, le rôle principal de l'algorithme est l'ajustement progressif des paramètres du modèle dans le but de minimiser l'erreur de prédiction commise par le système de règles floues.

5.3.1 Groupage flou

Les algorithmes de groupage flou ou de classification (Clustering en Anglais) sont des techniques d'induction de règles floues. En effet, ils sont utilisés principalement dans le but d'organiser des données en groupes cohérents associés de règles floues pour rendre compte de l'appartenance d'un individu à plusieurs classes (Ahmedou et al,1997).

5.3.2 Techniques de groupage

Plusieurs approches et techniques de groupage existent dans la littérature. Cependant, on peut distinguer deux méthodes selon le type d'apprentissage permettant la détermination et l'optimisation du nombre de groupes (Daniel, 2006)

5.3.2.1 Méthodes statiques d'adaptation

Dans cette catégorie de méthodes, l'algorithme de classification commence par un nombre fixe de classes déterminées par l'utilisateur mis à jour pendant le procédé de classification par un processus d'optimisation, on retrouve dans cette catégorie le *Hard Clustering-C-Means* (HCM) et le *soft clustering-Fuzzy C-Means* (FCM).

Les méthodes HCM et FCM divisent l'ensemble de donnée en classes et trouvent les centres des classes par minimisation d'une fonction objective ou de distance (Pal *et al.*, 1995) et (Lee *et al.*, 2001).

5.3.2.2 Méthodes dynamiques d'adaptation

Ce sont des méthodes capables de déterminer automatiquement le nombre de classes. On peut citer deux catégories de méthodes (Lee *et al.*, 2001), (Ahmedou *et al.*, 1997) : *Growing Partitioning Algorithms* (GPA) ou algorithme de partitionnement croissant, et *Shrinking Partitioning Algorithms* (SPA) ou algorithme de partitionnement décroissant. Le premier algorithme commence par des classes vides et adapte les nouvelles classes jusqu'à satisfaction d'un critère spécifié alors que le deuxième algorithme et dans le but d'accroître le nombre de classes produites

commence par un nombre raisonnable de classes et élimine celles qui ont une densité faible durant le processus d'évaluation (Daniel, 2006).

5.4 Méthodes de coalescence floue

Les modèles flous sont considérés sous l'optique d'une approche de modélisation multi-linéaire, qui essaye de résoudre un problème complexe de modélisation en le décomposant en plusieurs sous-problèmes plus simples. Nous considérons des méthodes de génération automatique de la décomposition, principalement à partir des données du matériau magnétique étudié. Dans cette section nous abordons une classe appropriée d'algorithmes de coalescence floue utilisés pour l'identification de l'hystérésis des matériaux magnétiques (Khodja, 1997).

5.4.1. Notation et Concepts de base

Soit le vecteur d'observation k (mesures) d'un processus physique :

$$z = \{z_{k1}, z_{k2}, \dots, z_{kn}\}^T, \quad 1 < k < z_k, z_k \in R^n \quad (5.2)$$

Où N est le nombre des observations et n le nombre de variables observées.

La matrice de l'ensemble des N observations dénoté par $Z = \{z_k \quad k = 1, 2, \dots, N\}$ est représentée par :

$$Z = \begin{bmatrix} z_{11} & z_{12} & z_{1N} \\ z_{21} & z_{22} & z_{2N} \\ \vdots & \vdots & \vdots \\ z_{n1} & z_{n2} & z_{nN} \end{bmatrix} \quad (5.3)$$

Dans le cas de la modélisation des systèmes dynamiques, les colonnes de Z contiennent les échantillons des signaux observés en fonction du temps et les lignes sont des variables physiques mesurées dans le système.

L'objectif des algorithmes de classification floue est de à réaliser une classification d'un ensemble de données en établissant une partition floue (introduite par Ruspini (Ruspini, 1969)) des observations en un certain nombre de classes. Au sens de Ruspini (partition floue stricte), une c -partition floue d'un ensemble Z peut être obtenue en définissant des c sous-ensembles flous de Z tel que la somme des degrés d'appartenance pour chaque observation de Z soit unitaire. Aux vecteurs observations $z_k \in Z$ est associé un vecteur de degrés d'appartenances aux différentes classes.

En fait, on associe à chaque observation $z_k \in Z$ un vecteur de degrés d'appartenance aux différentes classes. L'assemblage de ces vecteurs pour l'ensemble des N observations de Z définit une matrice U (de dimension $c \times N$) où l'élément μ_{ik} représente le coefficient d'appartenance de l'observation z_k à la classe c . Cette matrice établit une relation d'ordre floue et traduit l'idée d'une partition floue en c classes (Grisales, 2006).

Les propriétés suivantes doivent être satisfaites par la matrice d'appartenance $[U = \mu_{ik}]$ appelée aussi matrice de partition floue.

$$\mu_{ik} \in [0,1], \quad 1 \leq i \leq c, \quad 1 \leq k \leq N \quad (5.4)$$

$$0 < \sum_{k=1}^N \mu_{ik} < N, \quad 1 \leq i \leq c, \quad (5.5)$$

Et enfin la condition de normalisation

$$\sum_{i=1}^c \mu_{ik} = 1, \quad 1 \leq k \leq N, \quad (5.6)$$

5.4.2 Méthode des c-moyennes floues (FCM)

La méthode FCM issue des travaux de Dunn (Dunn, 1974), est une des différentes méthodes de coalescence floue basés sur la minimisation de la fonction objectif *c-mean* (Yu et al, 2004) (Grisales, 2007), de la forme :

$$J_{FCM}(Z;U,V) = \sum_{i=1}^c \sum_{k=1}^N (\mu_{ik})^m D_{ikA}^2 \quad (5.7)$$

Où Z est l'ensemble des données,
 $U = [\mu_{ik}]$: la matrice de partition floue (de dimension $c \times N$),
 $V = [v_1, v_2, \dots, v_c]$: un vecteur de prototypes de clusters(centres).
 $m \in [1, \infty]$ est un facteur qui désigne le degré de flou de la partition.

La norme de la distance quadratique définissant la mesure de distance entre l'observation z_k et le centre v_i de la métrique induite par A est donnée par :

$$D_{ikA}^2 = \|z_k - v_i\|_A^2 = (z_k - v_i)^T A (z_k - v_i), \quad 1 \leq i \leq c, \quad 1 \leq k \leq N \quad (5.8)$$

La forme des clusters dans l'espace des données du système étudié dépend directement du degré flou de la partition m . Cependant, La partition devient de plus en plus floue avec l'augmentation du paramètre m . Pour m au voisinage de la valeur 1, la fonction d'appartenance pour chaque cluster prend la forme booléenne ($\mu_{ik} \in \{0,1\}$). La

partition ($\mu_{ik} = 1/c$) et floue au maximum si $m \rightarrow \infty$, dans ce cas, les moyennes des clusters sont toutes égales à la moyenne de Z (Grisales, 2007).

La valeur de la fonction $J_{FCM}(Z, U, V)$ exprime la mesure de non similarité, il est déterminé par la somme des carrés des distances entre chaque vecteur de données z_k et le centre du cluster correspondant v_i . Le degré d'activation du cluster $(\mu_{ik})^m$ correspondant au vecteur de données z_k a un effet de pondération sur la mesure de la distance. En effet,

La minimisation de $J_{FCM}(Z, U, V)$ peut sse faire par plusieurs méthodes, parmi lesquelles la plus utilisée est l'algorithme *Fuzzy c-Means (FCM)*. Dans ce cas, les points stationnaires de la fonction objective peuvent être trouvés en ajoutant la contrainte de normalisation (5.6) au critère J_{FCM} au moyen des multiplicateurs de Lagrange :

$$\bar{J}_{FCM}(Z; U, V, \lambda) = \sum_{i=1}^c \sum_{k=1}^N (\mu_{ikA})^m D_{ikA}^2 + \sum_{k=1}^N \lambda_k \left[\sum_{i=1}^c \mu_{ik} - 1 \right] \quad (5.9)$$

Où les termes λ_k sont les coefficients multiplicateurs de Lagrange. La minimisation du critère J_{FCM} s'obtient alors en annulant le gradient de \bar{J}_{FCM} par rapport U, V et λ .

Si $D_{ikA}^2 > 0, \forall i, k$ et $m > 1$, alors on obtient les relations de mise à jour suivantes :

Pour les coefficients μ_{ik} de la matrice de partition floue :

$$\mu_{ik} = \frac{1}{\sum_{j=1}^c (D_{ikA}^2 / D_{jkA}^2)^{1/(m-1)}}, \quad 1 \leq i \leq c, \quad 1 \leq k \leq N, \quad (5.10)$$

Pour les prototypes (centres) v_i des clusters :

$$v_i = \frac{\sum_{k=1}^N (\mu_{ik})^m \cdot z_k}{\sum_{k=1}^N (\mu_{ik})^m}, \quad 1 \leq i \leq c. \quad (5.11)$$

De l'expression (5.11), on peut remarquer que v_i représente une moyenne pondérée des données qui appartiennent à une classe, où le facteur de pondération est associé aux degrés d'appartenance floue. Lorsque la partition atteint son seuil de convergence ε , le processus s'arrête, ceci s'exprime par la relation suivante :

$$\|U^{(t)} - U^{(t-1)}\| < \varepsilon \quad (5.12)$$

L'organigramme général de résolution FCM peut se formuler ainsi :

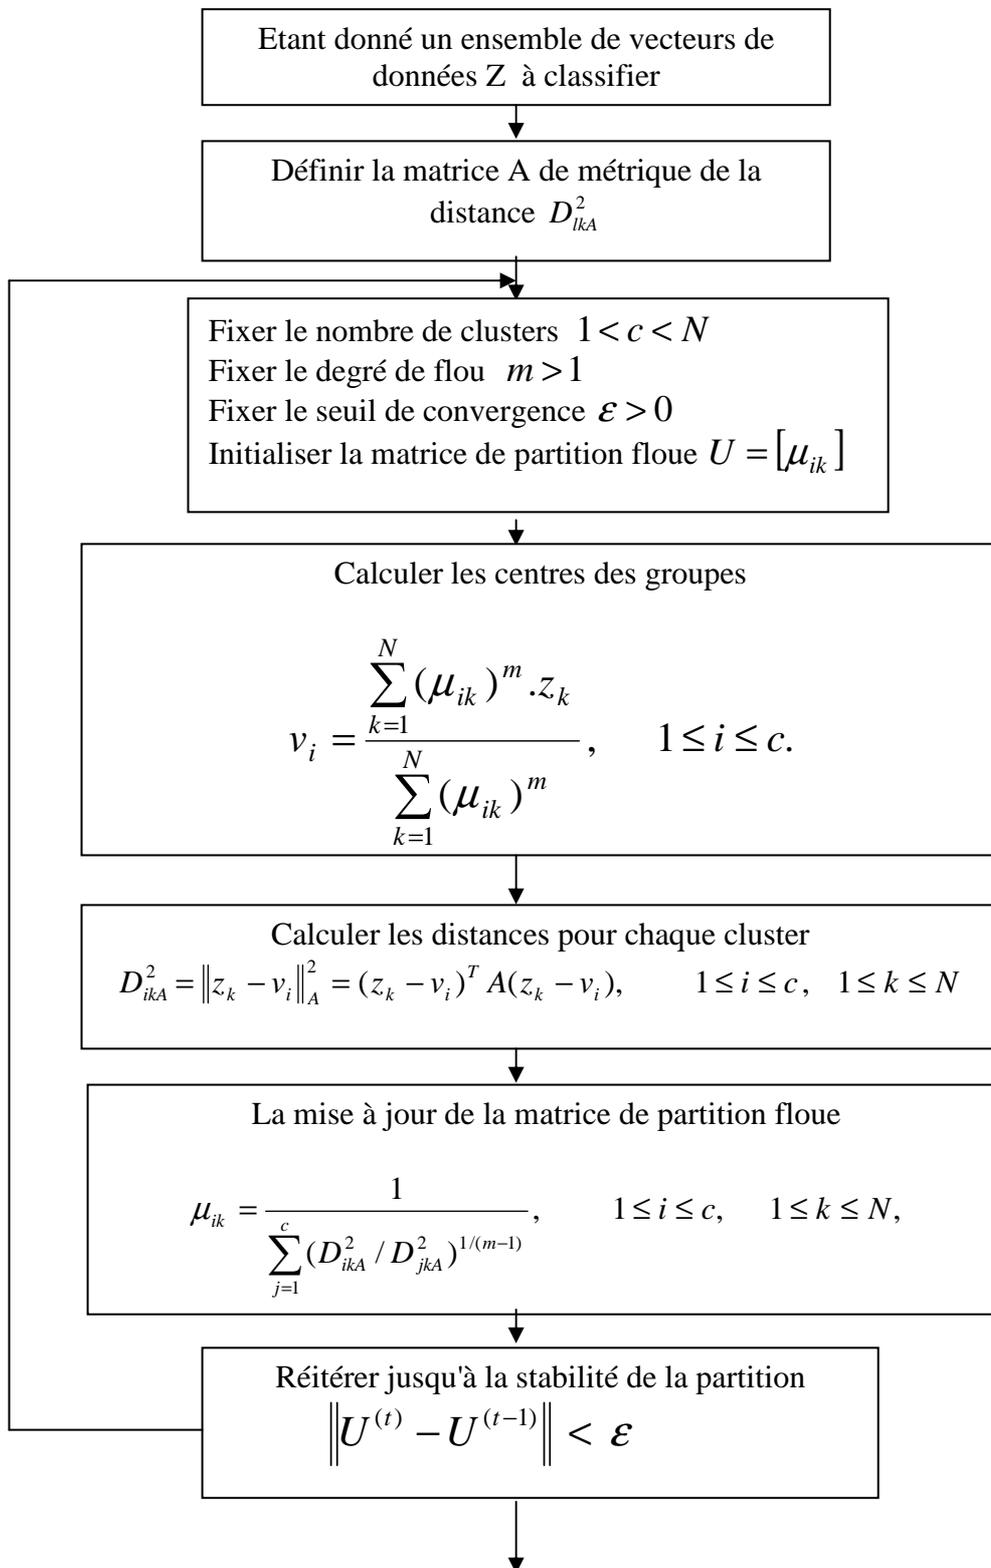


Figure 5.1 Organigramme de la méthode FCM

L'approche (**FCM**) réalise une partition floue d'un ensemble d'observations en un nombre connu *a priori* de classes. Le résultat obtenu dépend de l'initialisation des prototypes (centres) des classes, ainsi que du choix de la métrique employée et des différents paramètres de l'algorithme (c, m, ε) (Grisales, 2007). La forme des clusters dans l'algorithme (**FCM**) est déterminée par le choix de la matrice de norme induite A et par la mesure de distance D_{ikA}^2 .

Nous abordons dans les sections suivantes des techniques de classification floue qui vont être utilisées pour la modélisation floue de l'hystérésis magnétique et qui représentent des extensions de la méthode (**FCM**).

5.4.3 Méthode de Gustafson-Kessel (GK)

L'approche proposée par Gustafson et Kessel (Gustafson et al, 1979) est une extension de la technique **FCM**, elle emploie une norme de distance adaptative dans le but de détecter des clusters de différentes formes géométriques. Pour cela, chaque cluster, possède sa propre matrice de norme définie à l'aide d'une métrique A_i :

$$D_{ikA_i}^2 = (z_k - v_i)^T A_i (z_k - v_i) \quad (5.13)$$

La fonction objectif utilisée par Gustafson et Kessel est donc la suivante :

$$J_{GK}(Z; U, V, A) = \sum_{i=1}^c \sum_{k=1}^N (\mu_{ik})^m D_{ikA_i}^2 \quad (5.14)$$

Où $U \in R^{c \times N}$, $V \in R^{c \times N}$ et $A \in R^{n \times n}$ correspondent aux solutions de la minimisation (points stationnaires) de la fonctionnelle J_{GK} .

Pour des raisons d'optimisation A_i doivent être misent sous quelques contraintes imposées sur les déterminants. En permettant à la matrice A_i de varier alors que leurs déterminants restent fixes. Cela, correspond à une optimisation du nombre de clusters tout en gardant un volume constant :

$$|A_i| = \psi_i \quad (5.15)$$

Par utilisation de la méthode des multiplicateurs de Lagrange (Gustafson et al, 1979), la minimisation du critère d'optimisation conduit à l'expression de A_i suivante :

$$A_i = (\psi_i \cdot \det(F_i))^{1/n} F_i^{-1} \quad (5.16)$$

Où F_i est la matrice de covariance floue du $i^{\text{ème}}$ cluster, définie par l'expression :

$$F_i = \frac{\sum_{k=1}^N (\mu_{ik})^m (z_k - v_i)(z_k - v_i)^T}{\sum_{k=1}^N (\mu_{ik})^m} \quad (5.17)$$

La structure propre de la matrice de covariance floue d'un cluster $F_i \in R^{n \times n}$ nous renseigne sur la forme et l'orientation des clusters. En effet, le plus petit vecteur propre correspond à une normale de la direction du cluster, alors que le plus grand vecteur propre correspondra à la direction du cluster. Cela est illustré sur la Figure 5.2 pour un espace de dimension $n = 2$:

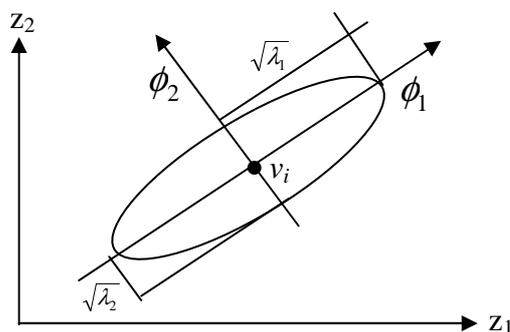


Figure 5.2 Interprétation géométrique de la matrice de covariance floue

L'équation

$$(z - v)^T \cdot F^{-1} \cdot (z - v) = 1 \quad \text{Définit un hyperellipsoïde dans } R^n.$$

La substitution des équations (5.16) et (5.17) dans l'expression (5.13) donne une norme quadratique de distance Mahalanobis généralisée entre le vecteur z_k et la moyenne (centre) du cluster v_i , où la covariance est pondérée par les degrés d'appartenance en U . La mesure de distance pour l'approche **GK** est définie alors comme :

$$D_{ikA_i}^2 = (z_k - v_i)^T (\psi_i \det(F_i)^{1/n} F_i^{-1}) (z_k - v_i) \quad (5.18)$$

Gustafson et Kessel ont en particulier utilisé leur approche pour discriminer deux classes allongées suivant deux directions orthogonales et ayant le même centre de gravité. Gath et Geva, ont aussi introduit une méthode qui sera discutée dans le paragraphe suivant qui descend des FCM et qui fait intervenir une distance non euclidienne.

L'organigramme de clustering de *Gustafson-Kessel* (**GK**) peut se formuler ainsi :

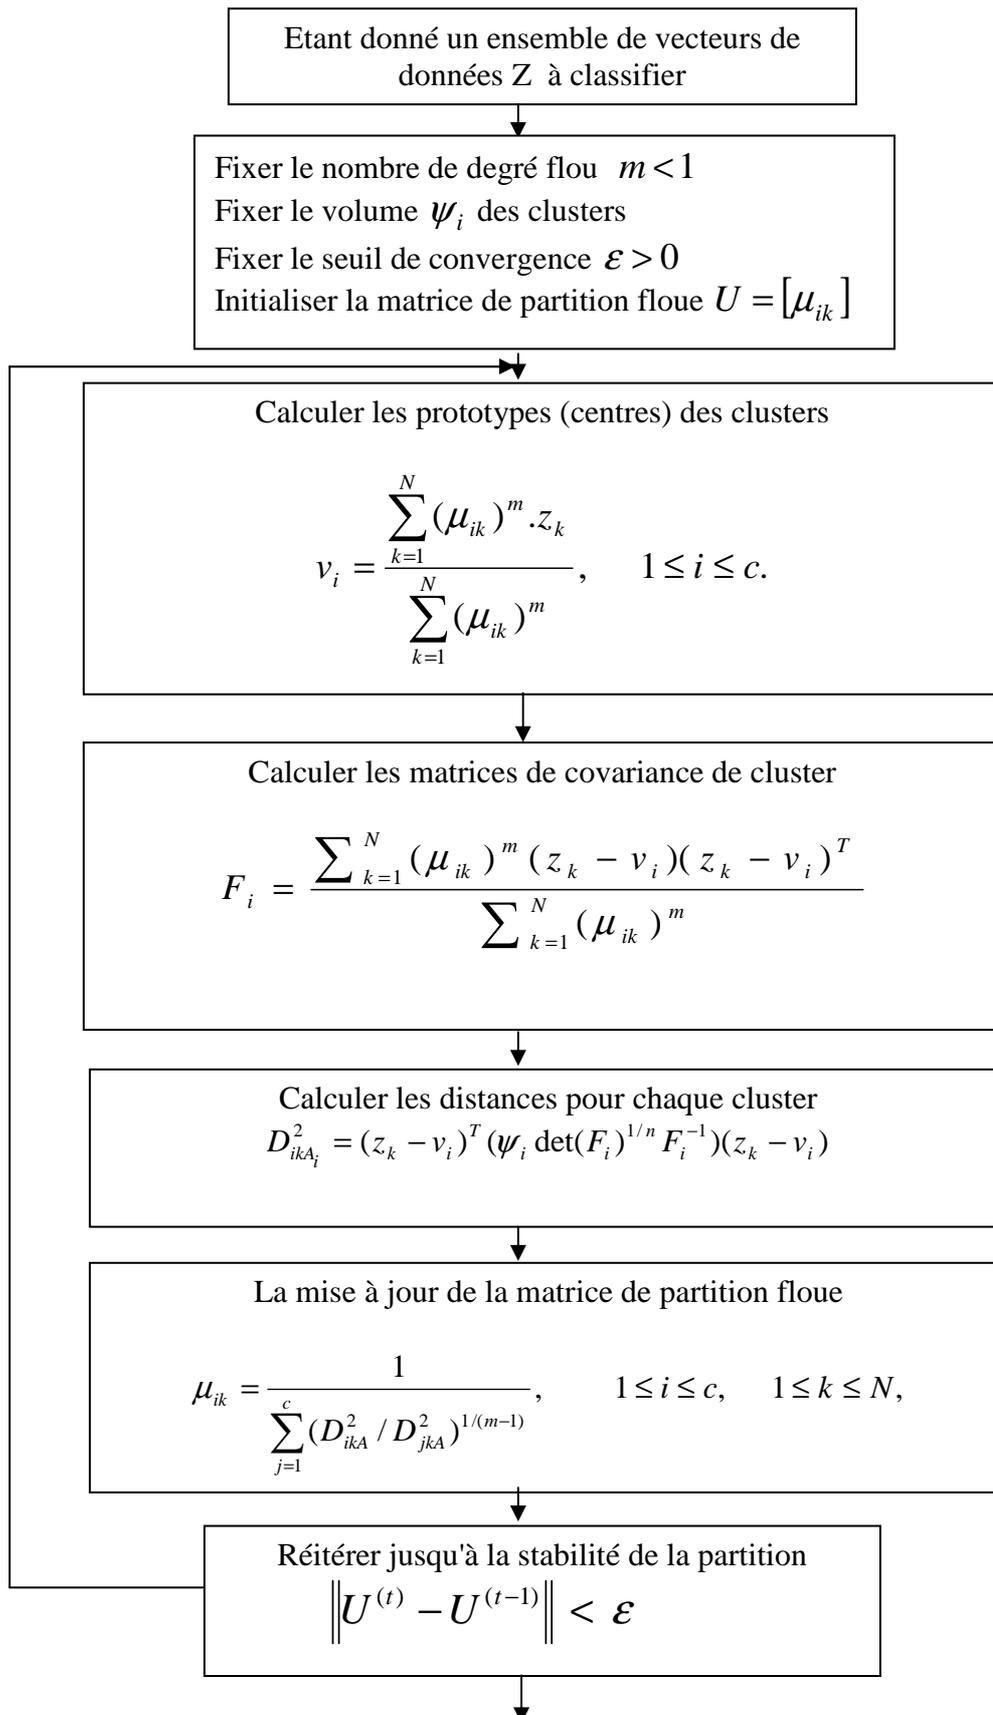


Figure 5.3 Organigramme de la méthode GK

Application de l'approche GK pour la modélisation de l'hystérésis magnétique

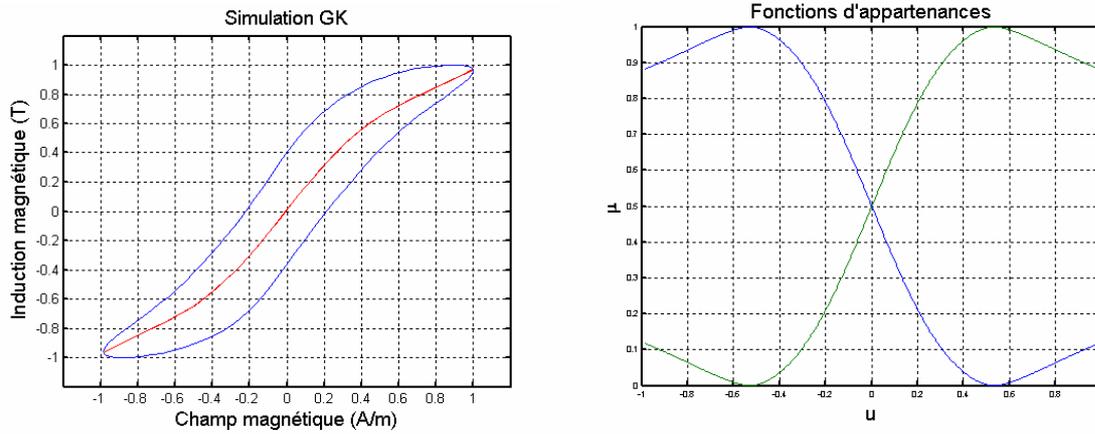


Figure 5.4 Régression GK ($n_u=1, n_y=0, c=2$)

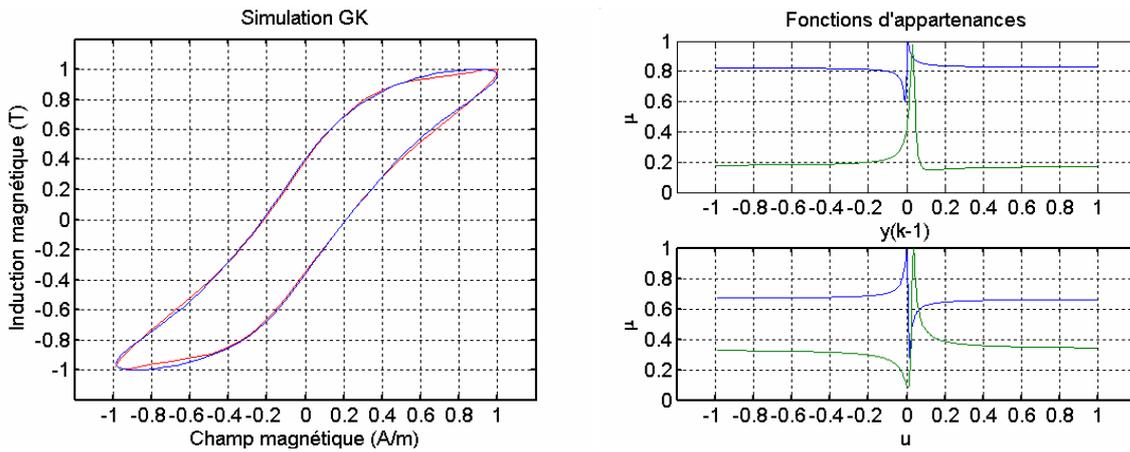


Figure 5.5 Régression GK ($n_u=1, n_y=1, c=2$)

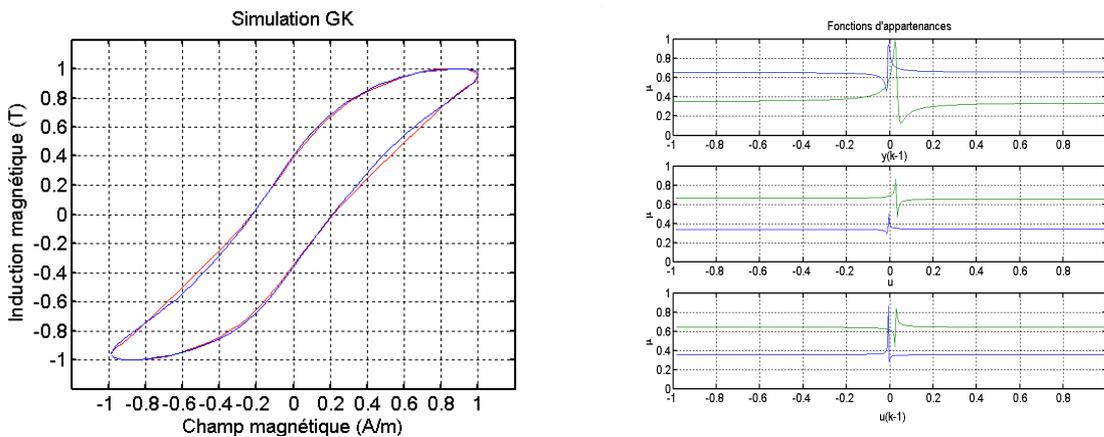


Figure 5.6 Régression GK ($n_u=2, n_y=1, c=2$)

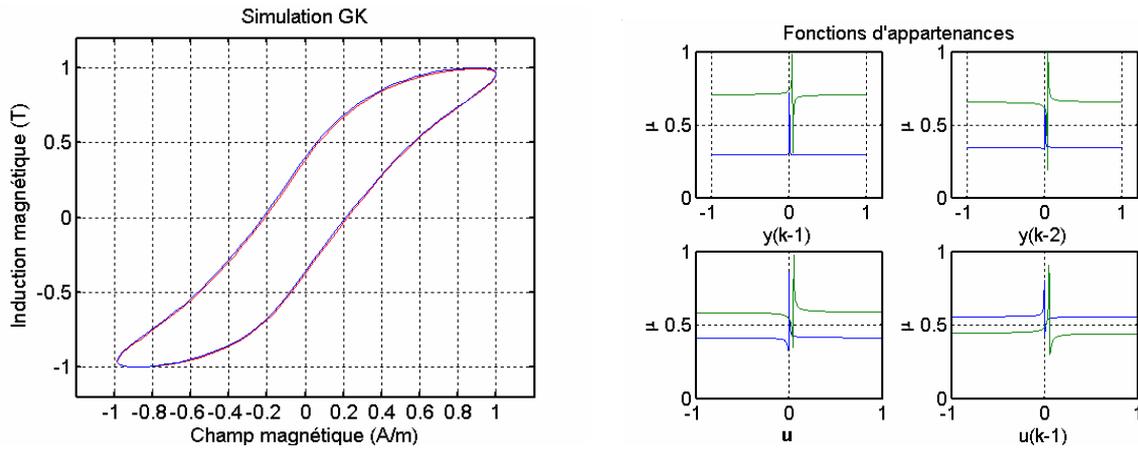


Figure 5.7 Régression GK ($n_u=2, n_y=2, c=2$)

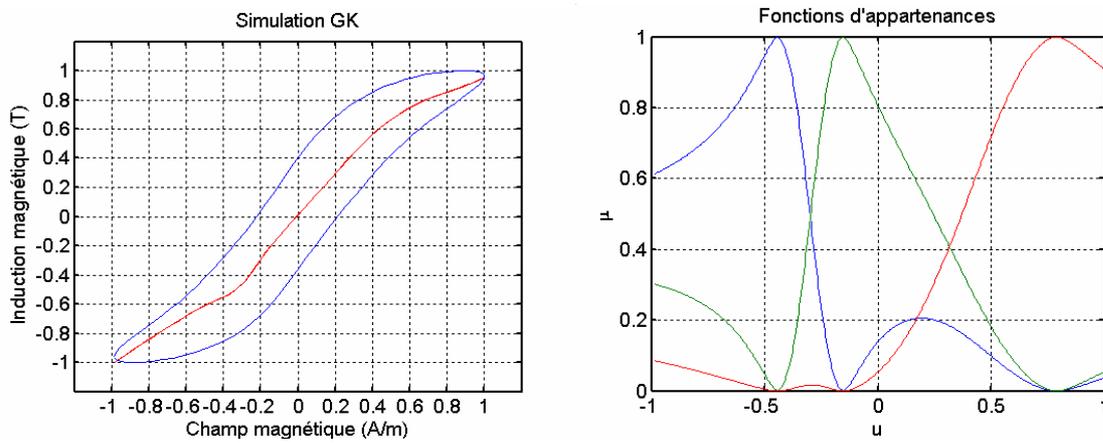


Figure 5.8 Régression GK ($n_u=1, n_y=0, c=3$)

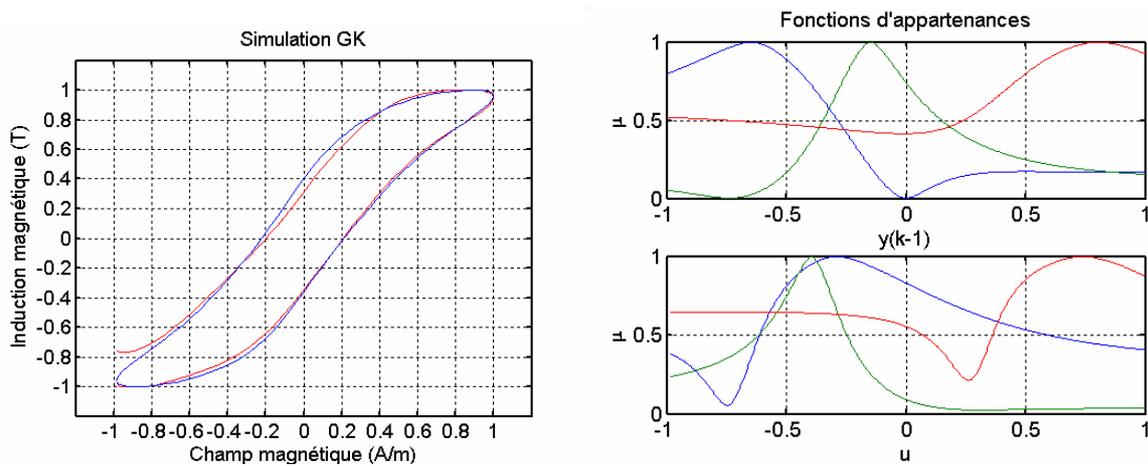


Figure 5.9 Régression GK ($n_u=1, n_y=1, c=3$)

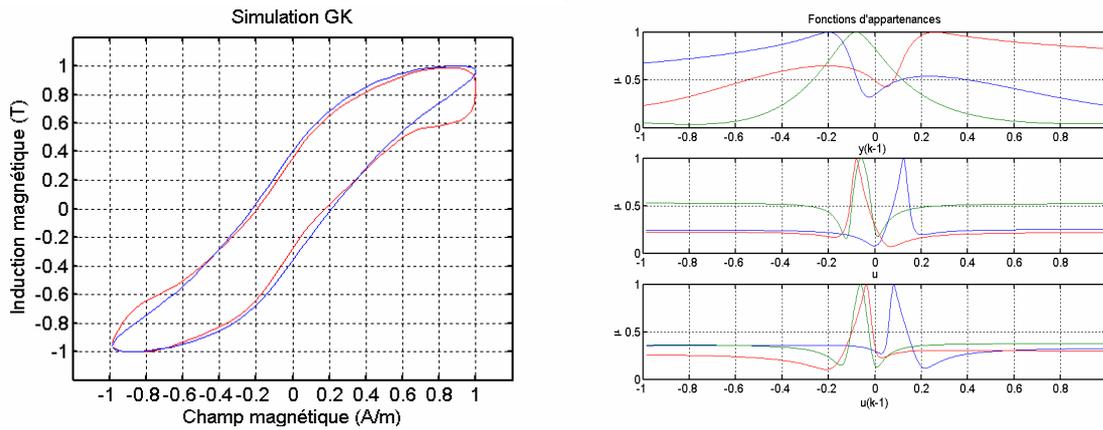


Figure 5.10 Régression GK ($n_u=2, n_y=1, c=3$)

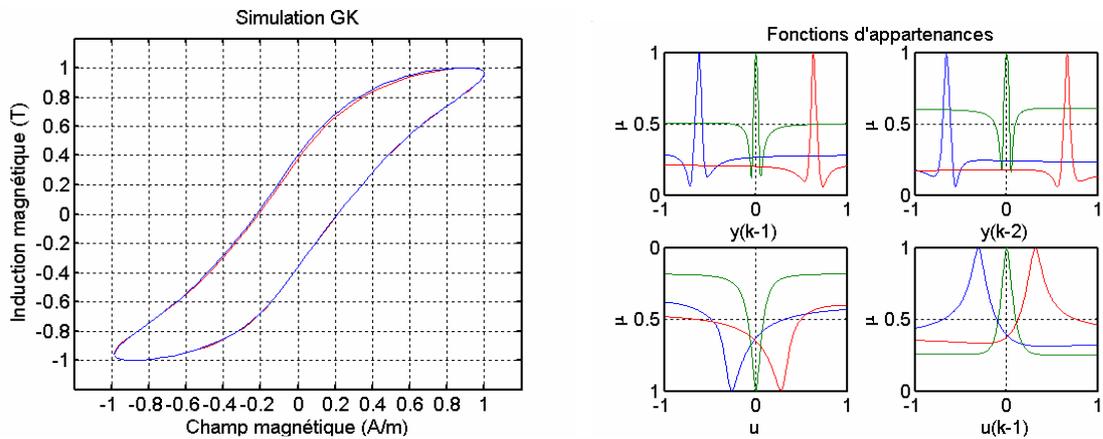


Figure 5.11 Régression GK ($n_u=2, n_y=2, c=3$)

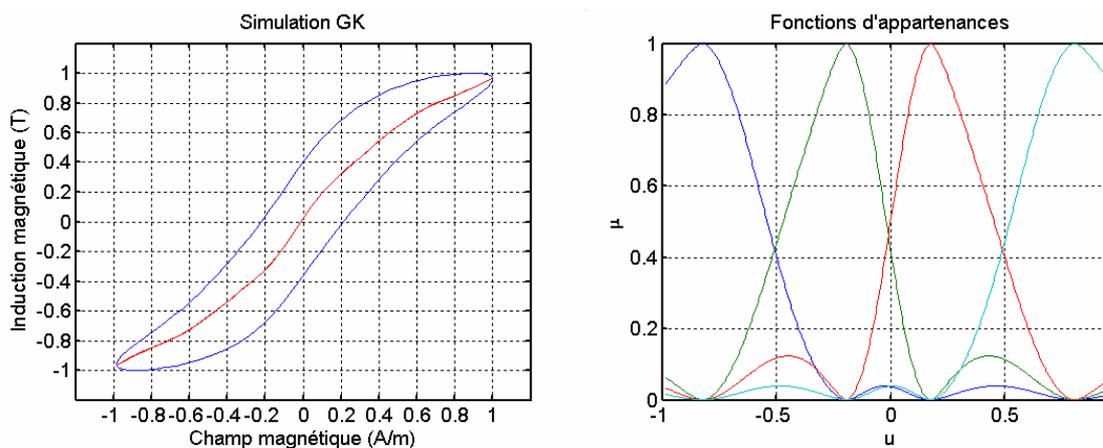


Figure 5.12 Régression GK ($n_u=1, n_y=0, c=4$)

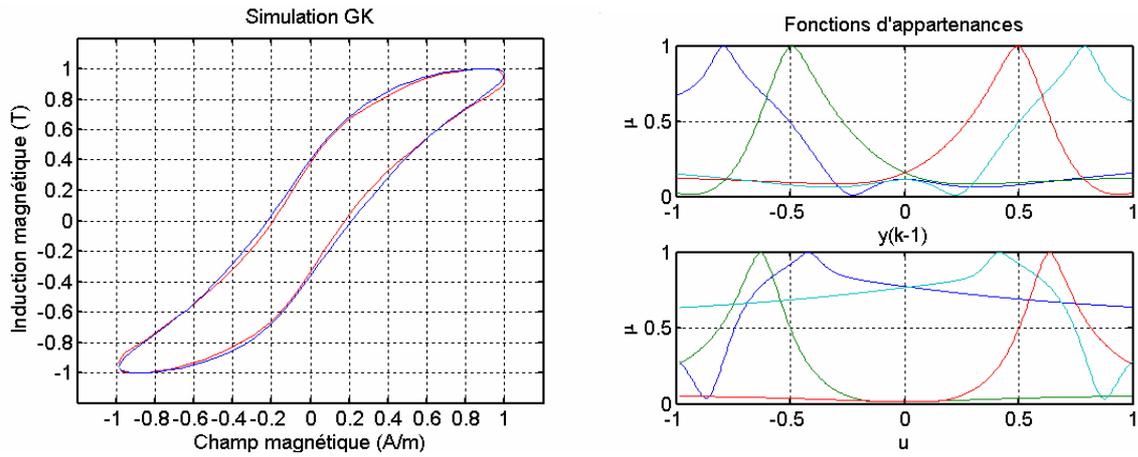


Figure 5.13 Régression GK ($n_u=1, n_y=1, c=4$)

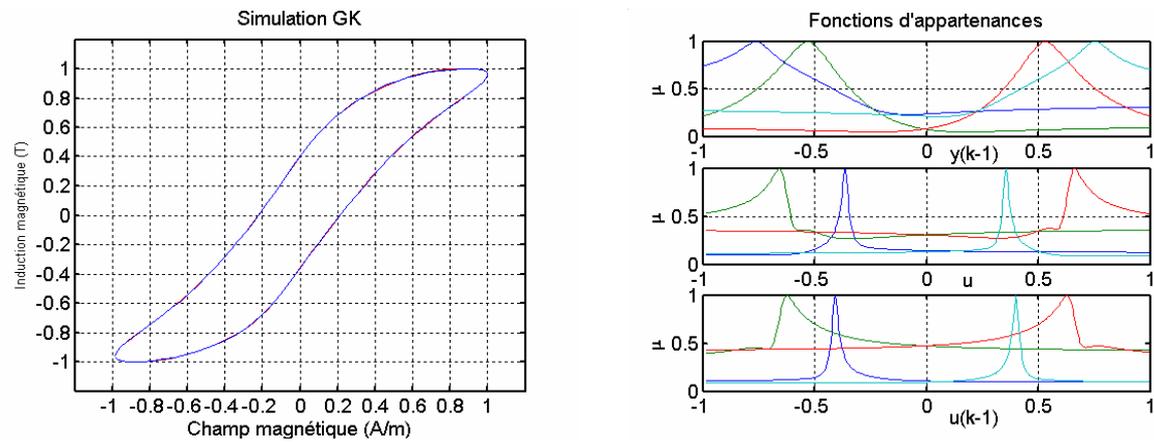


Figure 5.14 Régression GK ($n_u=2, n_y=1, c=4$)

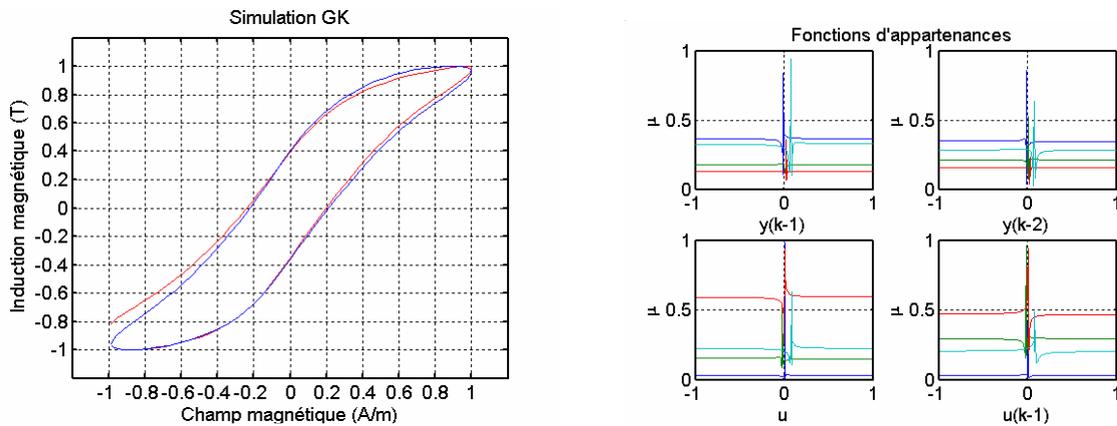


Figure 5.15 Régression GK ($n_u=2, n_y=2, c=4$)

5.4.4 Méthode de Gath et Geva (GG)

L'algorithme (**GG**) proposé par Bezdek et Dunn en 1989, est une variante de FCM qui s'inspire de l'estimation par le principe du maximum de vraisemblance (Hervé, 2004) (Gath, 1989). Afin d'adapter les FCM à des cas correspondant à des classes hyper-ellipsoïdales, à des densités différentes pour les différentes classes, ou à des distributions inégales de l'ensemble des points au sein des différentes classes, les auteurs définissent une distance basée sur le principe du maximum de vraisemblance.

Ce regroupement peut se transformer en une fonction exponentielle sur un espace de donnée variable (Abonyi, 2003).

Il peut être interprété dans le cadre probabiliste $p(\eta_i)$; exprime une fonction exponentielle de densité de probabilité conditionnelle $\sum_{i=1}^c p(\eta_i) = 1$; prenant une forme gaussienne multivariable $N(v_i, F_i)$; de moyenne (v_i) , et de matrice de covariance (F_i) telle que

$$p(z/\eta) = \sum_{i=1}^c p(z, \eta_i) = \sum_{i=1}^c p(z/\eta_i) p(\eta_i) \quad (5.19)$$

Qui peut être écrit sous forme gaussienne

$$p(z/\eta_i) = \frac{1}{(2\pi)^{\frac{n+1}{2}} \sqrt{|F_i|}} \exp\left(-\frac{1}{2}(z-v_i)(F_i)^{-1}(z-v_i)\right) \quad (5.20)$$

La densité conjointe $p(z) = p(x, y)$ du vecteur de régression X , et le vecteur de sortie Y sur $n \times n$ dimensions répartie sur c clusters, telle que

$$\begin{aligned} y &= f(x) = E[y/x] \\ &= \int yp(y/x)dy = \frac{\int yp(y, x)dy}{p(x)} \\ &= \sum_{i=1}^c \frac{[[x^T \mathbf{1}] \theta_i] p(x/\eta_i) p(\eta_i)}{p(x)} \\ &= \sum_{i=1}^c p(\eta_i/x) [[x^T \mathbf{1}] \theta_i] \end{aligned} \quad (5.21)$$

Les θ_i sont les paramètres du modèle de chaque cluster.

La probabilité conditionnelle de vecteur de régression $p(\eta_i/x)$ et donne par :

$$p(\eta_i / x) = \frac{\frac{p(\eta_i)}{(2\pi)^{n/2} \sqrt{|F_i^{xx}|}} \exp\left(-\frac{1}{2}(x - v_i^x)^T (F_i^{xx})^{-1} (x - v_i^x)\right)}{\sum_{i=1}^c \frac{p(\eta_i)}{(2\pi)^{n/2} \sqrt{|(F)_i^{xx}|}} \exp\left(-\frac{1}{2}(x - v_i^x)^T (F_i^{xx})^{-1} (x - v_i^x)\right)} \quad (5.22)$$

La matrice de covariance F_i peut s'exprimer sous la forme suivante :

$$F_i = \begin{bmatrix} F_i^{xx} & F_i^{xy} \\ F_i^{yx} & F_i^{yy} \end{bmatrix} \quad (5.23)$$

Avec

- F_i^{xx} matrice d'auto corrélation du vecteur d'entrée de dimensions
- F_i^{xy} vecteur d'inter corrélation entre l'entrée et la sortie.
- F_i^{yx} vecteur d'inter corrélation entre la sortie et l'entrée.
- F_i^{yy} matrice d'auto corrélation de la sortie.

Les fonctions d'appartenances des antécédents sont données comme suit :
Le modèle de régression sous une forme gaussienne mixte ; qui ce base sur un régime opérationnelle avec une fonction de validité décrit par $\phi_i(x) = p(\eta_i / x)$ répartie suivant une pondération sur les règles :

$$w_i = \frac{p(\eta_i)}{(2\pi)^{n/2} \sqrt{|F_i^{xx}|}} \quad (5.24)$$

Les fonctions d'appartenances gaussiennes pondérées définit par :

$$\beta_i(x) = w_i A_i(x) = w_i \exp\left(-\frac{1}{2}(x - v_j^x)^T (F_i^{xx})^{-1} (x - v_j^x)\right) \quad (5.26)$$

est transformée sous la forme suivante

$$A_{i,j}(\tilde{x}_{i,j}) = \exp\left(-\frac{1}{2} \frac{(\tilde{x}_{i,j} - \tilde{v}_{i,j})^2}{\tilde{\sigma}_{i,j}^2}\right) \quad (5.27)$$

- $\tilde{v}_{i,j} = \mathbf{t}_{i,j}^T \mathbf{v}_i^x$ la moyenne

- $\tilde{\sigma}_{i,j}^2 = \lambda_{i,j}^2$ la variance

$\lambda_{i,j}$ et t_{ij} , $j = 1, \dots, n$ Les valeurs et les vecteurs propre de la matrice d'auto corrélation F_i^{xx}

Donnant la relation générale de T.S :

$$R_i : \text{Si } \tilde{x}_{i,1} \text{ est } A_{i,1}(\tilde{x}_{i,1}) \text{ et...et } \tilde{x}_{i,n} \text{ est } A_{i,n}(\tilde{x}_{i,n}) \text{ Alors } \tilde{y} = \mathbf{a}_i^T \mathbf{x} + b_i \quad (5.28)$$

Les paramètres des conséquents peuvent être déduits par l'une des deux méthodes :

- **Moindre carrée généralisée :**

Les paramètres des conséquents des règles sont estimés en minimisant le critère suivant :

$$\min_{\theta_i} \frac{1}{N} (\mathbf{y} - \mathbf{X}_e \theta_i)^T \Phi_i (\mathbf{y} - \mathbf{X}_e \theta_i) \quad (5.29)$$

Avec

$\mathbf{X}_e = [\mathbf{X} \ 1]_i$: matrice des régresseurs prolongée par une colonne unitaire

Φ_i : matrice ayant les degrés d'appartenance sur sa diagonale principale

$$\Phi_i = \begin{bmatrix} \mu_{i,2} & 0 & \cdots & 0 \\ 0 & & \cdots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \cdots & \mu_{i,N} \end{bmatrix} \quad (5.30)$$

Donc :

$$\theta_i = (\mathbf{X}_e^T \Phi_i \mathbf{X}_e)^{-1} \mathbf{X}_e^T \Phi_i \mathbf{y} \quad (5.31)$$

Une fois les fonctions d'appartenances sont obtenues μ_{ik} sont obtenues, la matrice de covariance peut être directement employée donnant les paramètres sous la forme :

$$\begin{aligned} \mathbf{a}_i &= (\mathbf{F}^{xx})^{-1} \mathbf{F}^{xy} \\ \mathbf{b}_i &= v_i^y - \mathbf{a}_i^T \mathbf{v}_i^x \end{aligned} \quad (5.32)$$

- **Moindre carrée pondérée :**

Les clusters localement rapprochant la surface de régression, ils sont des sous espaces linéaires dimensionnelles $n+1$. Pour cela la plus petite valeur propre de la matrice de covariance F_i , correspond au vecteur propre du t_i centre.

Le vecteur de la normal A l'hyperplan engendré par les autres vecteurs propres.

$$\mathbf{t}_i^T (\mathbf{z} - \mathbf{v}_i) = 0 \quad (5.33)$$

L'observation $\mathbf{z} = [\mathbf{x}^T \mathbf{y}]^T$, est similaire au vecteur de partition $\mathbf{v}_i = \left[(\mathbf{v}_i^x)^T \ v_i^y \right]^T$
les vecteurs propre partitionne sous la forme $\mathbf{t}_i = \left[(\mathbf{t}_i^x)^T \ \mathbf{t}_i^y \right]^T$ donnant :

$$\left[(\mathbf{t}_i^x)^T \ \mathbf{t}_i^y \right] \left([\mathbf{x}^T \ \mathbf{y}] - \left[(\mathbf{v}_i^x)^T \ v_i^y \right] \right)^T = 0 \quad (5.34)$$

Où les paramètres hyperplan seront définit comme suit :

$$y = \underbrace{\frac{-1}{\mathbf{t}_i^y} (\mathbf{t}_i^x)^T \mathbf{x}}_{\mathbf{a}_i^T} + \underbrace{\frac{1}{\mathbf{t}_i^y} (\mathbf{t}_i^y)^T}_{\mathbf{b}_i} \mathbf{v}_i \quad (5.35)$$

La fonction objective de l'algorithme (GG) est décrite par :

$$J_{\text{GG}}(\mathbf{Z}, \mathbf{U}, \mathbf{V}) = \sum_{i=1}^c \sum_{j=1}^N \mu_{i,k}^m D_{i,k}^2 \quad (5.36)$$

Avec :

$$\begin{aligned} \mathbf{U} \in \mathbb{R}^{c \times N} \text{ est } \mu_{i,k} \in [0,1], \quad \forall i, k \\ \sum_{i=1}^c \mu_{i,k} = 1, \quad \forall k, \quad 0 < \sum_{k=1}^N \mu_{i,k} < N \end{aligned} \quad (5.37)$$

Les prototypes (centre) \mathbf{v}_i sous la forme :

$$\mathbf{v}_i^{(t)} = \frac{\sum_{k=1}^N \mu_{i,k}^{(t-1)} \mathbf{z}_k}{\sum_{k=1}^N \mu_{i,k}^{(t-1)}}, \quad 1 \leq i \leq c \quad (5.38)$$

Ou F_i est la matrice de covariance floue définit par l'expression :

$$\mathbf{F}_i^{(t)} = \frac{\sum_{k=1}^N \mu_{i,k}^{(t-1)} (\mathbf{z}_k - \mathbf{v}_i^{(t)}) (\mathbf{z}_k - \mathbf{v}_i^{(t)})^T}{\sum_{k=1}^N \mu_{i,k}^{(t-1)}}, \quad 1 \leq i \leq c \quad (5.39)$$

La probabilité à priori est exprimé par :

$$\alpha_i = \frac{1}{N} \sum_{k=1}^N \mu_{i,k}^{(t-1)} \quad (5.40)$$

Les distances sont mesurées par la relation suivante :

$$D_{i,k}^2(\mathbf{z}_k, \mathbf{v}_i) = \frac{(2\pi)^{\left(\frac{n+1}{2}\right)} \sqrt{\det(\mathbf{F}_i)}}{\alpha_i} \cdot \exp\left(-\frac{1}{2} (\mathbf{z}_k - \mathbf{v}_i^{(t)})^T \mathbf{F}_i^{-1} (\mathbf{z}_k - \mathbf{v}_i^{(t)}) \right) \quad (5.41)$$

L'algorithme général est reformulé comme suit :

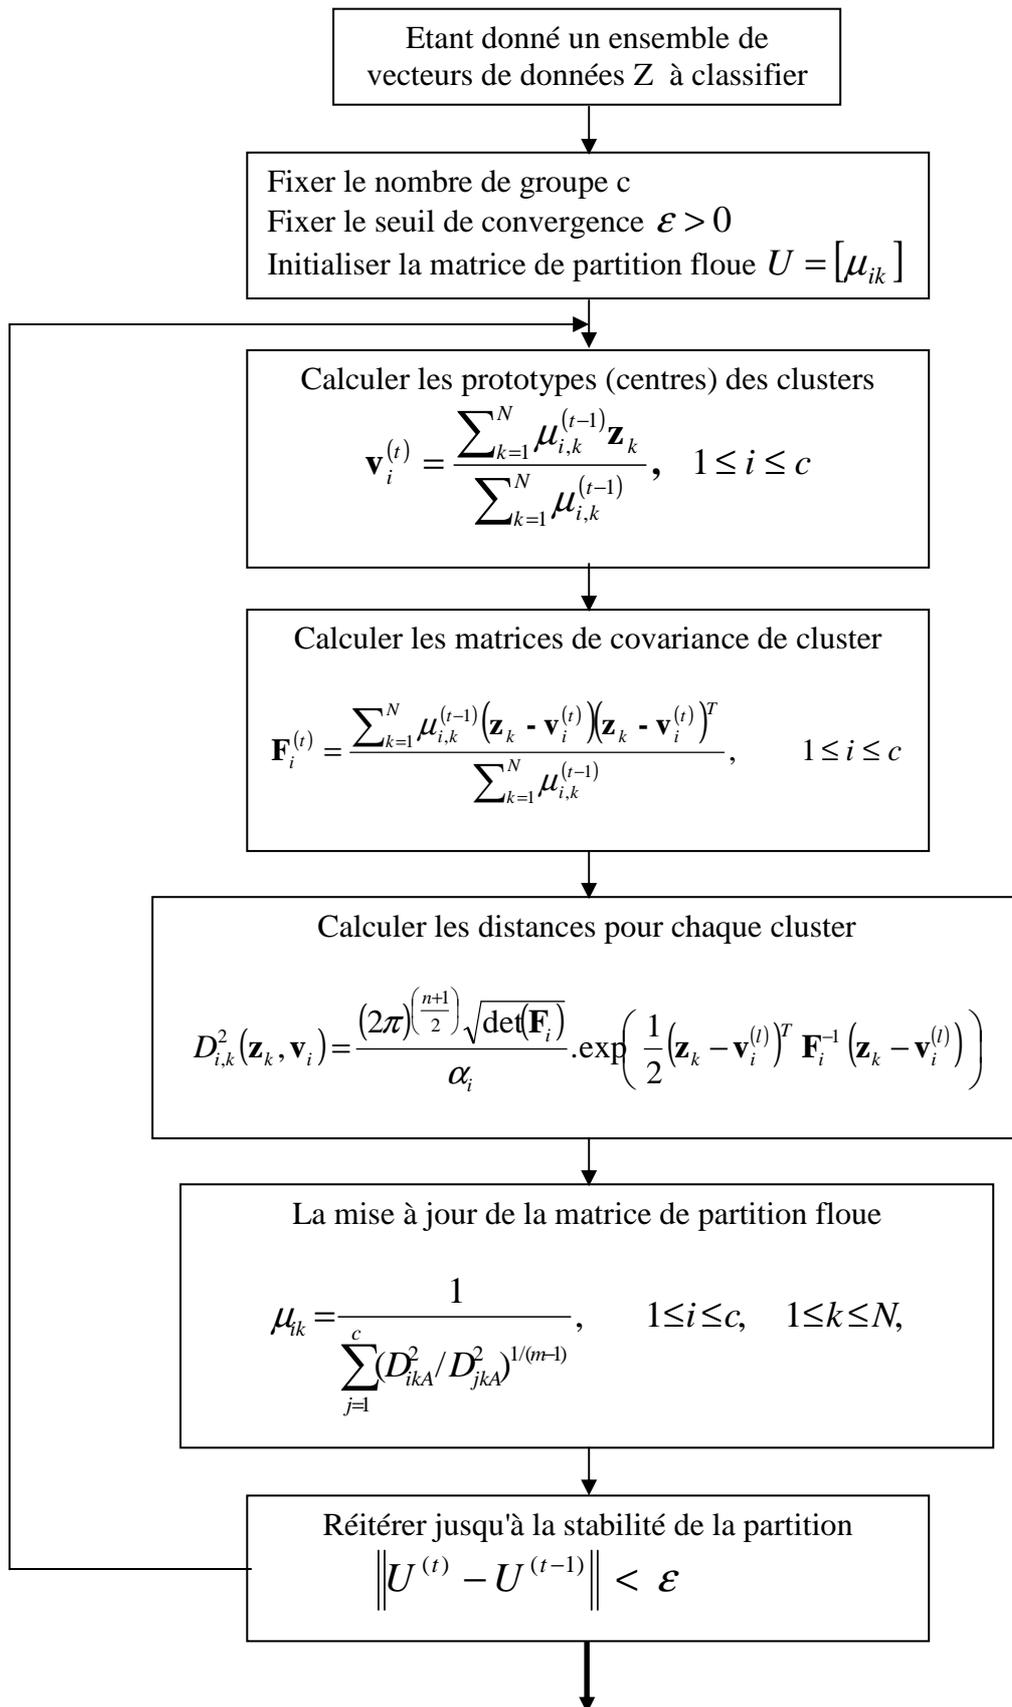


Figure 5.16 Organigramme de la méthode GG

L'utilisation de mesure exponentielle peut conduire à des problèmes d'instabilité dus aux minima locaux. L'étape d'initialisation de l'algorithme de Gath et Geva est donc notamment sensible. C'est la raison pour laquelle, on utilise généralement l'algorithme des C-moyennes floues pour une première estimation de la matrice de partition floue initiale pour l'approche de Gath et Geva

Exemple pour la visualisation de 11 clusters

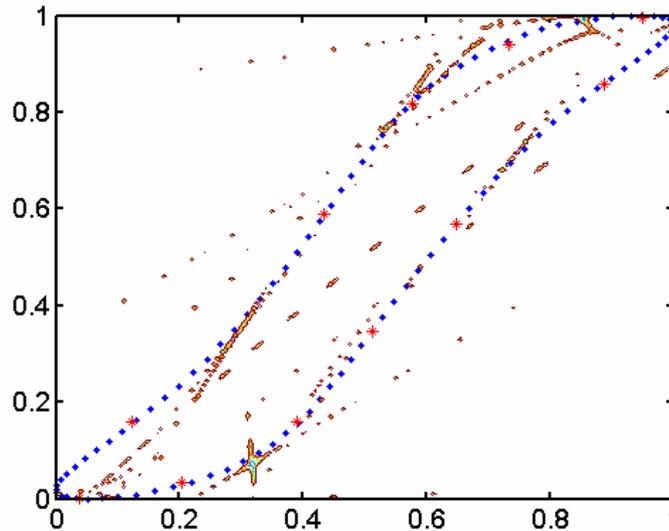


Figure 5.17 Résultats de classification par l'algorithme GG

Résultats

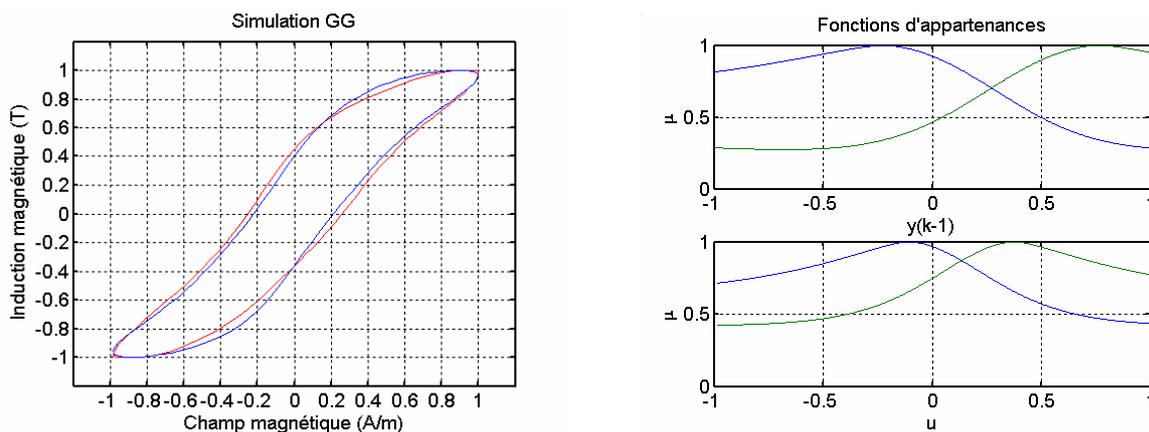


Figure 5.18 Régression GG ($n_u=1, n_y=1, c=2$)

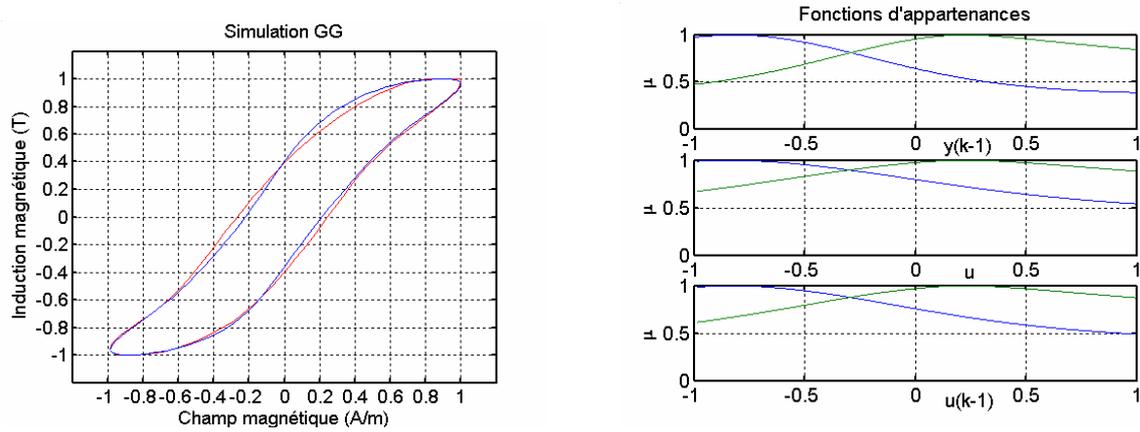


Figure 5.19 Régression GG ($n_u=2, n_y=1, c=2$)

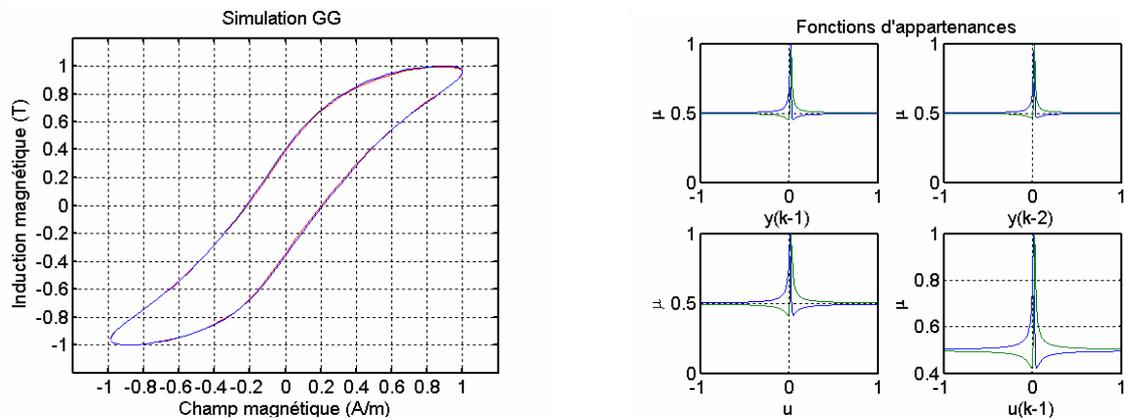


Figure 5.20 Régression GG ($n_u=2, n_y=2, c=2$)

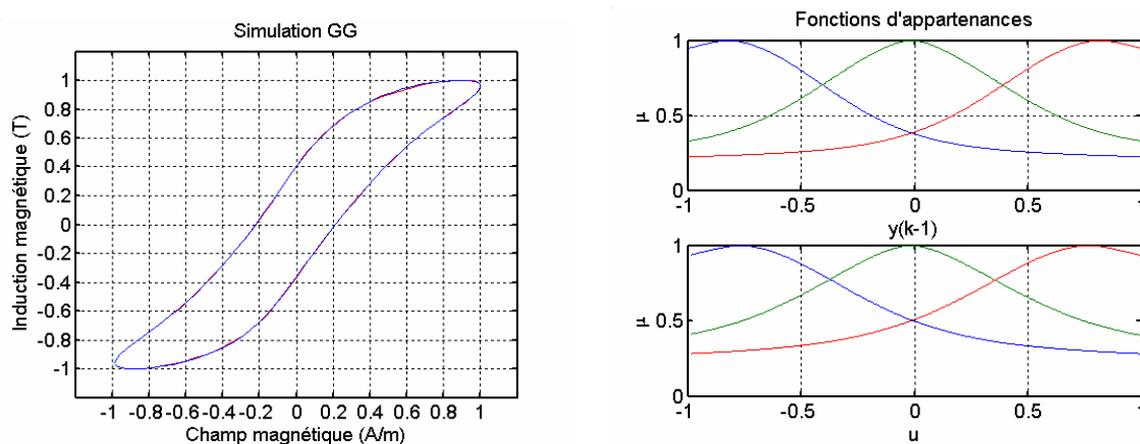


Figure 5.21 Régression GG ($n_u=1, n_y=1, c=3$)

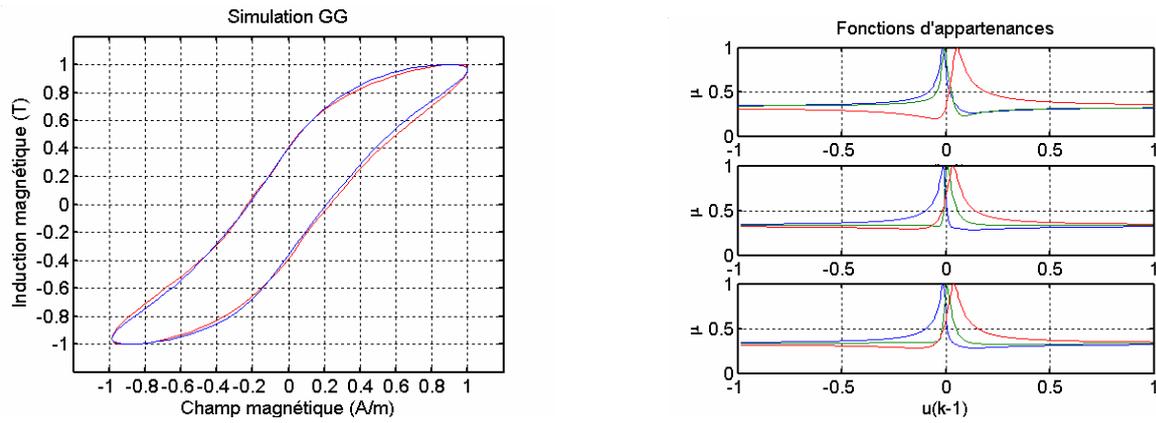


Figure 5.22 Régression GG ($n_u=2, n_y=1, c=3$)

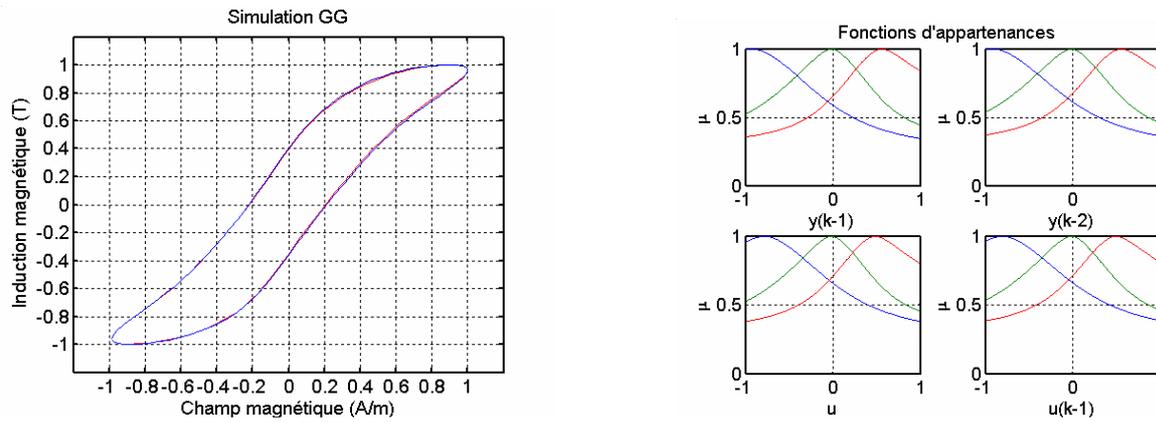


Figure 5.23 Régression GG ($n_u=2, n_y=2, c=3$)

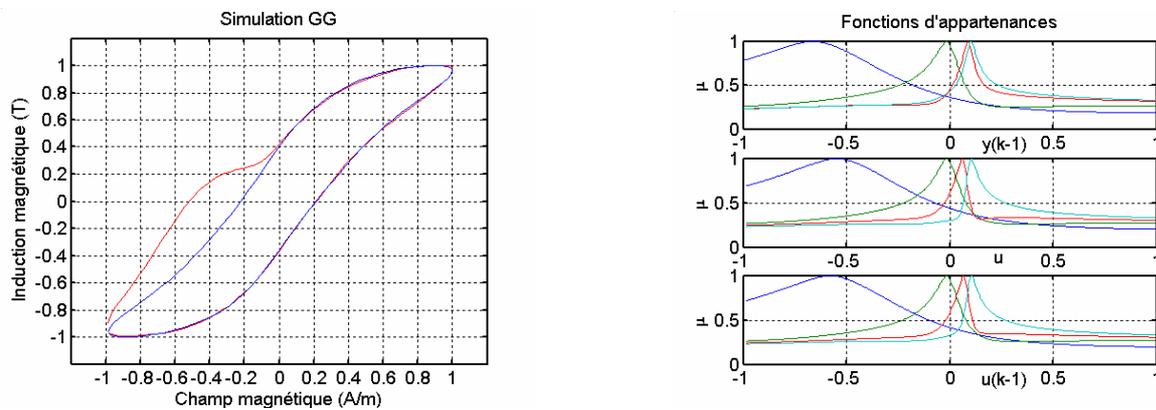
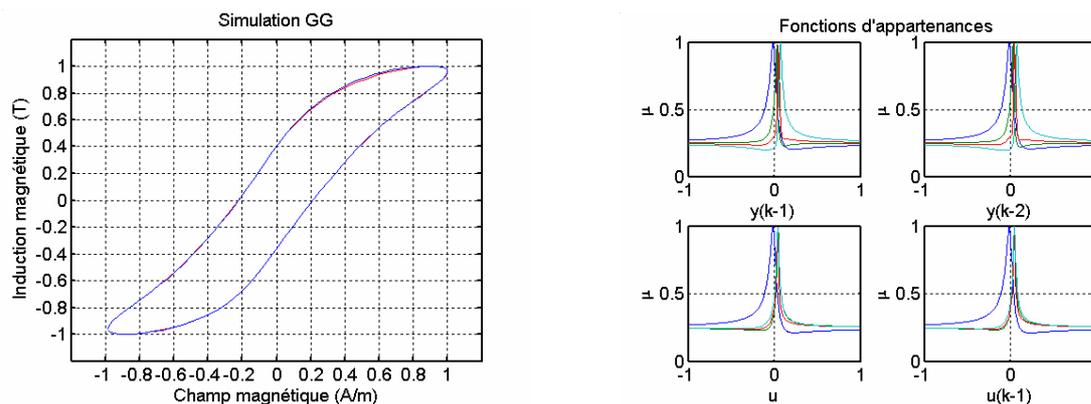


Figure 5.24 Régression GG ($n_u=2, n_y=1, c=4$)

Figure 5.25 Régression ($n_u=2$, $n_y=2$, $c=4$)

5.4.5 Méthode Expertation-Maximization

L'algorithme (**EM**) proposé par Abonyi (Abonyi, 2003) est une extension de l'algorithme (GG) ayant une matrice de covariance d'éléments diagonaux non nul ce qui engendrera une erreur dans la projection de ces éléments. Pour contourner ce problème Abonyi à proposer une nouvelle méthode classification appelée Expertation-Maximization.

Dans cette approche, les centres sont distribués sur l'ensemble Z par une fonction de probabilité conjointe

$$\begin{aligned}
 p(x, y) &= \sum_{i=1}^c p(x, y, \eta_i) = \sum_{i=1}^c p(x, y / \eta_i) p(\eta_i) \\
 &= \sum_{i=1}^c p(y / x, \eta_i) p(x / \eta_i) p(\eta_i)
 \end{aligned} \tag{5.42}$$

La fonction de distribution de l'entrée et sous forme gaussienne similaire à une fonction d'appartenance de différentes variations :

$$p(x / \eta_i) = \frac{1}{(2\pi)^{\frac{n}{2}} \sqrt{|\mathbf{F}_i^{xx}|}} \cdot \exp\left(-\frac{1}{2} (\mathbf{x} - \mathbf{v}_i^x)^T (\mathbf{F}_i^{xx})^{-1} (\mathbf{x} - \mathbf{v}_i^x)\right) \tag{5.43}$$

La distribution de sortie est :

$$p(y / \mathbf{x}, \eta_i) = \frac{1}{\sqrt{2\pi\sigma_i^2}} \cdot \exp\left(-\frac{(y - \mathbf{x}^T \theta_i)^2}{2\sigma_i^2}\right) \tag{5.44}$$

Avec σ_i l'écart type entre le modèle est le $i^{\text{ème}}$ conséquent.

La matrice \mathbf{F}^{xx} peut se réduire sous une forme diagonale qui simplifie les axes parallèles vus dans l'algorithme (GG) :

$$p(x_k / \eta_i) = \prod_{j=1}^n \frac{1}{\sqrt{2\pi\sigma_{i,j}^2}} \cdot \exp\left(-\frac{1}{2} \frac{(x_{j,k} - v_{i,j})^2}{\sigma_{i,j}^2}\right) \quad (5.45)$$

L'identification du modèle est basée sur la détermination des paramètres des clusters suivants : $p(\eta_i), \mathbf{v}_i^x, \mathbf{F}_i^{xx}, \theta_i, \sigma_i$.

A- Etape de vraisemblance

On note $\hat{\eta}$ l'estimation au sens de maximum likelihood, avec sa probabilité conditionnelle $\mathbf{L}(\eta) = p(\mathbf{z} / \eta)$, qui est basé sur la théorie de Bayes :

$$p(\eta_i / x, y) = \frac{p(x, y / \eta_i) p(\eta_i)}{p(x, y)} = \frac{p(x, y / \eta_i) p(\eta_i)}{\sum_{i=1}^c p(x, y / \eta_i) p(\eta_i)} \quad (5.46)$$

Chaque regroupement est généré par une distribution autour de son centre.

B- Etape de maximisation

L'ensemble de données est regroupé dans le but de corriger les paramètres des centres, en maximisant la densité de probabilité :

$$p(\eta_i) = \frac{1}{N} \sum_{i=1}^k p(\eta_i / x, y) \quad (5.47)$$

La moyenne et la matrice de covariance:

$$\mathbf{v}_i^x = \frac{\sum_{k=1}^N x_k p(\eta_i / x_k, y_k)}{\sum_{k=1}^N p(\eta_i / x_k, y_k)} \quad (5.48)$$

$$\mathbf{F}_i^{xx} = \frac{\sum_{k=1}^N (x_k - \mathbf{v}_i^x)(x_k - \mathbf{v}_i^x)^T p(\eta_i / x_k, y_k)}{\sum_{k=1}^N p(\eta_i / x_k, y_k)} \quad (5.49)$$

Dans le but de minimiser les paramètres du modèle linéaire, on met la dérivée de la densité de probabilité conjointe (log likelihood) égale à zéro:

$$\begin{aligned}
 0 &= \frac{\partial}{\partial \theta_i} \ln \prod_{k=1}^N p(x_k, y_k) = \sum_{k=1}^N \frac{\partial}{\partial \theta_i} \ln p(x_k, y_k) \\
 &= \frac{1}{N p(\eta_i)} \sum p(\eta_i / x, y) (y_k - f_i(x_k, \theta_i)) \frac{\partial f_i(x_k, \theta_i)}{\partial \theta_i}
 \end{aligned} \tag{5.50}$$

Où $f_i(x_k, \theta_i)$ représente les conséquents du modèle extrait par les moindres carrés pondérées tel que $f_i(x_k, \theta_i) = \mathbf{a}_i^T x_k + \mathbf{b}_i$, avec matrice de covariance :

$$\Phi_j = \begin{bmatrix} p(\eta_i / \mathbf{x}_1, y_1) & 0 & \cdots & 0 \\ 0 & p(\eta_i / \mathbf{x}_2, y_2) & \cdots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \cdots & p(\eta_i / \mathbf{x}_N, y_N) \end{bmatrix} \tag{5.51}$$

On calcule l'écart type répartie conditionnellement sur $p(y / \mathbf{x}, \eta_i)$ où :

$$\sigma_i^2 = \frac{\sum_{k=1}^N (y_k - f_i(\mathbf{x}_k, \theta_i))^T (y_k - f_i(\mathbf{x}_k, \theta_i)) p(\eta_i / \mathbf{x}_k, y_k)}{N p(\eta_i)} \tag{5.52}$$

Les prototypes (centre) \mathbf{v}_i :

$$\mathbf{v}_i^x = \frac{\sum_{k=1}^N \mu_{i,k}^{(l-1)} \mathbf{x}_k}{\sum_{k=1}^N \mu_{i,k}^{(l-1)}} \tag{5.53}$$

L'écart type des fonctions d'appartenance gaussienne :

$$\sigma_i^2 = \frac{\sum_{k=1}^N \mu_{i,k}^{(l-1)} (x_{j,k} - v_{j,k})^2}{\sum_{k=1}^N \mu_{i,k}^{(l-1)}} \tag{5.54}$$

Les paramètres du modèle local sont extraits comme suit :

$$\theta_i = (\mathbf{X}_e^T \Phi_i \mathbf{X}_e)^{-1} \mathbf{X}_e^T \Phi_i y \tag{5.55}$$

La probabilité à priori est exprimé par :

$$\alpha_i = \frac{1}{N} \sum_{k=1}^N \mu_{i,k} \tag{5.56}$$

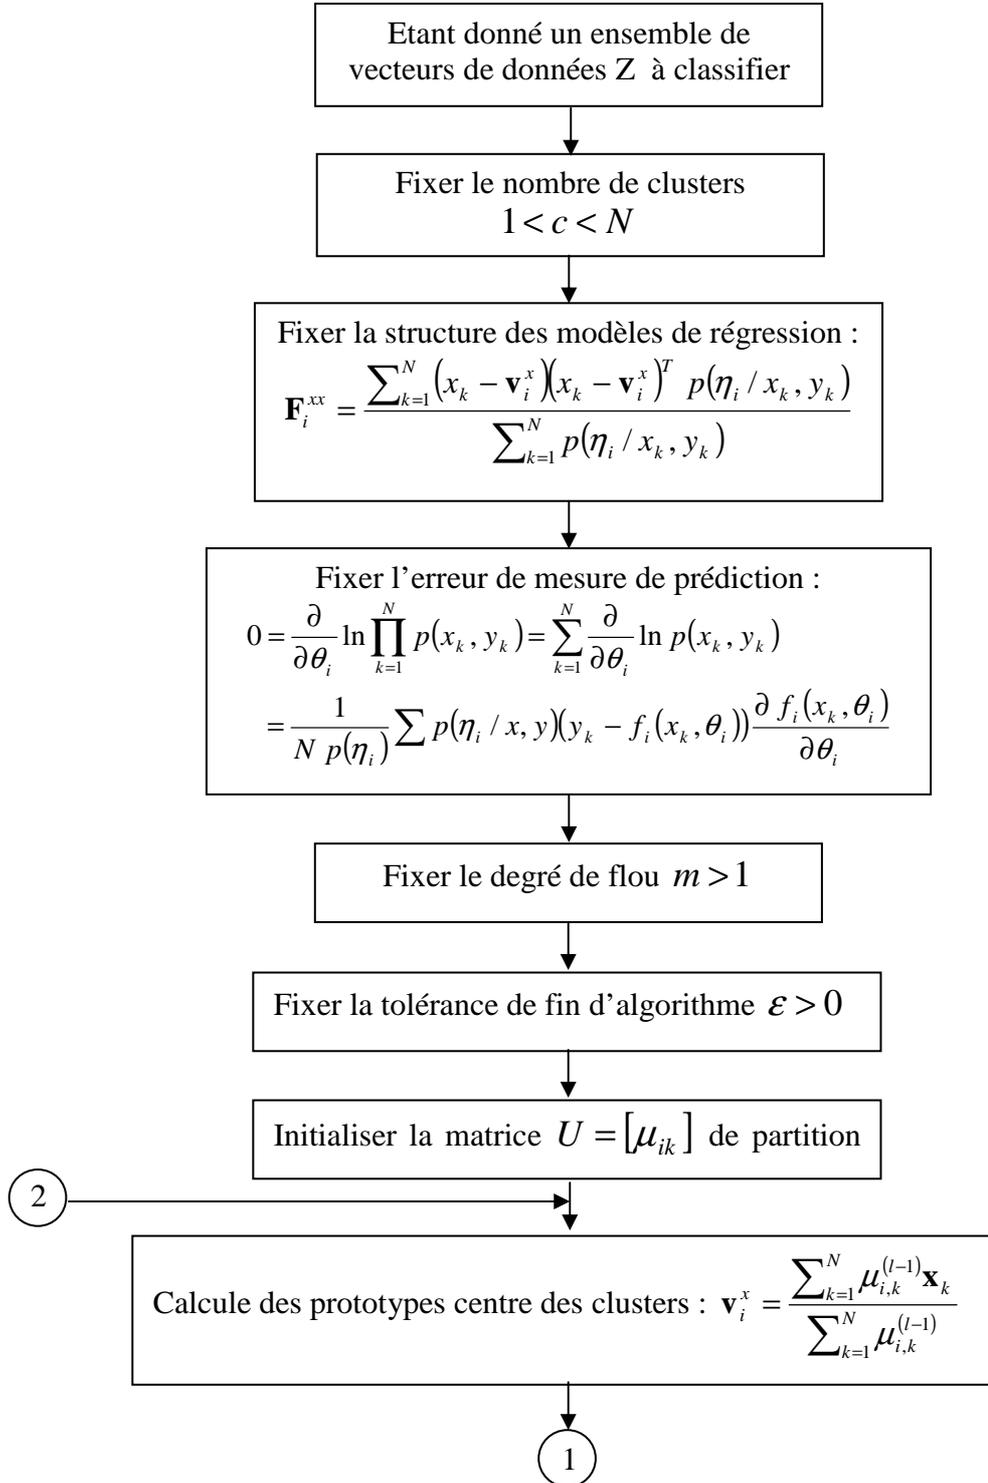
Les pondérations sur les règles sont :

$$w_i = \prod_{j=1}^n \frac{\alpha_i}{\sqrt{2\pi\sigma_{i,j}^2}} \tag{5.57}$$

Avec une distance illustrée par l'expression suivante :

$$\frac{1}{D_{i,k}^2} = \prod_{j=1}^n \frac{\alpha_j}{\sqrt{2\pi\sigma_{i,j}^2}} \cdot \exp\left(-\frac{1}{2} \frac{(x_{j,k} - v_{i,j})^2}{\sigma_{i,j}^2}\right) \cdot \frac{1}{\sqrt{2\pi\sigma_i^2}} \cdot \exp\left(-\frac{(y_k - f_i(\mathbf{x}_k, \boldsymbol{\theta}_i))^T (y_k - f_i(\mathbf{x}_k, \boldsymbol{\theta}_i))}{2\sigma_i^2}\right) \quad (5.58)$$

L'organigramme général est reformulé comme suit :



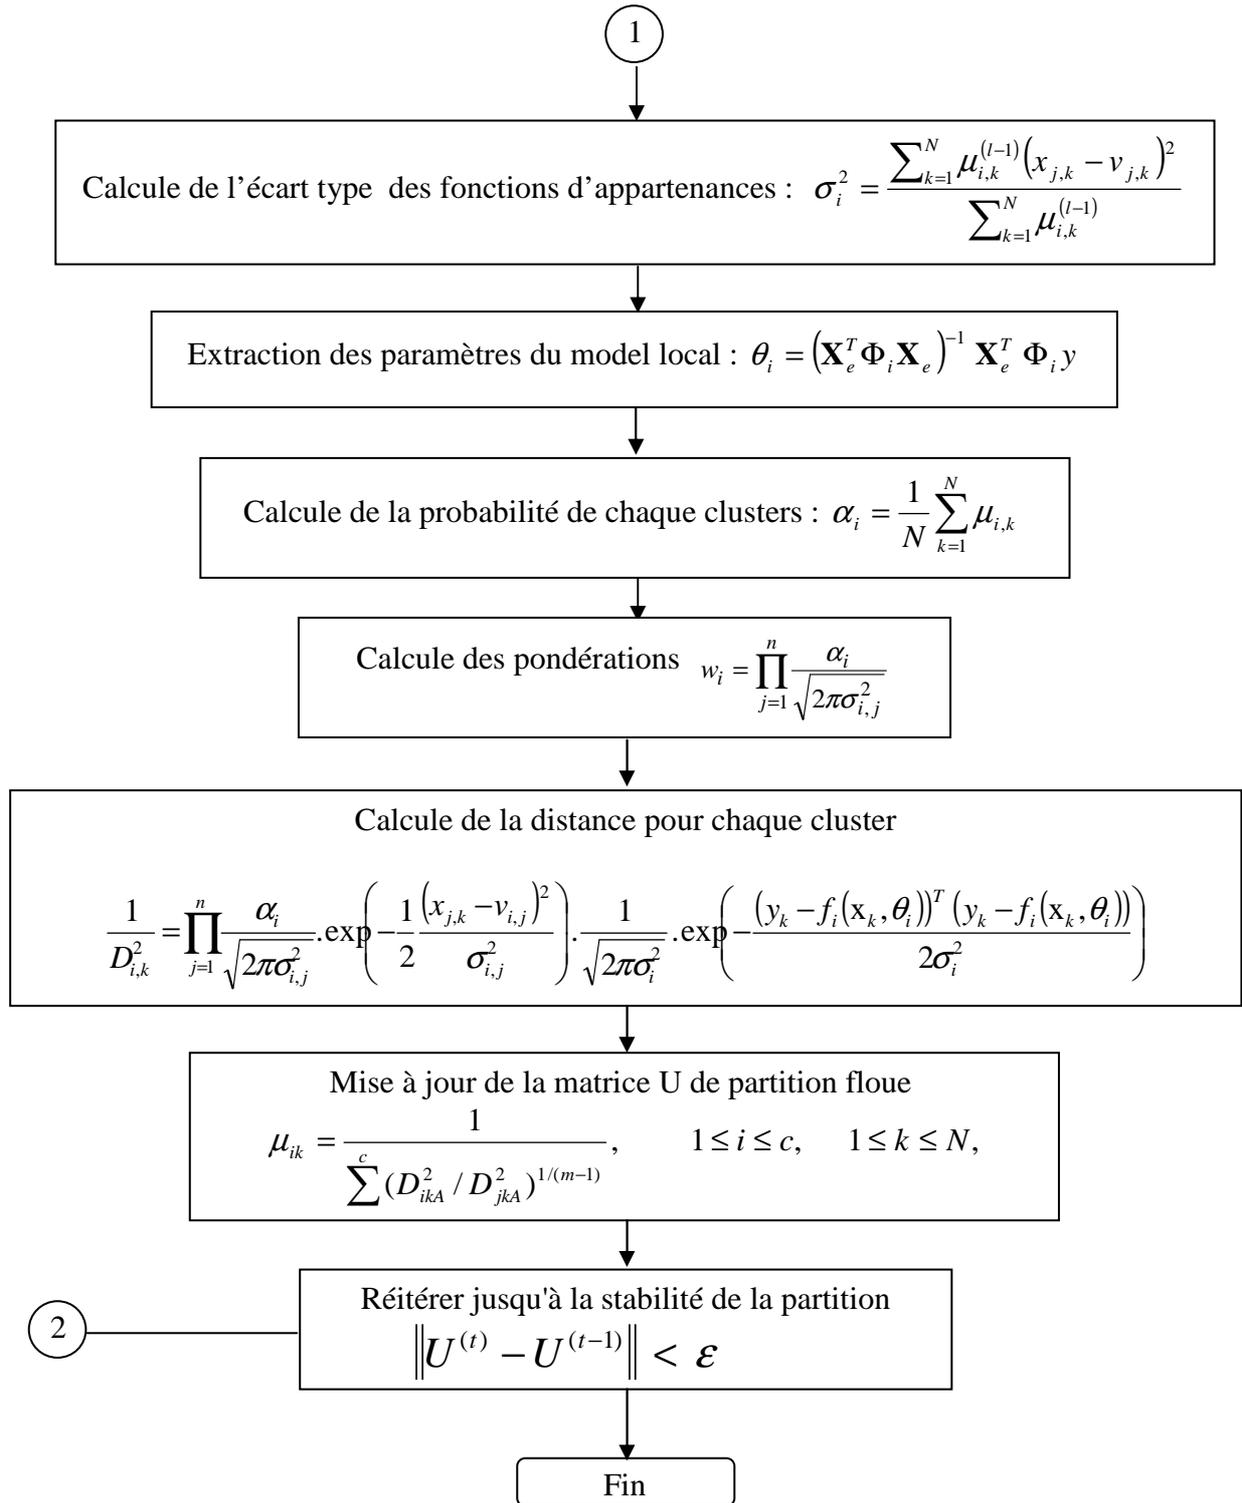


Figure 5.26 Organigramme de la méthode Expertation-Maximization

La distance inversée, implique un temps de calcul supérieur contrairement aux autres algorithmes (FCM, GK, GG).

Exemple pour visualisation à 03 clusters.

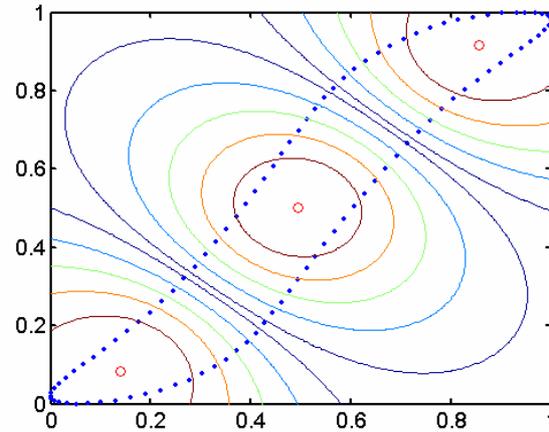


Figure 5.26.a Résultats de classification par l'algorithme EM

Résultats

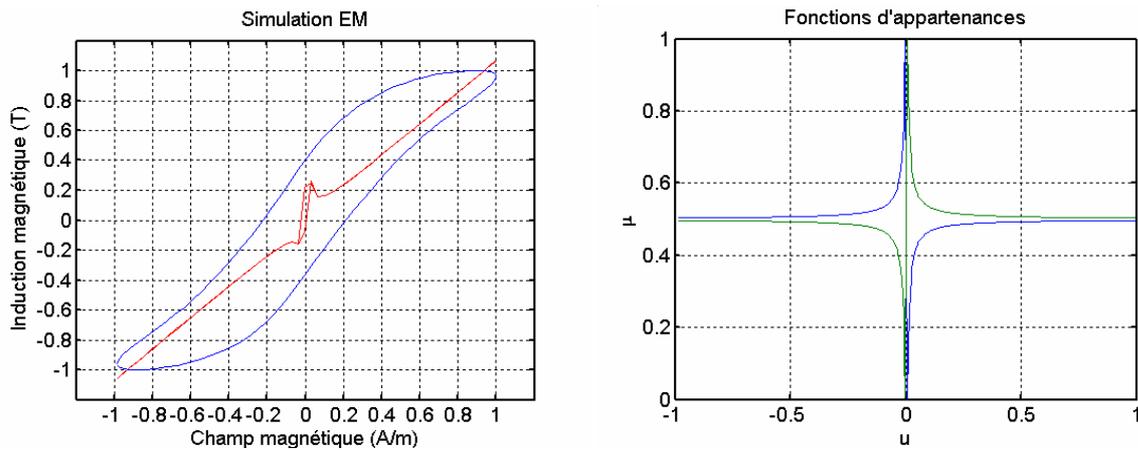


Figure 5.27 Régression EM ($n_u=1$, $n_y=0$, $c=2$)

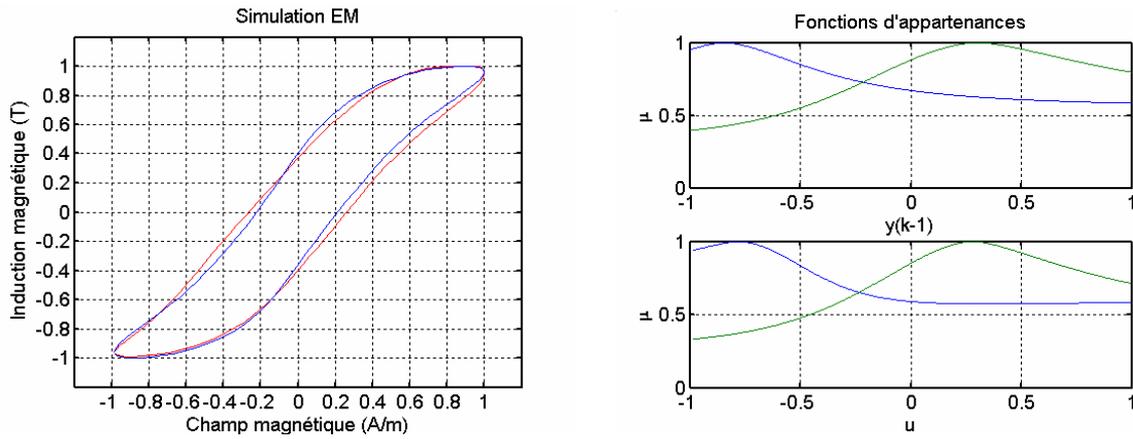


Figure 5.28 Régression EM ($n_u=1, n_y=1, c=2$)

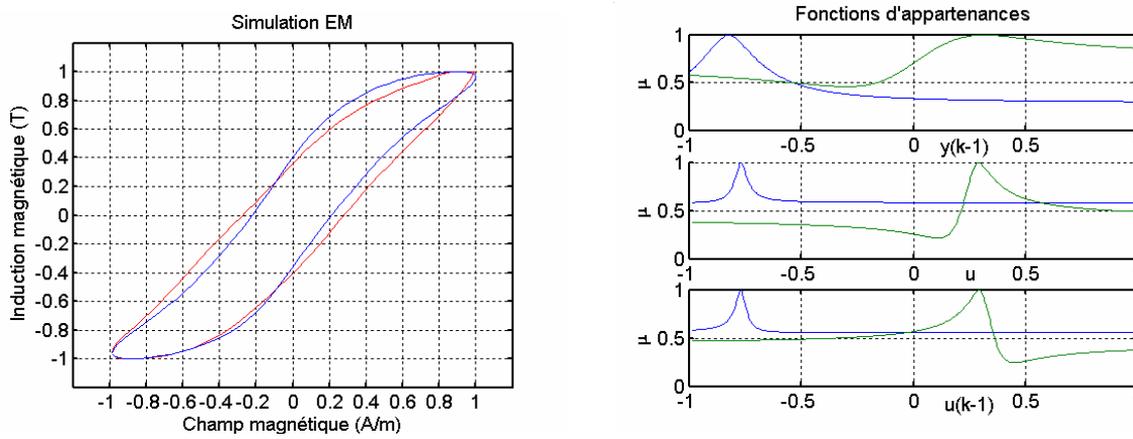


Figure 5.29 Régression EM ($n_u=2, n_y=1, c=2$)

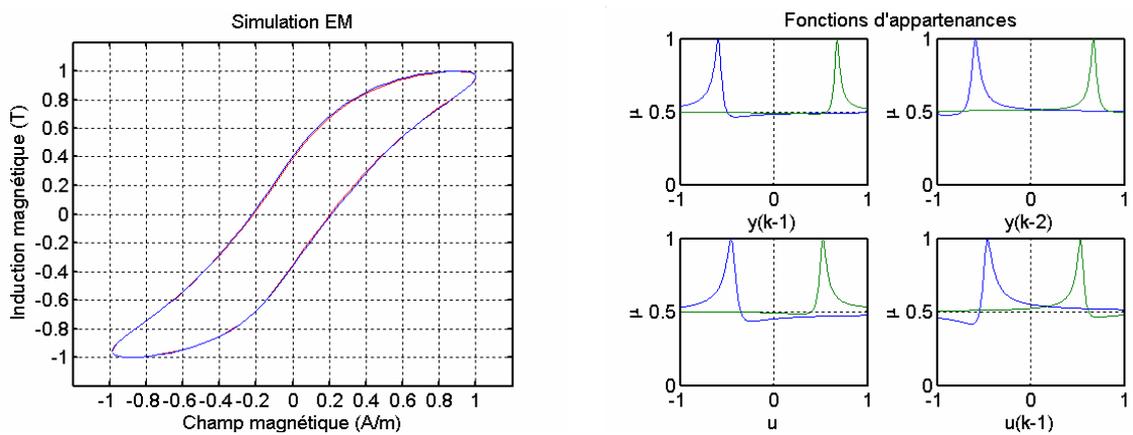


Figure 5.30 Régression EM ($n_u=2, n_y=2, c=2$)

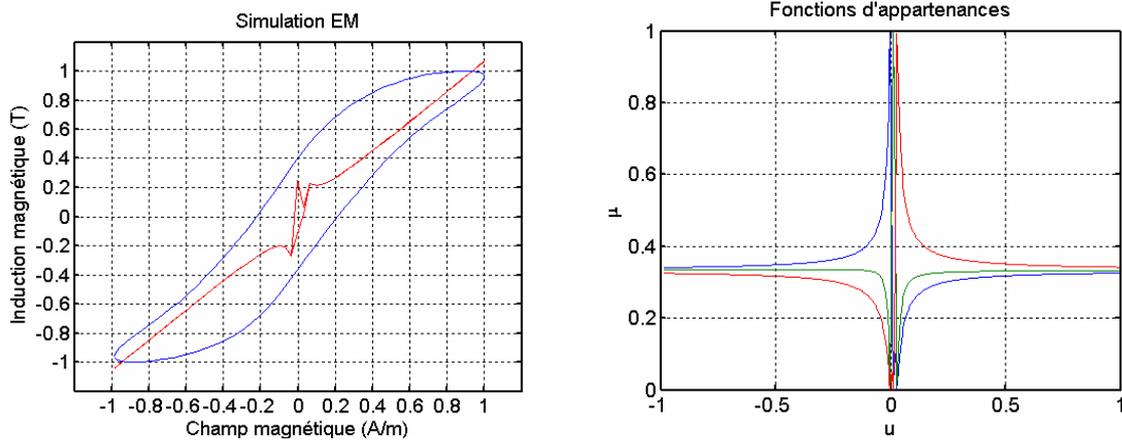


Figure 5.31 Régression EM ($n_u=1, n_y=0, c=3$)

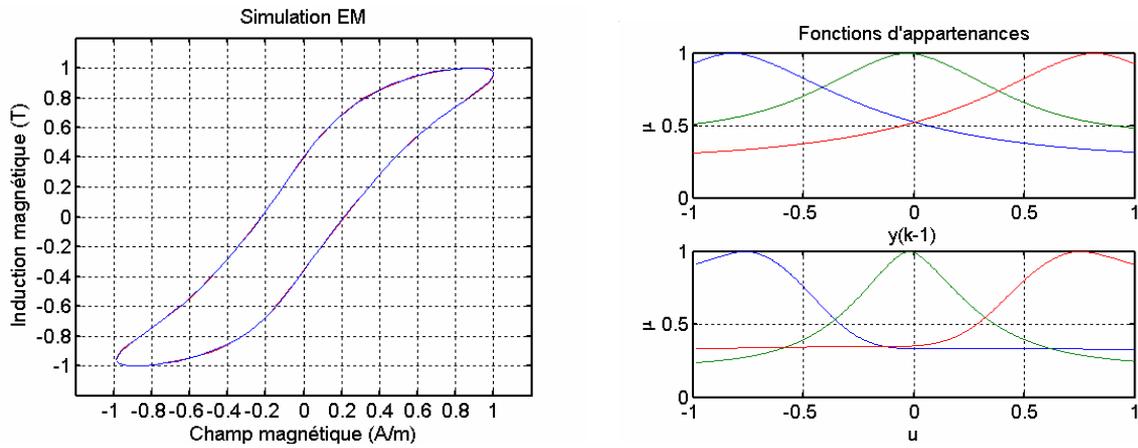


Figure 5.32 Régression EM ($n_u=1, n_y=1, c=3$)

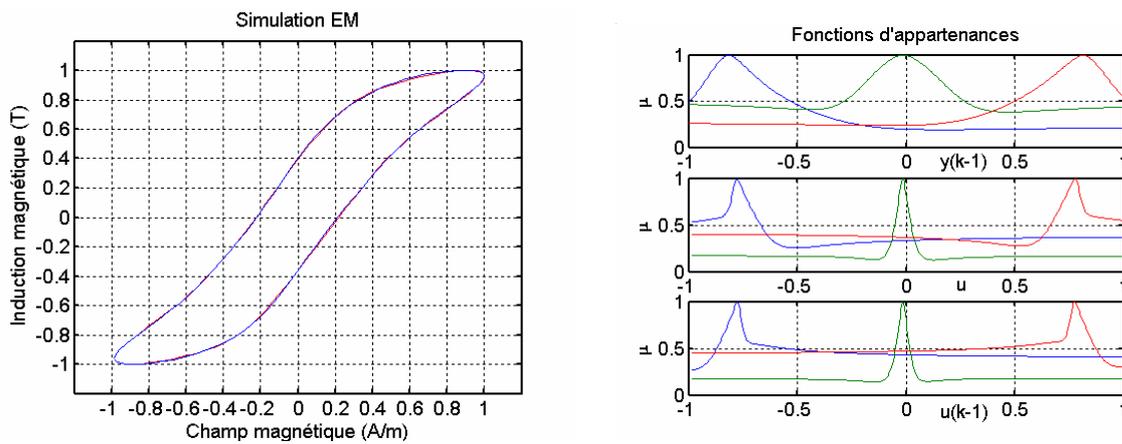


Figure 5.33 Régression EM ($n_u=2, n_y=1, c=3$)

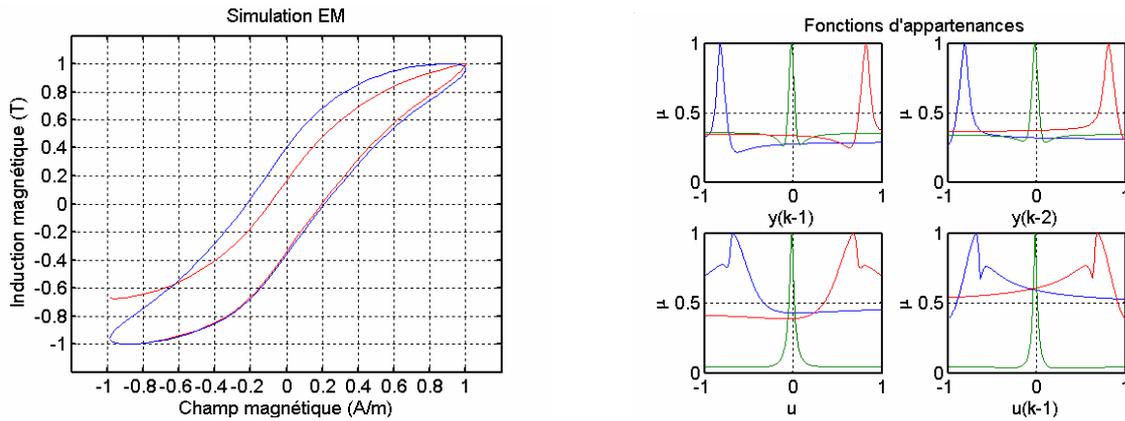


Figure 5.34 Régression EM ($n_u=2, n_y=2, c=3$)

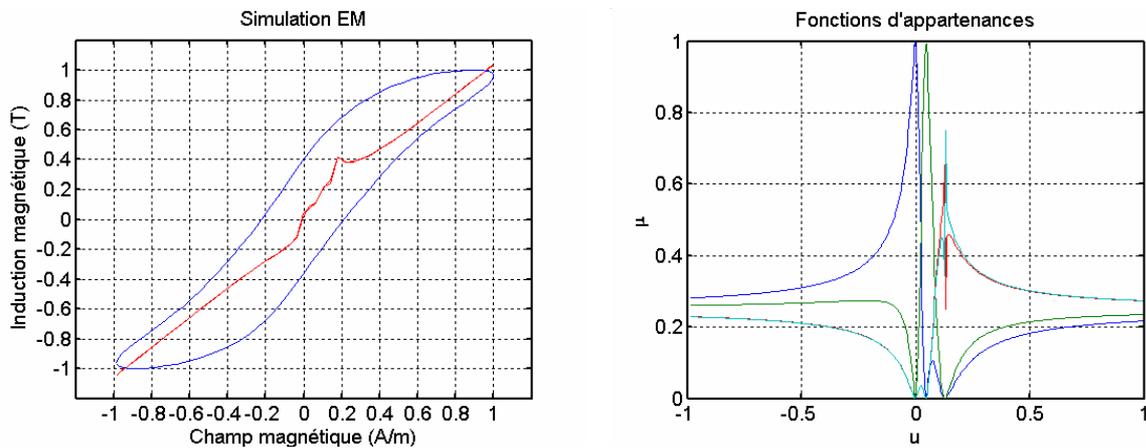


Figure 5.35 Régression EM ($n_u=1, n_y=0, c=4$)

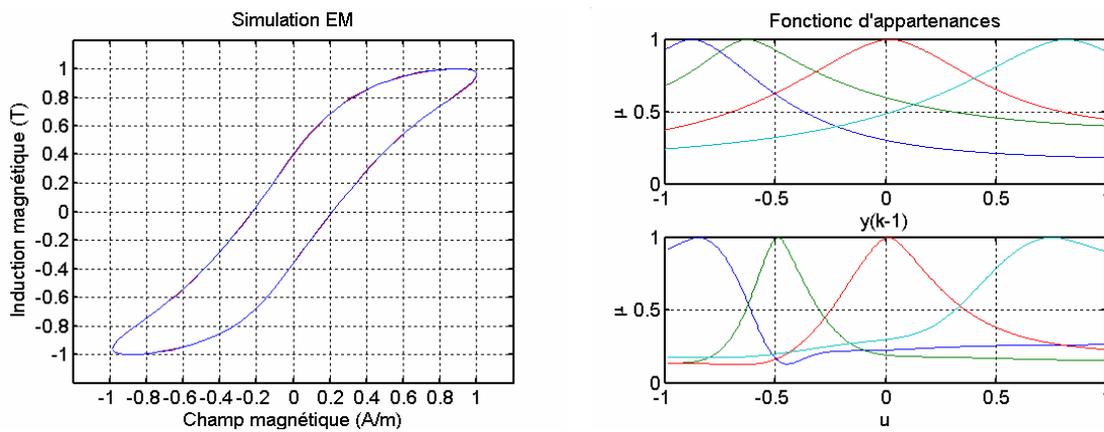


Figure 5.36 Régression EM ($n_u=1, n_y=1, c=4$)

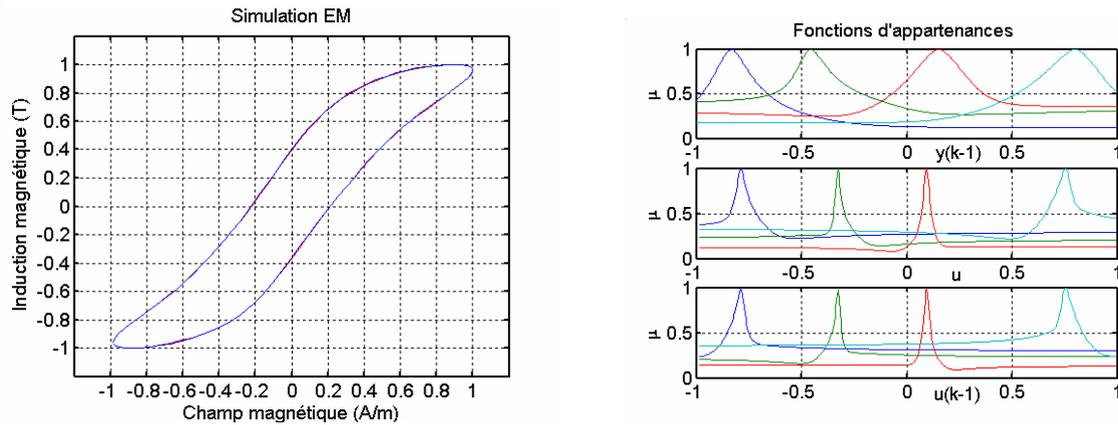


Figure 5.37 Régression EM ($n_u=2, n_y=1, c=4$)

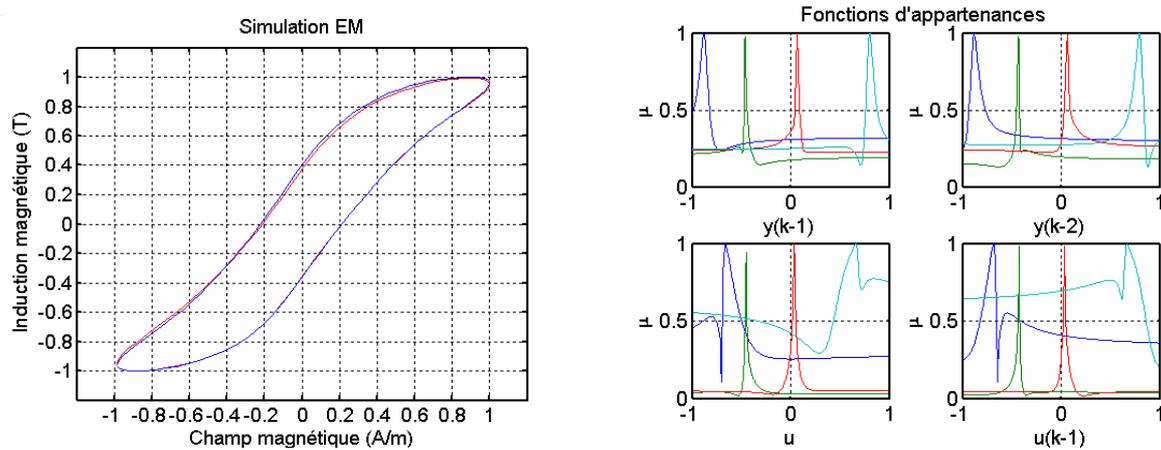


Figure 5.38 Régression EM ($n_u=2, n_y=2, c=4$)

Dans le but d'illustrer la procédure de modélisation et d'approximation floues de l'hystérésis magnétique et les résultats obtenus pour les trois approches (GK, EM et GG), nous considérons ici des cycles dynamiques obtenus par la mesure (Saghafifar et al, 2002) qui sont des fonctions fortement non linéaires.

La caractéristique non linéaire représente la relation induction magnétique en fonction du champ magnétique appliqué :

$$B=f(H) \tag{5.59}$$

Pour la modélisation floue une base de données de 4×10^1 points illustrés par la figure 5.39 à été considérée.

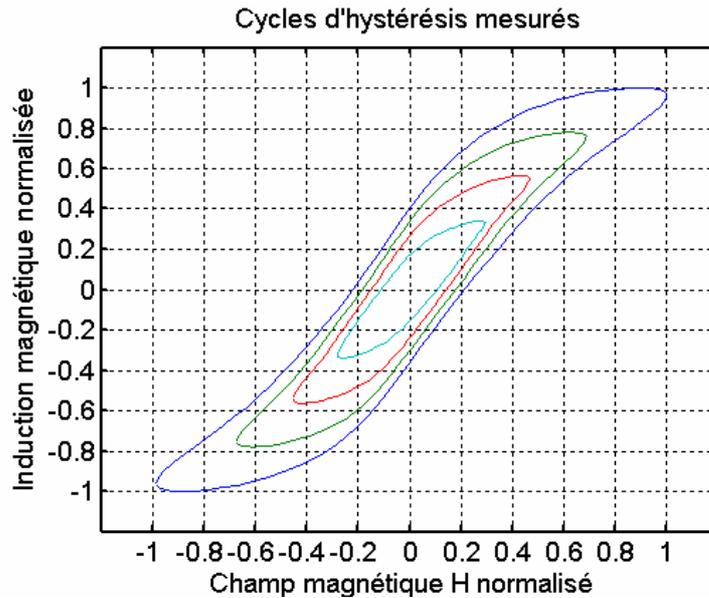


Figure 5.39 Cycles d'hystérésis mesurés

D'après la figure 5.39, nous avons considéré une approximation des cycles par utilisation de 2,3 et 4 régions différentes, ce qui correspond au nombre de clusters pour les trois approches utilisées.

5.5 Evaluation de la qualité de l'approximation et validation du modèle flou

Pour évaluer la qualité de l'approximation (performance numérique) obtenue par les modèles flous, nous utilisons les critères suivants :

RMSE, Erreur quadratique moyenne (en anglais *Root Mean Square Error*) : c'est une mesure globale sur le nombre total de points de l'écart par rapport à la valeur attendue. Sa valeur optimale est zéro; ce critère est défini par l'expression (5.60):

$$RMSE = \sqrt{\frac{1}{N} \sum_{k=1}^N (y_k - \hat{y}_k)^2} \quad (5.60)$$

où $1 \leq k \leq N$ est le nombre de points considérés pour la modélisation, y est la sortie mesurée et \hat{y} est la sortie du modèle.

VAF, Comptabilisation en pourcentage de la variance (en anglais *Variance Accounting For*) : introduit par Babuska *et al.* (Babuska, 1998), ce critère permet d'évaluer en pourcentage la qualité d'un modèle en mesurant l'écart normalisé de la variance entre deux signaux. Sa valeur optimale est 100% quand les deux signaux sont égaux, s'ils sont différents, le VAF est inférieur. Le critère VAF est donné par l'expression (5.61):

$$VAF = 100\% \left[1 - \frac{\text{var}(y - \hat{y})}{\text{var}(y)} \right] \quad (5.61)$$

Tcal, Temps de calcul : correspond au temps machine requis pour les calculs de construction du modèle flou à partir des données.

Le tableau ci-dessous illustre les performances (Qualité du modèle VAF, RMSE et temps de calcul) issues des différentes étapes d'identifications par les trois approches (GK, EM et GG) obtenue pour chaque cas [régression, nombres de clusters] et par utilisation des toolbox développés par Babuska (Babuska, 2002), (Babuska, 1995) et Balasko (Balasko et al) et d'un micro-ordinateur Pentium 4, 2.06 GHz avec 256 Mo de RAM et un système d'exploitation Windows 2000 Professionnel.

n_u	n_y	GK			EM			GG			
		$c=2$	$c=3$	$c=4$	$c=2$	$c=3$	$c=4$	$c=2$	$c=3$	$c=4$	
1	0	VAF	87.1820	87.1556	87.1956	86.444	86.5605	86.5195	x	x	x
		RMSE	0.2557	0.2560	0.2556	0.263	0.2618	0.2622	x	x	x
		Tcal (s)	0.1100	0.1410	0.1560	0.1410	0.1720	0.187	x	x	x
1	1	VAF	99.2979	99.9958	99.9494	99.7023	99.9982	99.999	98.8875	99.9426	x
		RMSE	0.0406	0.0047	0.017	0.0403	0.0031	0.0023	0.0753	0.0171	x
		Tcal (s)	0.0940	0.1880	0.172	0.4530	0.359	0.4690	0.1720	0.1720	x
2	1	VAF	99.8781	99.9829	62.6359	99.3087	99.9947	99.9971	99.1191	99.9963	99.9979
		RMSE	0.0250	0.0127	0.602	0.0603	0.0052	0.0039	0.0671	0.0044	0.0033
		Tcal (s)	0.125	0.1410	0.1870	0.313	0.5320	0.578	0.125	0.1560	0.187
2	2	VAF	99.9978	99.9975	99.7737	99.9899	99.7137	99.8517	99.9885	99.9969	99.9987
		RMSE	0.0034	0.0059	0.0355	0.0072	0.0382	0.029	0.0077	0.0040	0.0026
		Tcal (s)	0.1720	0.1410	0.1570	0.2650	0.282	0.4530	0.172	0.1870	0.265

Tableau 5.1 Résultats d'apprentissage en fonction de la régression et du nombre de clusters.

Les résultats obtenus pour l'identification et l'apprentissage flou en utilisant les trois algorithmes déjà mentionnés sont résumés ci-dessous. Nous présentons l'approximation résultante, les fonctions d'appartenances correspondantes, ainsi que les bases des règles obtenues pour chacun des modèles (Tableau 5.1), le meilleur modèle suivant les critères VAF et RMSE et du temps de calcul. Par la suite nous

utilisons le modèle approprié pour la génération des autres cycles dans un but de la validation.

D'après le tableau 5.1 on peut observer que pour l'algorithme GK 02 clusters avec 02 entrées et 02 sorties (Figure 5.7) donne la meilleure approximation par contre avec l'approche EM la meilleur identification est obtenue pour un nombre de clusters égale à 4 avec une entrée et une sortie du modèle flou (Figure 5.36). La technique GG donne de bons résultats avec un nombre de cluster égale à 4 pour 02 entrées et 02 sorties du modèle (Figure 5.25). Notons que la méthode GG présente la meilleure approximation du point de vue VAF, RMSE et temps de calcul.

Le tableau 5.2 suivant présente les différentes règles des modèles flous générés par les trois algorithmes.

Règles du modèle flou pour l'algorithme GK $c=2, N_u=02$ et $N_y=02$

Clusters	Antécédent	Conséquent
1	Si $y(k-1)$ est A_{11} et $y(k-2)$ est A_{12} et $u(k)$ est A_{13} et $u(k-i)$ est A_{14}	$y(k)=2.y(k-1)-1.01.y(k-2)+2.26.10^{-2}.u(k)-2.45.10^{-2}.u(k-1)+1.98.10^{-5}$
2	Si $y(k-1)$ est A_{21} et $y(k-2)$ est A_{22} et $u(k)$ est A_{23} et $u(k-i)$ est A_{24}	$y(k)=1.92.y(k-1)-9.12.y(k-2)+6.7.10^{-2}.u(k)-7.91.10^{-2}.u(k-1)+6.28.10^{-5}$

Règles du modèle flou pour l'algorithme EM $c=4, N_u=01$ et $N_y=01$

1	Si $y(k-1)$ est A_{11} et $u(k)$ est A_{12}	$y(k) = 8.44.10^{-1}.y(k-1)+8.20.10^{-2}.u(k)-8.39.10^{-2}$
2	Si $y(k-1)$ est A_{21} et $u(k)$ est A_{22}	$y(k) = 8.56.10^{-1}.y(k-1)+2.98.10^{-1}.u(k)-6.65.10^{-4}$
3	Si $y(k-1)$ est A_{31} et $u(k)$ est A_{32}	$y(k) = 8.52.10^{-1}.y(k-1)+1.47.10^{-1}.u(k)+3.95.10^{-2}$
4	Si $y(k-1)$ est A_{41} et $u(k)$ est A_{42}	$y(k) = 8.41.10^{-1}.y(k-1)+8.04.10^{-2}.u(k)+8.73.10^{-2}$

Règles du modèle flou pour l'algorithme GG $c=4, N_u=02$ et $N_y=02$

1	Si $y(k-1)$ est A_{11} et $y(k-2)$ est A_{12} et $u(k)$ est A_{13} et $u(k-1)$ est A_{14}	$y(k) = 1.7y(k-1)-7.33.10^{-1}y(k-2)+4.75.10^{-2}u(k)-2.57.10^{-2}u(k-1)-1.60.10^{-2}$
2	Si $y(k-1)$ est A_{21} et $y(k-2)$ est A_{22} et $u(k)$ est A_{23} et $u(k-1)$ est A_{24}	$y(k) = 1.95y(k-1)-9.54.10^{-1}y(k-2)+7.64.10^{-2}u(k)-7.02.10^{-2}u(k-1)+2.48.10^{-4}$
3	Si $y(k-1)$ est A_{31} et $y(k-2)$ est A_{32} et $u(k)$ est A_{33} et $u(k-1)$ est A_{34}	$y(k) = 1.58 y(k-1)-6.21.10^{-1}y(k-2)+9.38.10^{-2}u(k)-5.73.10^{-2}u(k-1)+1.28.10^{-2}$
4	Si $y(k-1)$ est A_{41} et $y(k-2)$ est A_{42} et $u(k)$ est A_{43} et $u(k-1)$ est A_{44}	$y(k) = 2.21 y(k-1)-1.2.10^{-1}y(k-2)-8.55.10^{-2}u(k)+5.69.10^{-2}u(k-1)+1.01.10^{-3}$

Tableau 5.2 : Règles des 03 modèles flous

Les tableaux suivant présentent les centres des antécédents des trois modèles flous de l'hystérésis magnétique.

Centres des antécédents du modèle GK

$v_{y(k-1)}$	$v_{y(k-2)}$	$v_{u(k)}$	$v_{u(k-1)}$
$5.49.10^{-3}$	$5.89.10^{-3}$	$-1.76.10^{-3}$	$-1.28.10^{-3}$
$4.52.10^{-2}$	$4.44.10^{-2}$	5.10^{-2}	5.10^{-3}

Centres des antécédents du modèle EM

$v_{y(k-1)}$	$v_{u(k)}$
$-8.03.10^{-1}$	$-7.41.10^{-1}$
$-7.55.10^{-2}$	$-5.45.10^{-2}$
$5.89.10^{-1}$	$4.35.10^{-1}$
$8.75.10^{-1}$	$8.47.10^{-1}$

Centres des antécédents du modèle GG

$v_{y(k-1)}$	$v_{y(k-2)}$	$v_{u(k)}$	$v_{u(k-1)}$
$-8.26.10^{-1}$	$-8.15.10^{-1}$	$-6.88.10^{-1}$	$-6.97.10^{-1}$
$-5.35.10^{-2}$	$-5.6.10^{-2}$	$-2.36.10^{-2}$	$-2.6.10^{-2}$
$8.08.10^{-1}$	$7.91.10^{-1}$	$6.99.10^{-1}$	$7.04.10^{-1}$
$8.36.10^{-1}$	$8.49.10^{-1}$	$5.79.10^{-1}$	$6.06.10^{-1}$

Tableau 5.3 : Centres des antécédents des trois modèles

La structure des régresseurs dans les cas GK et GG est défini par :

$$[y_i(k-1) \quad y_i(k-2) \quad u_i(k) \quad u_i(k-1)], \quad \text{avec } n_y = 2; n_u = 2. \text{ Pour } i=1 \text{ et } 2$$

Alors que dans le cas EM, elle est sous la forme :

$$[y_i(k-1) \quad u_i(k)], \quad \text{avec } n_y = 1; n_u = 1 \text{ pour } i=1, 2, 3 \text{ et } 4$$

La structure générale à identifiée est donnée par l'équation suivante :

- **Cas GK et GG**

Si $y(k-1)$ est A_{11} et $y(k-2)$ est A_{12} et $u(k)$ est A_{13} et $u(k-i)$ est A_{14}

Alors :

$$y_i(k) = \begin{bmatrix} a_i \\ a_{i+1} \\ b_i \\ b_{i+1} \end{bmatrix} [y_i(k-1) \quad y_i(k-2) \quad u_i(k) \quad u_i(k-1)]$$

- **Cas EM**

Si $y(k-1)$ est A_{11} et $u(k)$ est A_{12}

Alors :

$$y_i(k) = \begin{bmatrix} a_i \\ b_i \end{bmatrix} [y_i(k-1) \quad u_i(k)]$$

Les coefficients a_i et b_i sont définis dans le tableau 5.2.

Afin d'argumenter le nombre de clusters $c=2$ choisi qualitativement par l'observation des deux critères [VAF, RMSE] dans les cas GG et GK et $c=4$ dans le cas EM, on va procéder à l'utilisation des critères de validation proposés par Bezdek (Bezdek, 1981), (Bezdek, 1980).

5.6 Critères de validation du nombre de clusters

Lorsqu'on est confronté à un problème de classification d'un ensemble de données, on est amené à faire une sélection optimale de classes présentes dans l'ensemble des données. Dans ce cas, l'utilisateur doit appliquer un algorithme de classification non supervisée avec les différentes valeurs de c qu'il estime plausible et de choisir la partition optimale correspondant à son problème. Cependant, le temps de calcul devient très lourd à cause de la répétition du processus de classification. A cet effet, nous serons obligés de définir un critère, ou une fonction de validité, mesurant la performance du clustering pour choisir la partition optimale parmi toutes celles obtenues avec les différentes valeurs plausible, et testées, du nombre de clusters recherché.

L'étude de la validité d'une répartition présente deux aspects :

- d'une part, il s'agit d'étudier l'existence ou non d'une structure quelconque au sein des données, c'est-à-dire, voir si les données sont distribuées d'une façon aléatoire ou pouvant être regroupées dans des groupes bien définis,

- il faudrait, d'autre part, étudier si les classes identifiées sont bien réelles, en ce sens qu'elles doivent être liées aux propriétés intrinsèques des données, et non pas être juste un artefact de calcul ou un pur produit de l'algorithme utilisé.

Les fonctions de validité s'attaquent au premier problème. Quant au deuxième aspect, c'est l'utilisateur qui, par le choix de l'algorithme qu'il utilise, suppose ce que sont les propriétés des classes qu'il recherche. Une fonction de validité ne peut pas décider si un algorithme donné est bien adapté aux données analysées. Elle ne fait que refléter à quel degré la partition obtenue avec cet algorithme obéisse aux critères inhérents à ce dernier.

Nous présentons par la suite quelques mesures de validité des clusters couramment utilisés. Chaque critère est supposé atteindre sa valeur optimale lorsque la valeur de c correspond au nombre de clusters réels. Cependant, la recherche d'une partition optimale n'est pas du tout une tâche simple parce que, bien que disposant du meilleur critère possible, il reste un bon nombre de partitions envisageables pour le même jeu de données.

5.6.1 Hypervolume flou (CHF) (Gate and Geva, 1989)

C'est un critère proposé par Gath et Geva basé sur la densité totale de la partition. Il est associé aux matrices F_i de covariance floue des clusters. Pour une classe donnée, ce critère est défini par la somme des degrés d'appartenances des éléments qui lui sont centraux, à l'hypervolume de cette classe, qui n'est autre que la racine carré du déterminant de sa matrice de covariance.

$$C_{HF}(c) = \sum_{i=1}^c [\det(F_i)]^{1/2} \quad (5.62)$$

La partition optimale est donc celle correspondant à une densité maximale et un hypervolume total minimal.

5.6.2 Coefficient de partition (PC)

Proposé par Bezdek (Bezdek, 1981), il mesure la quantité de "chevauchement" (*overlapping*) entre clusters. Le principal inconvénient du critère PC est le manque de rapport direct avec certaines propriétés des données. Théoriquement, la classification est d'autant plus satisfaisante que ce critère est élevé, et donc, plus proche de 1, il est défini comme :

$$PC(c) = \frac{1}{N} \sum_{i=1}^c \sum_{k=1}^N (\mu_{ik})^2 \quad (5.63)$$

5.6.3 Entropie de classification (CE)

Elle est similaire au coefficient de partition précédent dans le sens que cette mesure est associée au degré de "flou" (*fuzzyness*) de la partition. Le critère est donné par l'expression suivante :

$$CE(c) = -\frac{1}{N} \sum_{i=1}^c \sum_{k=1}^N \mu_{ik} \log(\mu_{ik}) \quad (5.64)$$

Le nombre de cluster optimal correspond à un *CE* minimal.

5.6.4 Index de partition (SC)

Ce critère tient compte du rapport de la compacité et la séparation des clusters. Il correspond à la somme des mesures de validité individuelles, normalisées par la division de la cardinalité floue \sum_i de chaque cluster, selon l'expression donnée par (Bensaid et al, 1996).

$$SC(c) = \sum_{i=1}^c \frac{\sum_{k=1}^N (\mu_{ik})^m \|X_k - v_i\|^2}{\sum_i \sum_{j=1}^c \|v_j - v_i\|^2} \quad (5.65)$$

Ce critère est utile aussi pour la comparaison de différentes partitions avec le même nombre de clusters. Une valeur basse du critère *CIP* indique une meilleure partition.

5.6.5 Index de séparation (S)

A l'inverse du critère précédent, cet index utilise une séparation de distance minimale pour la validation de la partition (Bensaid et al, 1996). Le critère *S* est donné par :

$$S(c) = \frac{\sum_{i=1}^c \sum_{k=1}^N (\mu_{ik})^2 \|x_k - v_i\|^2}{N \cdot \min_{i,j} \|v_j - v_i\|^2} \quad (5.66)$$

5.6.6 Index de Xie et Beni (XB)

Ce critère permet de mesurer le degré de compacité (le rapport de la variation totale à la taille de l'ensemble des données) et de séparation (le carré du minimum de toutes les distances séparant deux centres de classes différentes) d'une partition floue

donnée. C'est le rapport de la compacité obtenue à la séparation relative à la c-partition floue, c-a-d, le carré du minimum des distances inter-centres (Xie et al, 1991).

$$XB(c) = \frac{\sum_{i=1}^c \sum_{k=1}^N (\mu_{ik})^m \|x_k - v_i\|^2}{N \cdot \min_{i,k} \|x_k - v_i\|^2} \quad (5.67)$$

Une petite valeur de XB suggère des classes compactes et séparées les unes des autres. Le but est alors de trouver les c-partitions qui donnent les plus petites valeurs possibles pour XB .

Notons que les degrés d'appartenances μ_{ij} sont calculés à l'aide d'une technique quelconque, et le critère XB peut donc être utilisé pour trouver la c-partition floue obtenue avec n'importe quelle technique de clustering flou non supervisée.

5.6.7 Index de Dunn (DI) et (ADI) (Dunn, 1974)

Dunn a défini des index nets de compacité. Les 02 critères de Dunn permettent de voir si un ensemble de points peut être considéré comme séparable en des parties homogènes (éventuellement disjointes), et font partie d'une approche que l'on peut qualifier de classique.

Le premier index (DI) de Dunn à été proposé pour être employé à l'identification des classes compactes et séparées. Ainsi le résultat de classification doit être recalculé comme il été un algorithme de partition.

$$DI(c) = \min_{i \in c} \left\{ \min_{j \in c, i \neq j} \left\{ \frac{\min_{x \in C_i, y \in C_j} d(x, y)}{\max_{k \in c} \left\{ \max_{x, y \in C} d(x, y) \right\}} \right\} \right\} \quad (5.68)$$

L'inconvénient principal de l'index de Dunn est le temps de calcul informatique qui devient très couteux avec l'augmentation du nombre de clusters c et des données N .

Le deuxième index de Dunn (ADI) est donné par :

$$ADI(c) = \min_{i \in c} \left\{ \min_{j \in c, i \neq j} \left\{ \frac{\min_{x \in C_i, y \in C_j} |d(y, v_i) - d(x, v_j)|}{\max_{k \in c} \left\{ \max_{x, y \in C} d(x, y) \right\}} \right\} \right\} \quad (5.69)$$

5.7 Validation du nombre de clusters

* Validation du nombre de clusters pour la méthode GG

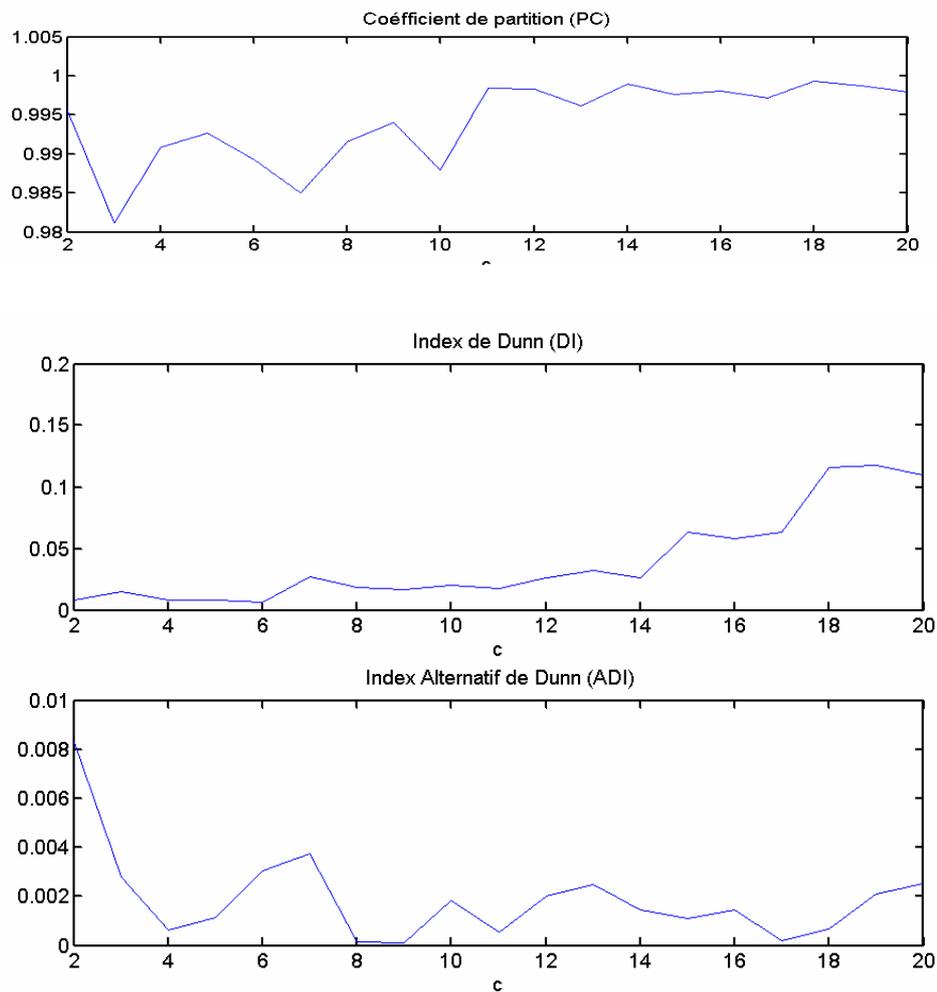


Figure 5.40 : Critères de validation en fonction du nombre de cluster pour la méthode GG

* Validation du nombre de clusters pour la méthode EM

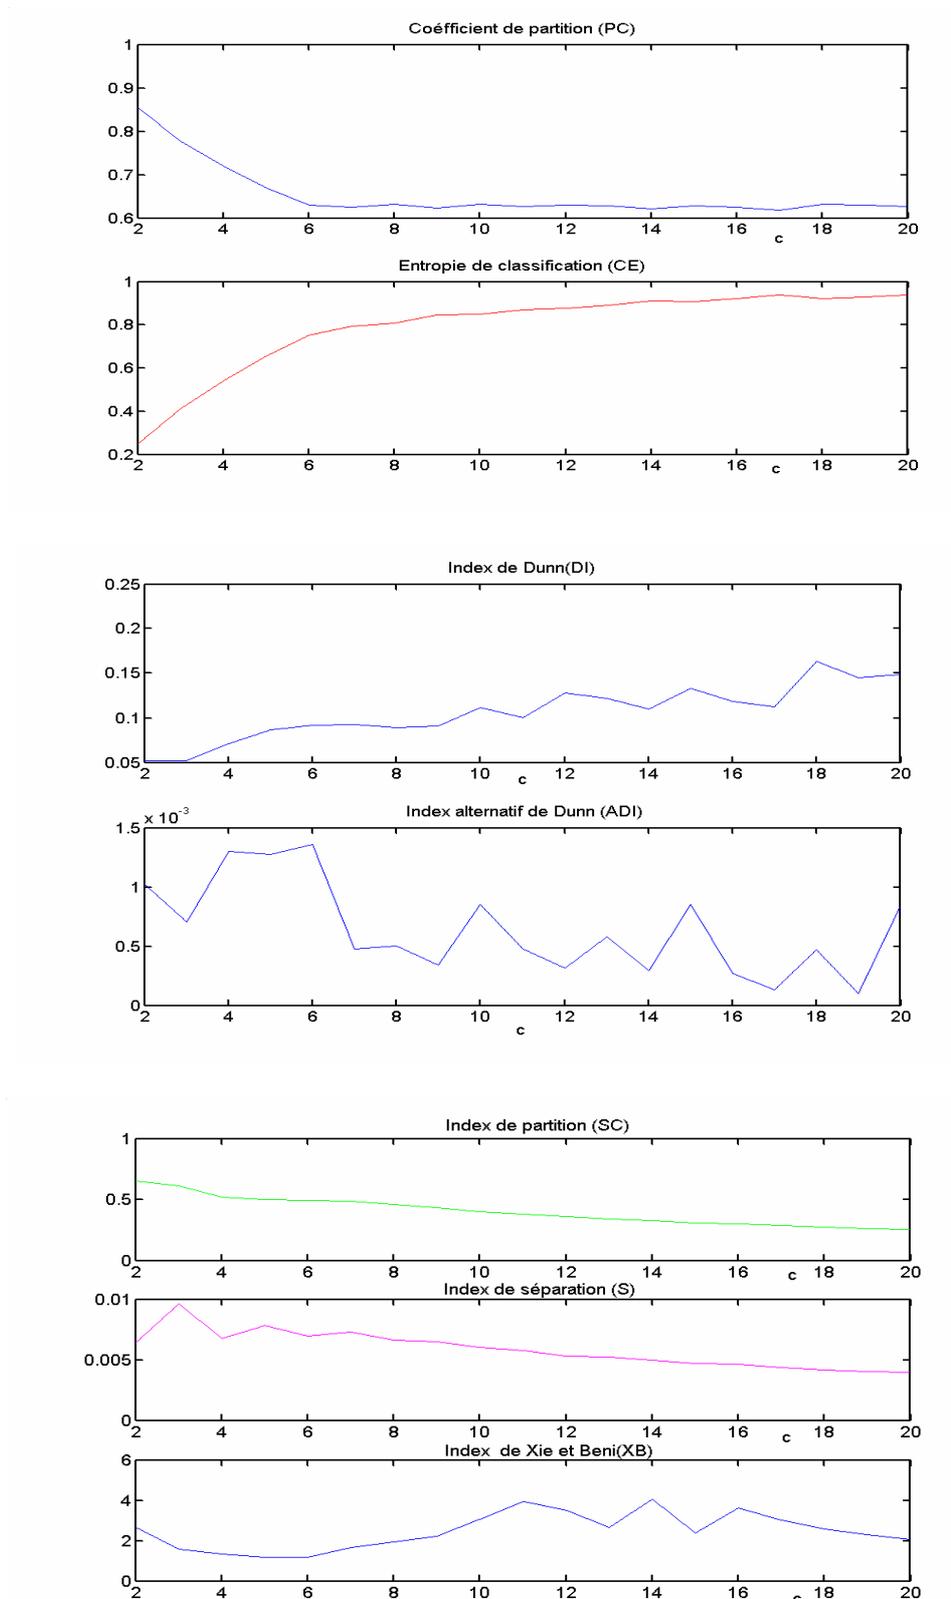


Figure 5.41 : Critères de validation en fonction du nombre de cluster pour la méthode EM

* Validation du nombre de clusters pour la méthode GK

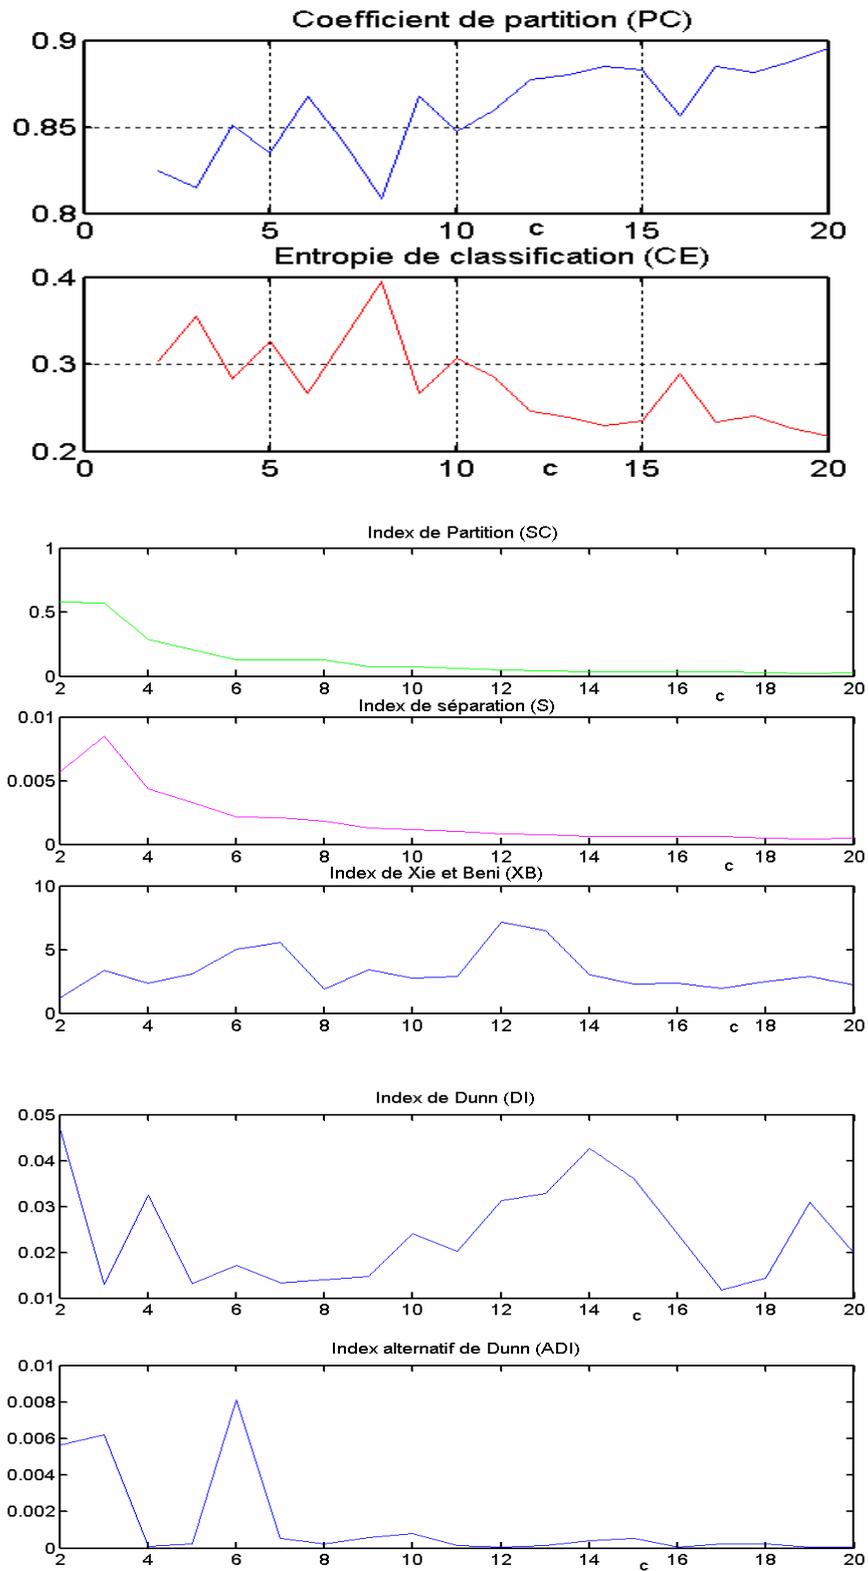


Figure 5.42 : Critères de validation en fonction du nombre de cluster pour la méthode GK

* Discussion des résultats

L'approche PC appliquée aux méthodes GG, EM et GK n'a pas été efficace, en effet, ce coefficient s'est avéré être sensible au nombre de clusters (c) et à l'indice flou (m), et ce indépendamment de toute structure au sein des données. La valeur maximale de PC ne correspond donc pas forcément à la partition optimale dans le cas générale.

Le critère d'entropie proposé par Bezdek (Bezdek et al, 1975), est malheureusement, lui aussi sensible aux paramètres c et m , donc on peut dire que les deux critères ne dépendent pas directement des données.

5.8 Validation du modèle ($C=2$, $\nu=2$, $\eta=2$)

Dans cette section on va tester les modèles extraits par les algorithmes (**GK**, **EM** et **GG**), en validant les trois autres cycles présentés par la figure 5.39

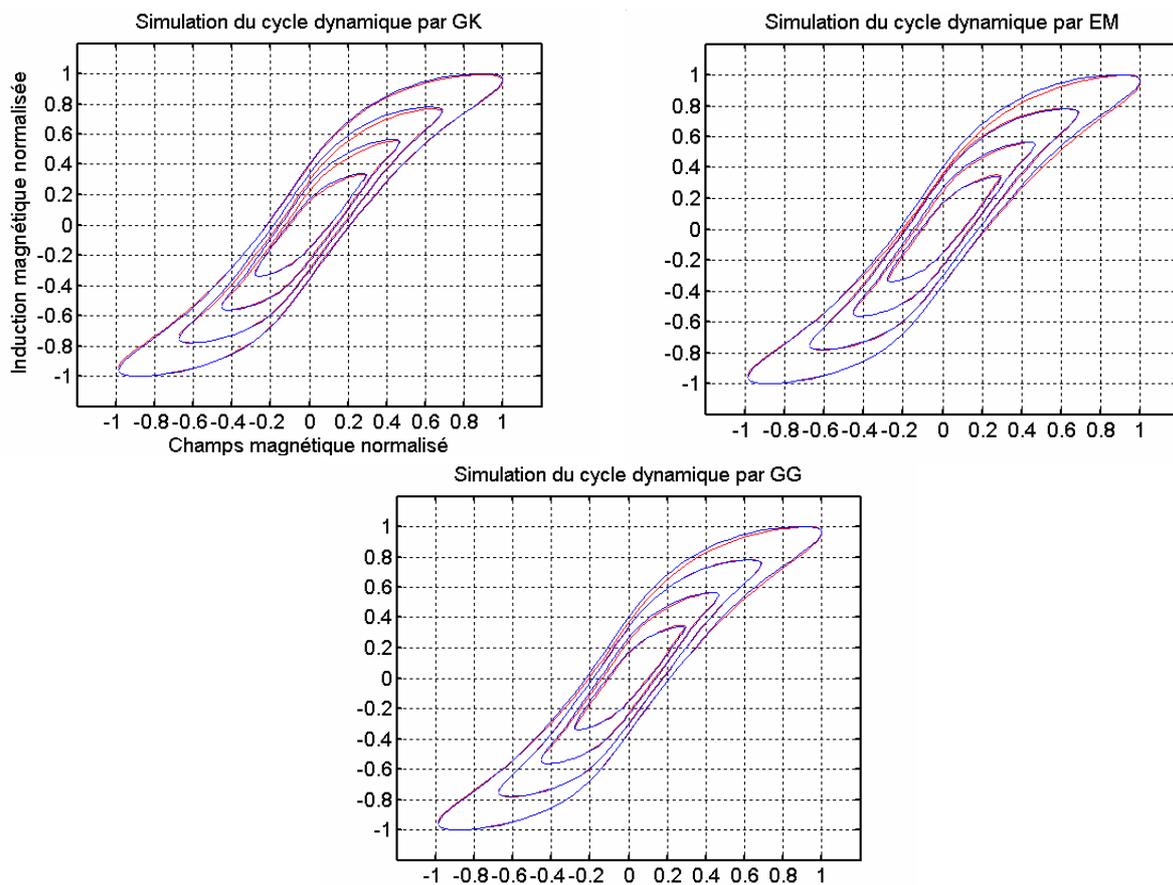


Figure 5.43 Cycles d'hystérésis validé par les méthodes GK, EM et GG

Le tableau suivant présente une comparaison numérique des résultats d'apprentissage et de validation par les trois algorithmes :

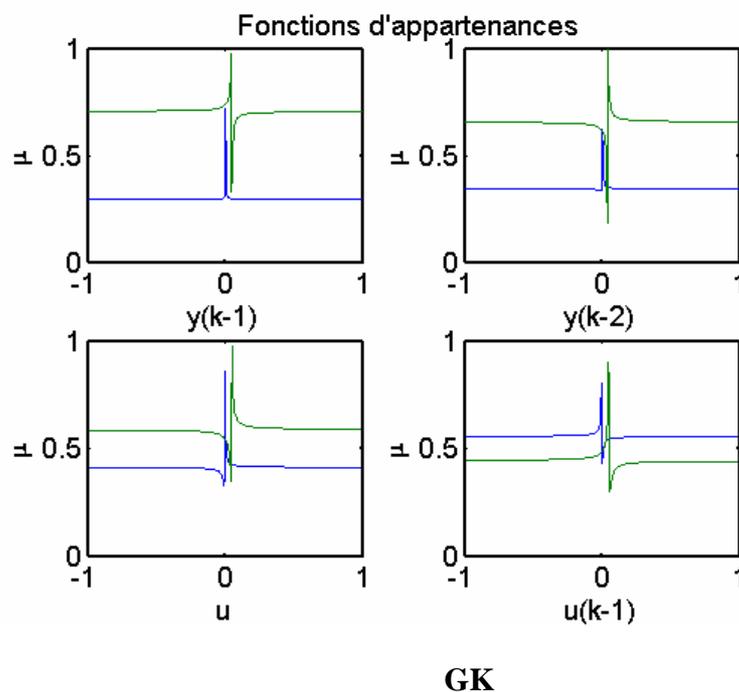
Tableau 5.4 Résultats d'apprentissage et de validation des trois algorithmes

Critères	GK		EM		GG	
	RMSE	VAF	RMSE	VAF	RMSE	VAF
	0.0081	99.987	0.0205	99.9499	0.0159	99.9646
	0.0224	99.8679	0.0074	99.9832	0.0024	99.9982
	0.0224	99.7441	0.0119	99.9239	0.0121	99.9158
	0.0085	99.8937	0.0114	99.7816	0.0114	99.7777

Le bon apprentissage ne donne surtout pas dans tout les cas une bonne validation. C'est l'inconvénient principal de l'algorithme **GK** lors de cette étape (validation).

Pendant nos expériences on prenant le cycle Majeur **L1** comme donnée E/S d'apprentissage nous avons remarqué que, l'initialisation de l'algorithme **GK** par une matrice de partition floue de l'algorithme **EM**, donne le meilleur résultat du **GK**.

Les fonctions d'appartenances des antécédents :



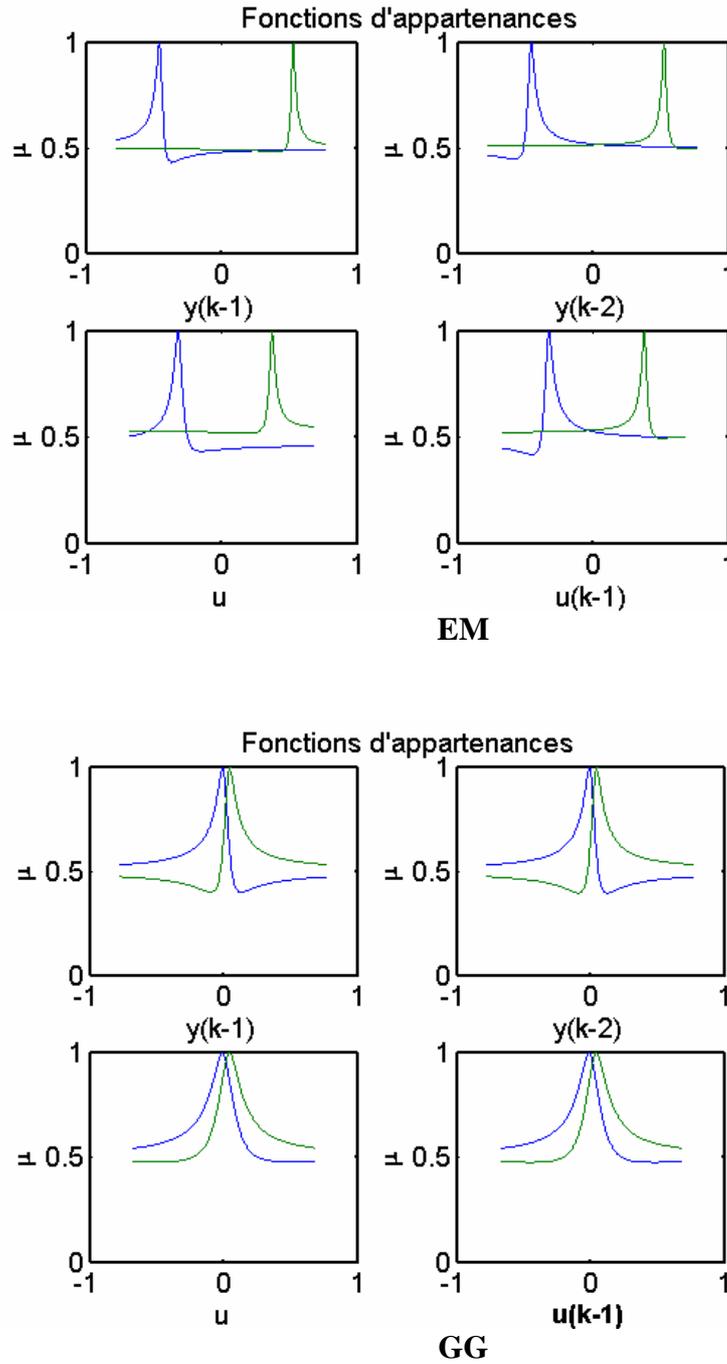


Figure 5.44 Fonctions d'appartenance des antécédents obtenus par les méthodes GK, EM et GG

Le pourcentage d'erreurs pour chaque cycle est donné par la figure suivante :

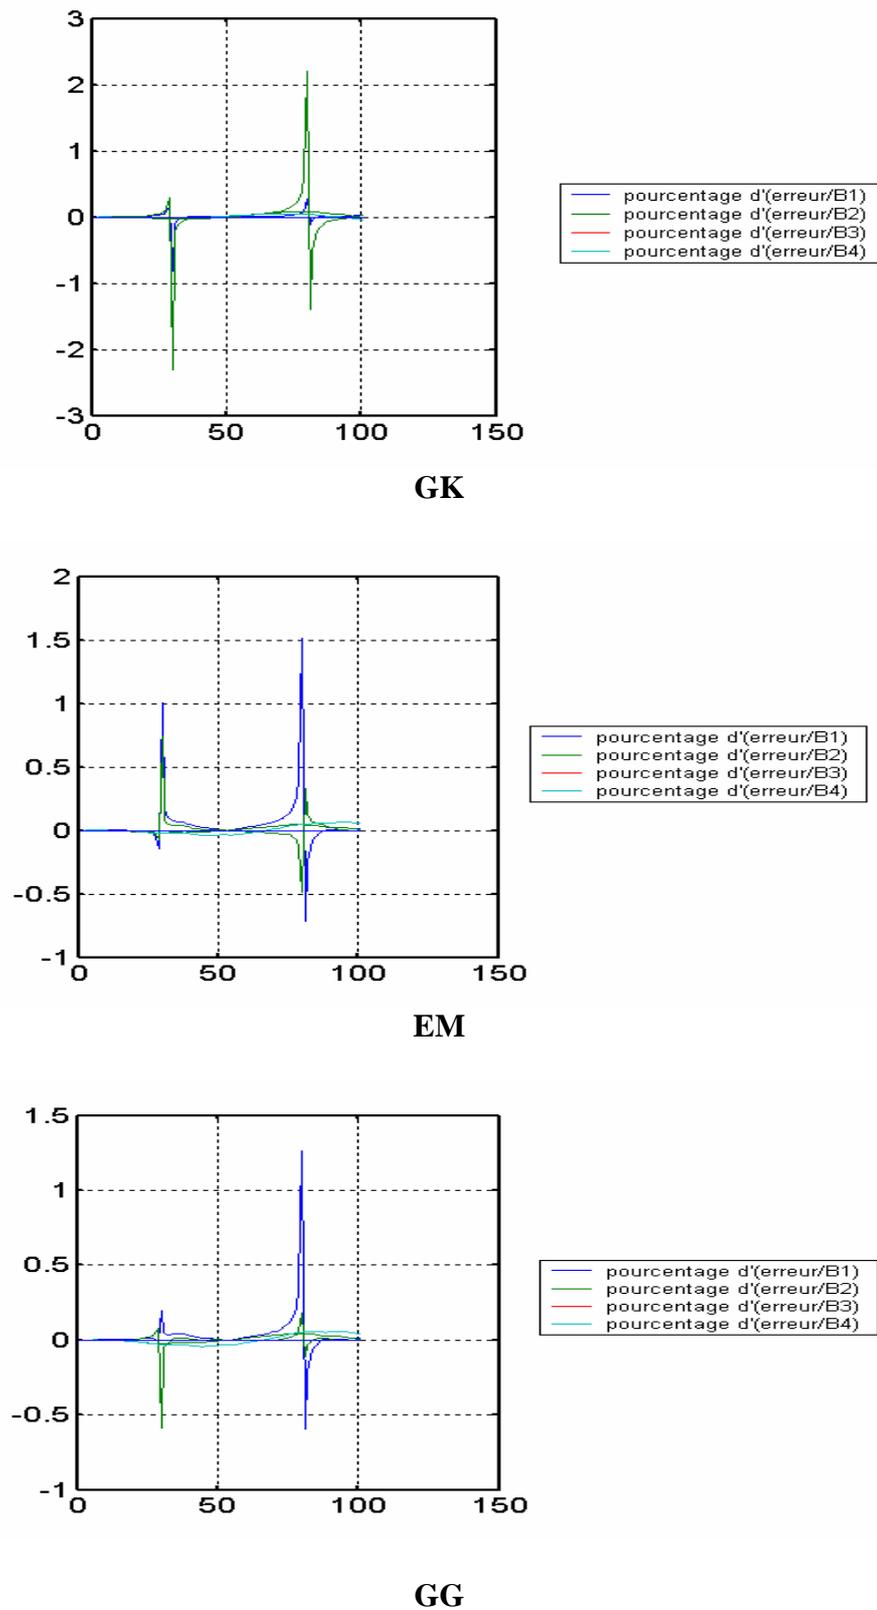
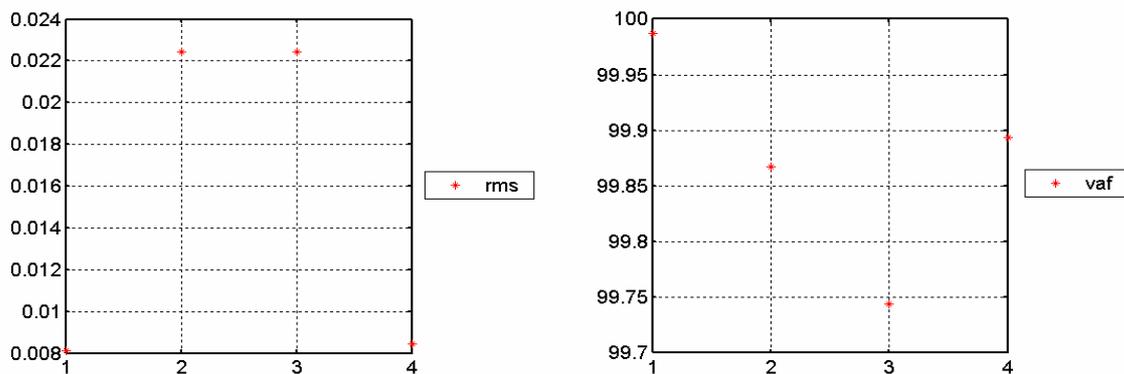
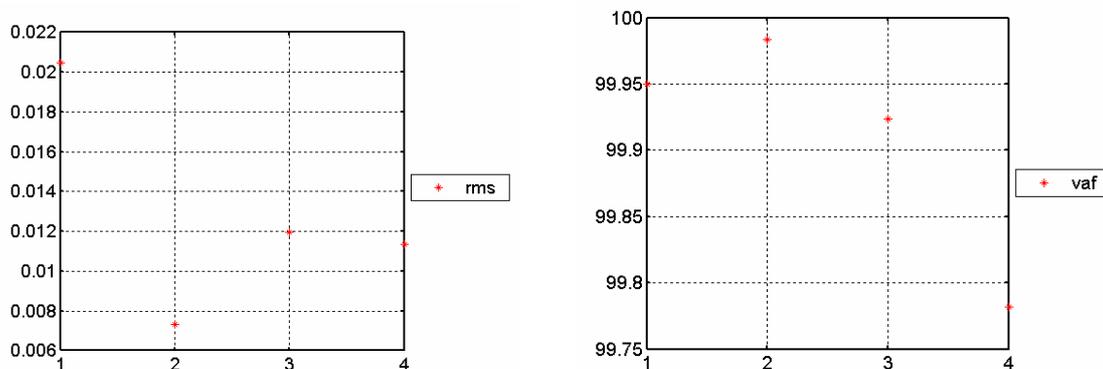


Figure 5.45 Pourcentage d'erreur pour chaque cycle des méthodes GK, EM et GG

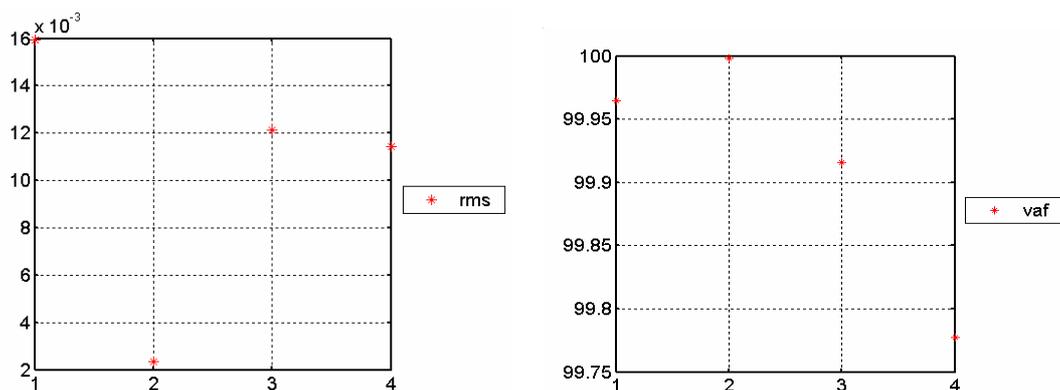
Les figures suivantes présentent la valeur de l'erreur RMSE et du VAF en fonction du nombre de cycle à identifié.



GK



EM



GG

Figure 5.46 RMSE et VAF en fonction du cycle à identifié par les méthodes GK, EM et GG

L'allure de chaque règle est comme suit :

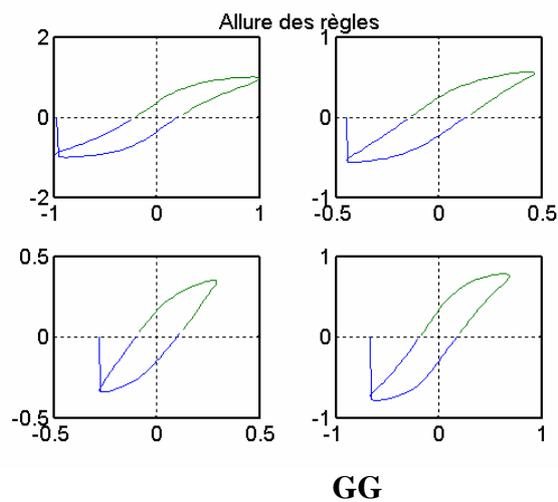
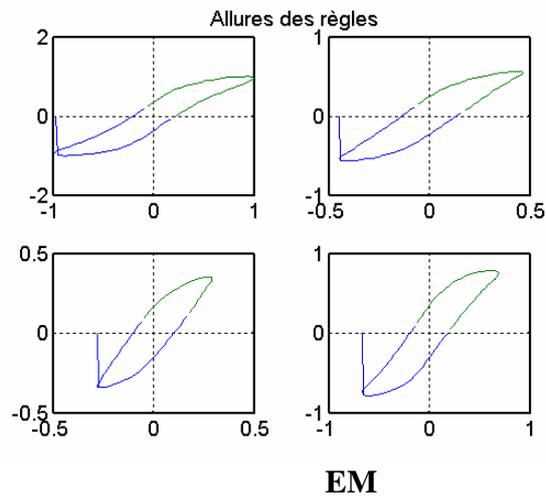
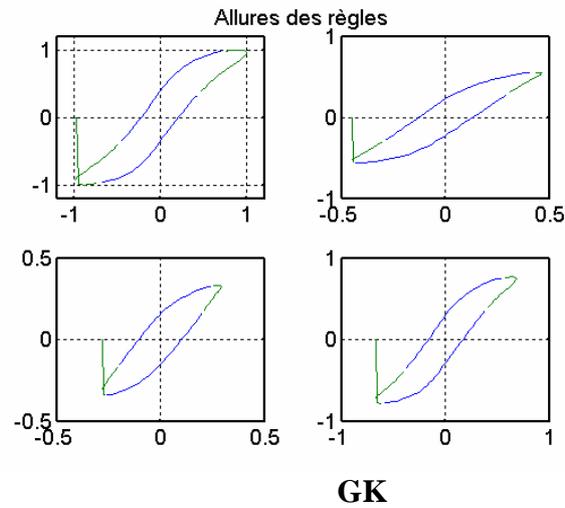


Figure 5.47 Allures des règles obtenues par les trois GK, EM et GG

L'étape la plus difficile c'est la détermination de la structure du modèle. Lorsqu'il s'agit d'une structure inconnue il faut répéter l'expérience à plusieurs reprises, jusqu'à la restitution du cycle réel. Par contre lorsque le système a une structure préalable, il est facile de prévoir une structure au départ. L'initialisation de l'algorithme **GK** par l'algorithme **EM** a minimisé le degré de Flouification, ce qui a stabilisé le **GK** autour de son minimal local. C'est pour cela qu'on ne peut pas négliger une ou plusieurs méthodes (algorithmes), mais chacune à ces propres caractéristiques.

5.9 Conclusion

Dans ce chapitre, nous avons donné une vision globale du problème de modélisation et d'identification de l'hystérésis magnétique. En générale, le problème s'est focalisé sur le choix d'une expression mathématique donnant l'induction magnétique (sortie du système) à partir de l'information contenue dans le vecteur d'entrée (champ magnétique) et des états passés du vecteur de sortie. Nous avons montré que pour les problèmes cycliques fortement non linéaires, nous pouvons utiliser des techniques issues de l'intelligence artificielle. En effet, ce chapitre nous a permis de faire le tour d'horizon des principes théoriques nécessaires à la compréhension de la modélisation et de l'identification floues de systèmes en utilisant l'approche par classification à partir des données entrée-sortie. Cependant, nous avons abordé plusieurs algorithmes de classification, Algorithme FCM, algorithme de Gustafson-Kessel, algorithme de Gath-Geva et enfin l'algorithme d'expertation-Maximisation.

Nous avons discuté les différentes étapes d'identification de modèles flous à partir des données mesurées. Cependant, nous avons développés trois modèles flous de l'hystérésis magnétique dynamique par application de trois techniques de classification.

Dans le cadre de nos travaux et par utilisation du logiciel Matlab, nous avons développé des programmes de simulation pour l'identification floue type Takagi Sugeno de l'hystérésis dynamique. Cependant, nous avons utilisé plusieurs méthodes de classification à partir des données entrée-sortie. Les résultats ont montré l'applicabilité des algorithmes de groupage comme GK, EM et GG avec une meilleure qualité de l'approximation de l'hystérésis dynamique malgré le temps de calcul plus aux moins élevé pour la convergence. Enfin, il paraît raisonnable de considérer que la caractérisation d'un système (matériau magnétique) non linéaire par une approche multi-modèle est un chemin prometteur pour un rapprochement entre la théorie mathématique et la pratique industrielle. En effet, en obtenant une représentation simple par zones d'opération définies par les fonctions d'appartenances dans les antécédents, le modèle flou permet la représentation des systèmes non linéaires, cycliques, statiques ou dynamiques par un enchaînement de sous-modèles linéaires associés aux conséquents des règles.

Dans le chapitre suivant, nous allons utiliser une méthode adaptative pour la génération des règles des antécédents toujours en se basant sur le modèle flou Takagi-Sugeno par utilisation des systèmes hybrides neuro-flous.

*Développement de modèles
d'hystérésis neuro-flous*

6.1 Introduction

La simulation des caractéristiques hystérétiques des matériaux magnétiques doit être mise en application dans des outils de simulation de champs électromagnétique pour prévoir le comportement de différents types de pièces électromagnétiques. Cependant, il existe deux grandes approches décrivant la relation entre le champ appliqué et la magnétisation du matériau. La première consiste en une approche empirique dans laquelle on ne se préoccupe pas de la physique du matériau mais d'une définition mathématique approchant au mieux des grandeurs observées (Preisach, 1935). La seconde se qualifie au contraire d'approche phénoménologique se basent sur la connaissance des phénomènes physiques intervenant dans le matériau afin d'extraire des règles générales de comportement (Modèle de Jiles-Atherton(JA)). En comparaison à d'autres modèles, le modèle de JA présente certains avantages tel que sa formulation en équation différentielles et son emploi de paramètres réduits (cinq paramètres) dont l'identification s'effectue par un seul cycle (Jiles et al, 1986). L'intelligence artificielle a été également appliquée à la modélisation de l'hystérésis et à l'identification des paramètres caractérisant d'autres modèles à savoir les réseaux de neurones et les algorithmes génétiques (Wilson et al, 2001), (Salvini et al, Mars 2002), (Salvini et al, 2001), (Delvicchio et al, 2000), (Xu et al, 1997), (Saliyah et al, 1997), (Dimitre et al, 2001), (Dimitre et al, 2003), (Saghafifar et al, 2001), (Kuczmann et al, 2002) et (Kuczmann et al, Mars 2002). Comme les réseaux de neurones, la logique floue (Zadeh, 1965) peut être aussi aisément employée pour l'approximation des fonctions arbitraires (Buckley et al, 1994) et (Kosko et al, 1992). Les réseaux de neurones ont l'avantage de l'apprentissage à partir de données mesurées sans pour autant prendre ni de décision ni de la connaissance. Par contre la logique floue peut prendre de la décision sans apprentissage. Les techniques neuro-floues combinées à la logique floue aux réseaux de neurones utilisent les avantages de l'un et de l'autre.

Récemment, des développements des modèles neuro-flous ont donnés des résultats remarquables (Yen et al, 1999), (Jang et al, 1997) et (Abraham, 2001). Parmi ces systèmes développés l'ANFIS s'avère le mieux adapté (Mathworks, 1998). Des exemples d'applications, des architectures d'approximations des fonctions non linéaires et de l'identification des systèmes dynamiques ont été publiées par (Jang, 1997), (Jang, 1992) et (Jang, March 1995).

Dans ce chapitre, nous exploitons la puissance des systèmes adaptatifs hybrides intégrés dans la conception de modèles neuro-flous pour la modélisation du phénomène d'hystérésis magnétique. Les résultats de modélisation obtenus par la modèle de Jiles-Atherton seront utilisés pour l'apprentissage et l'identification du modèle obtenu par la technique Neuro-floue.

6.2 Modèle d'hystérésis de Jiles-Atherton

6.2.1 Formulation

Le modèle de Jiles–Atherton est un modèle physique qui prend en considération les différents mécanismes mis en jeu dans la procédure d'aimantation des matériaux magnétiques. Dans ce modèle, l'aimantation M du matériau est représentée par la somme de l'aimantation magnétique irréversible M_{irr} due au déplacement des parois des domaines magnétiques et de l'aimantation réversible M_{rev} due à la forme des parois magnétiques (Jiles et al, 1986). La variation de l'aimantation irréversible par rapport aux variations du champ appliqué est donnée par :

$$\frac{dM_{irr}}{dH} = \frac{(M_{an} - M)}{\frac{k}{\mu_0} \delta - \alpha(M_{an} - M)} \quad (6.1)$$

Où L'aimantation anhystérétique M_{an} est représentée par la fonction de Langevin (Wilson et al, 2001) corrigée par la théorie de Weiss :

$$H_e = H + \alpha M \quad (6.2)$$

$$M_{an} = M_s \left(\coth \left(\frac{H_e}{a} \right) - \frac{a}{H_e} \right) \quad (6.3)$$

La variation de l'aimantation réversible est proportionnelle à la différence entre la composante hystérétique et l'aimantation totale :

$$\frac{dM_{rev}}{dH} = c \left(\frac{dM_{an}}{dH} - \frac{dM}{dH} \right) \quad (6.4)$$

En combinant les composantes irréversibles et réversibles, l'expression de la variation de l'aimantation globale est donnée par :

$$\frac{dM}{dH} = \frac{1}{1+c} \frac{(M_{an} - M)}{\frac{k\delta}{\mu_0} - \alpha(M_{an} - M)} + \frac{c}{c+1} \frac{dM_{an}}{dH} \quad (6.5)$$

L'utilisation du modèle de JA exige l'identification de cinq paramètres à savoir :

- α : paramètre moyen de champ (Facteur de correction de Weiss) définissant l'accouplement magnétique entre les domaines dans le matériel, et est exigé pour calculer le champ magnétique efficace, H_e (Equation. 6.2) composé par le champ externe appliqué et la magnétisation interne.
- M_s et a , respectivement l'aimantation de saturation et le paramètre de Langevin.

- k : Coefficient définissant la densité d'épinglage.
- c : Coefficient définissant la composante réversible de l'aimantation.

6.2.2 Identification des paramètres

6.2.2.1 Susceptibilité anhystérétique

La susceptibilité anhystérétique est la valeur de la dérivée de M_{an} lorsque H et M tendent vers zéro.

$$\chi_{an} = \left(\frac{dM_{an}}{dH} \right)_{M=0H=0} = \frac{M_s}{3.a - \alpha.M_s} \quad (6.6)$$

D'où:

$$a = \frac{M_s}{3} \left(\frac{1}{\chi_{an}} + \alpha \right) \quad (6.7)$$

6.2.2.2 Susceptibilité initiale

La composante réversible de l'aimantation est exprimée par l'intermédiaire du paramètre c dans l'équation d'hystérésis (Equation 6.4) par:

$$\chi_{ini} = \left(\frac{dM}{dH} \right)_{H=0M=0} = \frac{c.M_s}{3.\alpha} \quad (6.8)$$

6.2.2.3 Coercivité

Le coefficient d'épinglage k représente la densité des sites d'épinglage et caractérise la largeur du cycle. Les pertes dans le matériau sont déterminées à partir du champ coercitif H_c et de la valeur de la susceptibilité différentielle en ce point :

$$k = \frac{M_{an}(H_c)}{1-c} \left[\alpha + \frac{1}{\chi(H_c) - \left(\frac{c}{1-c} \right) \frac{dM}{dH}} \right] \quad (6.9)$$

6.2.2.4 Rémanence

Le facteur de correction de Weiss α est déterminé par l'équation suivante :

$$M_r = M_{an}(M_r) + \frac{k}{\frac{a}{1-c} + \frac{1}{\chi(M_r) - c dM/dH}} \quad (6.10)$$

Les différents paramètres du modèle de JA sont déterminés à partir de quelques points de mesure. Le coefficient de réversibilité est tiré de la courbe de première aimantation par (Equation 6.8) et les paramètres (a, α et k) sont obtenus successivement à partir des équations (Equation 6.7) et (Equation 6.9).

6.3 Système neuro-flou à inférence adaptative (ANFIS)

Les systèmes hybrides neuro-flous à inférence adaptative sont une combinaison de techniques neuronales et floues. Ils sont une des catégories de systèmes hybrides les plus développées car la logique floue et les réseaux connexionnistes ont beaucoup de points en commun. Actuellement on cite principalement 03 types de systèmes Neuro-Flous à savoir :

- Systèmes intégrant des règles floues dans des réseaux ;
- Systèmes faisant extraction de règles floues à partir de réseau ;
- Systèmes implémentant des neurones flous.

L'utilisation conjointe des méthodes neuronales et floues dans des systèmes hybrides permet de tirer davantage des qualités de l'une et de l'autre, et en particulier les capacités d'apprentissage des premières, la lisibilité et la souplesse des éléments manipulés par les secondes (Jang et al, 1997). La forme des fonctions de nœud dans un système hybride à inférence adaptative peut changer d'un nœud à un autre.

Le principal type d'association entre réseaux de neurones et systèmes flous est le cas où un système d'inférence flou est mis sous la forme d'un réseau multicouche. Incontestablement, la technique Anfis est une technique actuellement très utilisée par les chercheurs du domaine suite à son bon support software (Yen et al, 1999), (Mathworks, 1998), (Jang, 1992) et (Jang et al, 1995). Cette méthode implémente le modèle de Takagi et Sugeno (TSK) d'ordre zéro ou d'ordre un, sous la forme d'un réseau multicouches à rétro propagation, dont les paramètres ajustables sont ceux des fonctions d'appartenances ainsi que ceux de la sortie. Cette méthode très performante est largement utilisée dans les réalisations pratiques.

6.3.1 Présentation d'ANFIS

ANFIS est un modèle de génération automatique de règles floues basé sur le modèle d'inférence de Takagi Sugeno. Son schéma architectural est donné par figure (6.1)

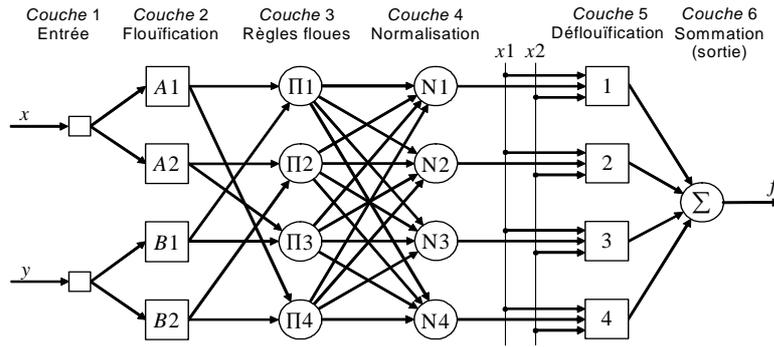


Figure 6.2 Architecture d'ANFIS

Pour présenter l'architecture d'ANFIS, nous supposons qu'il y a deux variables linguistiques d'entrées x et y et une sortie f , et supposons que la base des règles contient deux règles de types :

Règle1 : Si x est $A1$ et y est $B1$, Alors $f1 = p1 x + q1 y + r1$

Règle2 : Si x est $A2$ et y est $B2$, Alors $f2 = p2 x + q2 y + r2$

Où x et y sont les variables d'entrée et A_1, A_2, B_1 et B_2 des ensembles flous, f_i les sorties de tous les neurones de déflouification, p_i, q_i et r_i sont des paramètres du conséquent de la règle i déterminés pendant le processus d'apprentissage.

Le réseau ANFIS est un réseau multicouches dont les connexions ne sont pas pondérées, ou ont toutes un poids de 1. Les nœuds sont de deux types différents selon leur fonctionnalité, ceux qui contiennent des paramètres (nœuds carrés) et ceux qui ne contiennent pas (nœuds circulaires). La sortie O_i^k du nœud i de la couche k (appelé nœud (i,k)) dépend des signaux provenant de la couche $k-1$ et des paramètres du nœud (i,k) , c'est-à-dire :

$$O_i^k = f(O_1^{k-1}, \dots, O_{n_{k-1}}^{k-1}, p, q, r, \dots) \tag{6.11}$$

Où n_{k-1} est le nombre de nœuds dans la couche $k-1$.

Dans le réseau de la figure(1), les nœuds d'une même couche ont des fonctions issues d'une même famille que nous expliquons ci-dessous :

- **Première couche** Son rôle principal est la transmission de données d'entrées à la couche de flouification.

- **deuxième couche** Chaque nœud de cette couche ait une fonction telle que :

$$O_i^2 = \mu_{A_i}(x) \tag{6.12}$$

Où x est l'entrée du nœud i , et A_i le terme linguistique associé à sa fonction. En d'autres termes, O_i^2 est le degré d'appartenance de x à A_i . Les paramètres de chaque nœud de cette couche sont ceux de la fonction d'appartenance correspondante. Par exemple, si la fonction d'appartenance est une bellshape donnée par :

$$\mu_{A_i}(x) = \frac{1}{1 + \left\{ \left(\frac{x - c_i}{a_i} \right)^2 \right\}^{b_i}} \quad (6.13)$$

Où a_i , b_i et c_i sont des paramètres de la fonction d'appartenance.

- **Troisième couche** Chaque neurone appartenant à cette couche correspond à une règle floue Sugeno. Il reçoit les sorties des neurones de flouification et calcule son activation. La conjonction des antécédents est réalisée avec l'opérateur produit Π . Ce produit représente le degré d'activation d'une règle:

$$O_i^3 = \omega_i = \mu_{A_i}(x)\mu_{B_i}(y) \quad i = 1,2 \quad (6.14)$$

- **Quatrième couche** Chaque nœud i de cette couche est un nœud circulaire appelé N . La sortie du nœud i est le degré d'activation normalisé de la règle i :

$$O_i^4 = \bar{\omega}_i = \frac{\omega_i}{\omega_1 + \omega_2} \quad i = 1,2 \quad (6.15)$$

- **Cinquième couche** Chaque nœud i est relié à un nœud de normalisation (Nœud carré) correspondant aux entrées initiales du réseau. Il calcule le conséquent pondéré de la règle sous-jacent comme étant:

$$O_i^5 = \bar{\omega}_i f_i = \bar{\omega}_i (p_i x + q_i y + r_i) \quad i = 1,2 \quad (6.16)$$

Où $\bar{\omega}_i$ est la sortie de la couche 3, et $\{p_i, q_i, r_i\}$ des paramètres de sortie de la règle i .

- **Sixième couche** Comprend un seul neurone qui fournit la sortie de ANFIS en calculant la somme des sorties de tous les neurones de flouification.

$$O_i^6 = \sum_{i=1}^2 \bar{\omega}_i f_i = \frac{\sum_{i=1}^2 \omega_i f_i}{\omega_1 + \omega_2} \quad (6.17)$$

L'architecture d'Anfis montre l'existence de deux couches adaptatives, la deuxième et la cinquième. La deuxième couche présente trois paramètres modifiables $\{a_i, b_i, c_i\}$ liées aux fonctions d'appartenances d'entrées, appelés paramètres des

prémises. La cinquième couche, contienne également trois paramètres modifiables $\{p_i, q_i, r_i\}$ appelés paramètres conséquents (Jang, 1993).

6.3.2 Algorithme d'apprentissage de ANFIS

Dans cette technique, L'apprentissage à partir d'un ensemble de données concerne l'identification des paramètres des prémises et des conséquents, la structure du réseau étant fixée. L'algorithme d'apprentissage utilisé est un algorithme d'apprentissage hybride qui combine un algorithme de descente de gradient avec une estimation par moindres carrées, on a alors :

$$f = \frac{\omega_1}{\omega_1 + \omega_2} f_1 + \frac{\omega_2}{\omega_1 + \omega_2} f_2 \quad (6.18)$$

Substituons l'équation (6.15) dans l'équation (6.18):

$$f = \bar{\omega}_1 f_1 + \bar{\omega}_2 f_2 \quad (6.19)$$

La substitution des règles Si-Alors dans l'équation (6.19) donne:

$$f = \bar{\omega}_1 (p_1 x + q_1 y + r_1) + \bar{\omega}_2 (p_2 x + q_2 y + r_2) \quad (6.20)$$

Après réarrangement des termes on a :

$$f = (\bar{\omega}_1 x) p_1 + (\bar{\omega}_1 y) q_1 + (\bar{\omega}_1) r_1 + (\bar{\omega}_2 x) p_2 + (\bar{\omega}_2 y) q_2 + (\bar{\omega}_2) r_2 \quad (6.21)$$

C'est une combinaison linéaire des paramètres conséquents modifiables p_1, q_1, r_1, p_2, q_2 et r_2 . Notons que dans cet algorithme, on optimise aussi bien les paramètres des prémises que ceux des conséquents. Durant la passe avant, les paramètres des conséquents sont adaptés alors que les paramètres des prémises sont maintenus constants, alors que durant la passe arrière, les rôles sont inversés (Figure 6.2).

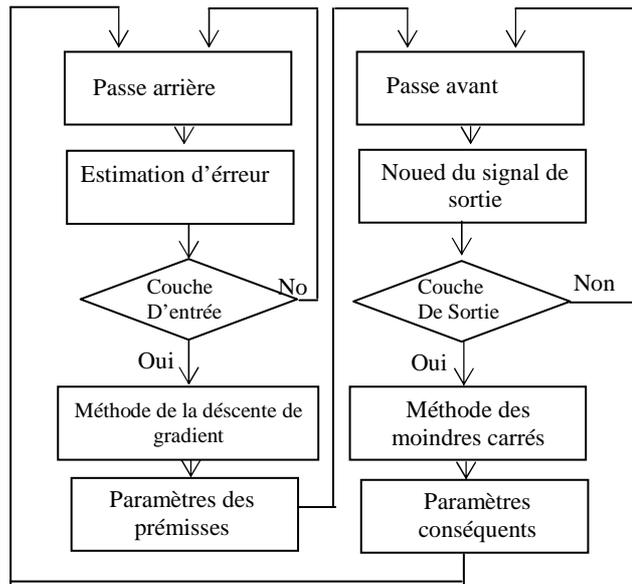


Figure 6.2: Algorithme D'apprentissage d'Anfis pour l'ajustement de la production des paramètres des règles

Nous pouvons diviser le paramètre S en deux ensembles :

$$S = S_1 \oplus S_2$$

S = Ensemble de tous les paramètres,

S_1 = Ensemble des paramètres de prémisses (non linéaires),

S_2 = ensemble des paramètres conséquents (linéaires)

\oplus : Somme directe

Pour le passage vers l'avant (Figure 6.2), nous pouvons appliquer la méthode des moindres carrés pour l'identification des paramètres conséquents. Pour un ensemble de valeurs S_1 , nous pouvons utiliser les données d'apprentissage, nous obtenons donc un système d'équation :

$$A \Theta = y \quad (6.22)$$

Avec Θ matrice contenant les paramètres inconnus dans l'ensemble S_2 . C'est un problème linéaire, la solution pour Θ est réduit au minimum $\|A\Theta - y\|$:

$$\Theta^* = (A^T A)^{-1} A^T y \quad (6.23)$$

Nous pouvons utiliser également la méthode des moindres carrés récursif dans le cas d'apprentissage en ligne. Pour la passe en arrière (voir la figure 6.2), les signaux d'erreurs propagent vers l'arrière. Les paramètres des prémisses sont adaptés par la méthode de descente.

$$J(\Theta) = \frac{1}{2} \sum_{N=1}^N [y(k) - \hat{y}(k, \Theta)]^2 \quad (6.24)$$

d'une façon récursive, en respectant $\Theta_{(S2)}$. L'adaptation des paramètres dans le $i^{\text{ème}}$ noeud de la couche L s'écrit comme:

$$\hat{\Theta}_i(k) = \hat{\Theta}_i^L(k-1) + \eta \frac{\partial^+ E(k)}{\partial \hat{\Theta}_i^L(k)} \quad (6.25)$$

avec η le rapport d'apprentissage et le vecteur gradient.

$$\frac{\partial^+ E}{\partial \hat{\Theta}_i^L} = \varepsilon_{L,i} \frac{\partial \hat{z}_{L,i}}{\partial \hat{\Theta}_i^L} \quad (6.26)$$

$\partial \hat{z}_{L,i}$ est la sortie du noeud et $\varepsilon_{L,i}$ est l'erreur de la back-propagation.

6.4 Approximation de l'hystérésis magnétique

6.4.1 Simulation

L'équation différentielle (6.5), sous sa forme originale a été reformulée en une équation en fonction du temps par la multiplication des deux membres par dH/dt , ainsi on a :

$$\frac{dM}{dt} = \frac{1}{1+c} \frac{dH}{dt} \frac{(M_{an}-M)}{\frac{\partial k}{\mu_0} - \alpha(M_{an}-M)} + \frac{c}{1+c} \frac{dM_{an}}{dt} \quad (6.27)$$

Cette reformulation permet donc la détermination de l'aimantation au moyen de la méthode de Runge Kutta d'ordre 4 dans l'environnement de Matlab.

Pour calculer l'induction magnétique B à partir de l'aimantation M et le champ magnétique H , on emploie la loi constitutive du matériau suivante :

$$B = \mu H = \mu_0 \mu_r H = \mu_0 (H + M) \quad (6.28)$$

Avec :

$\mu_0 = 4.\pi.10^{-7}$ (H/m) est la perméabilité du vide et μ_r représente la perméabilité relative du matériau utilisé.

Le cycle d'hystérésis quasi-statique généré par le modèle de Jiles-Atherton sera donc utilisé pour l'identification du cycle généré par le modèle flou (Mordjaoui et al, 2007), (Mordjaoui et al, Mai 2007).

6.4.2 Modèle neuro-flou proposé

Dans ce paragraphe, nous vérifions les capacités d'ANFIS par approximation de l'hystérésis magnétique quasi-statique. L'induction $B(t)$ résultante de la simulation du modèle de Jiles-Atherton d'un matériau ferromagnétique (figure 6.3 a et b) soumis à un champ magnétique amorti ($f=0.5$ Hz) est utilisé comme un vecteur d'entrée.

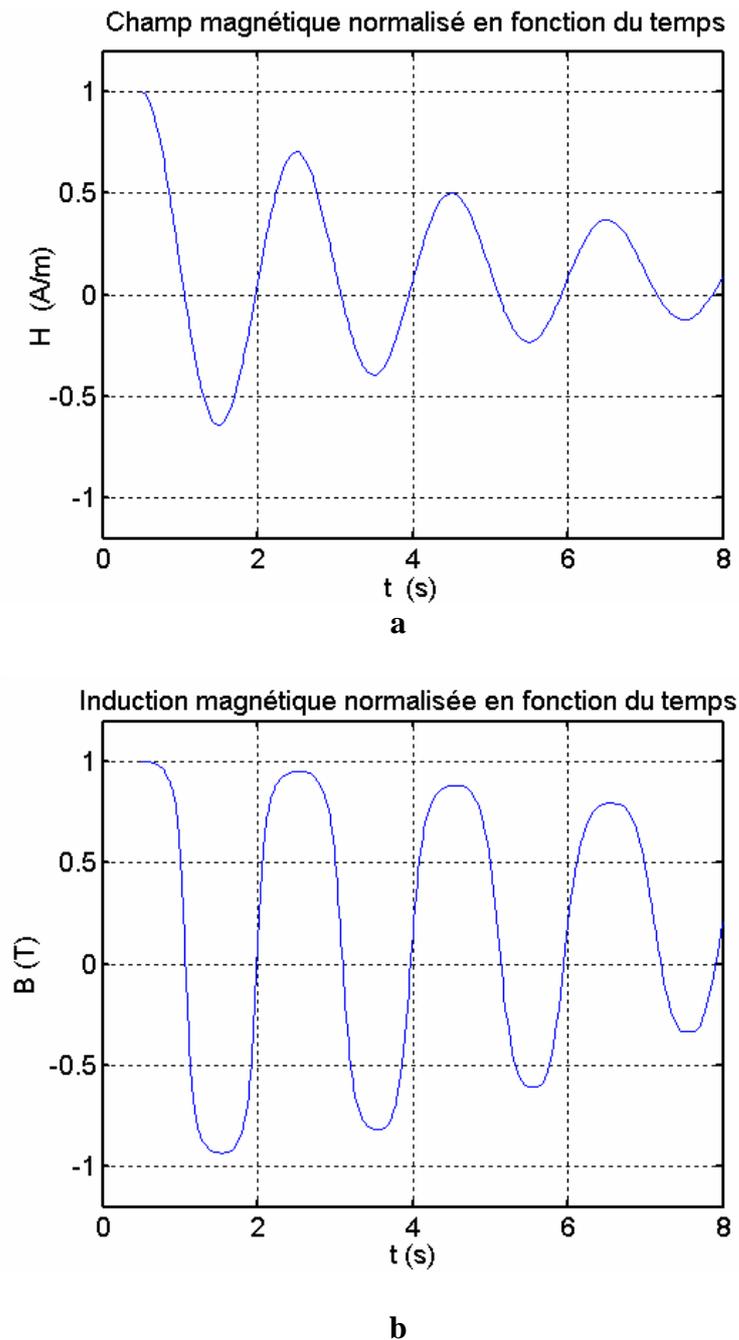


Figure 6.3 Champ et induction magnétique correspondante en fonction du temps

Notre but est l'extraction d'un modèle de processus quasi-statique qui prévoit l'induction magnétique en utilisant 12 vecteurs candidats à ANFIS où chaque vecteur

contient 346 paires de données $(H(t), B(t))$. Les 173 premières paires sont utilisées pour l'apprentissage alors que les 173 dernières sont utilisées pour le test, la précision et l'efficacité du modèle. Nous avons ensuite étudié l'erreur d'apprentissage que présente chaque modèle dès 35 générés par les différentes combinaisons entre les vecteurs d'entrées et la sortie désirée. Le résultat de cette étude montre que le modèle (H1, B4) présente le minimum d'erreur (figure 6.4). Notons que quatre fonctions d'appartenances ont été choisies pour ce test et une seule période pour l'identification des paramètres de linéarisation. Enfin, nous avons utilisé le modèle choisit comme vecteurs d'entrée de ANFIS et nous l'avons fait traîner pendant 100 périodes.

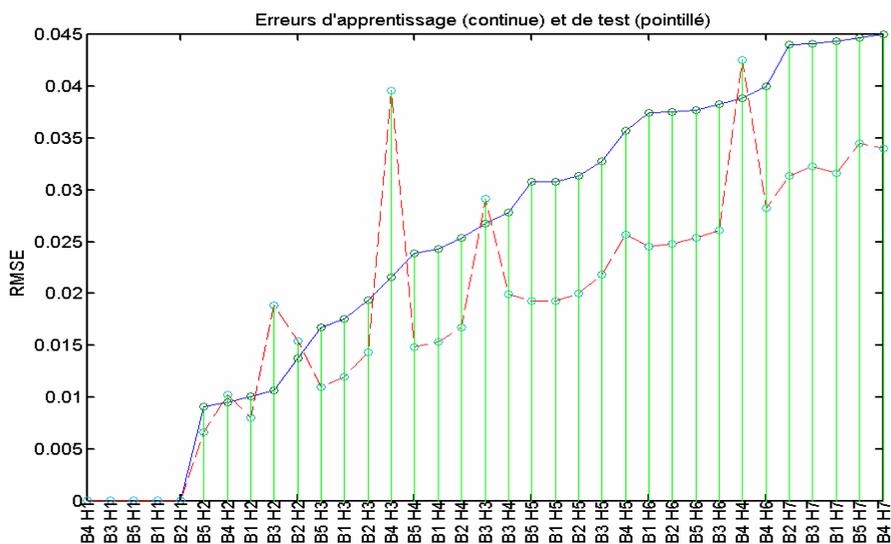


Figure 6.4 Sélection des entrées

La figure (6.5) présente la courbe de l'erreur de convergence de ANFIS. Les paramètres optimaux sont obtenus au minimum d'erreur de test indiqué par un petit cercle vert.

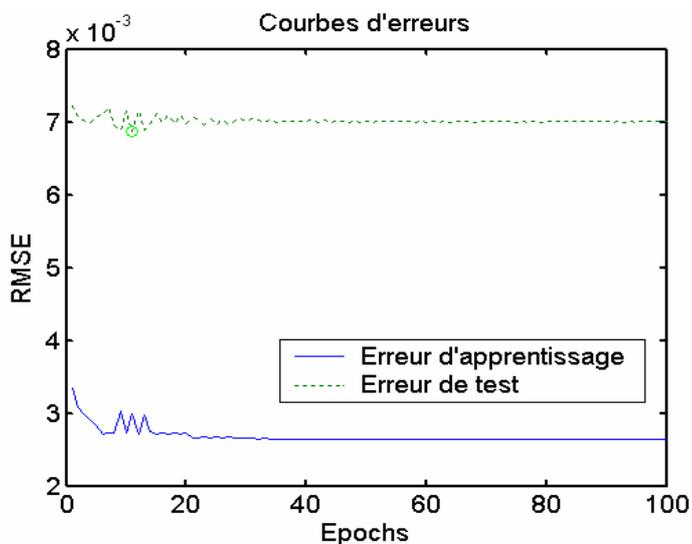


Figure.6.5 Courbes d'erreur d'apprentissage et de test

La distribution de données est indiquée par la figure (6.6), où on peut remarqué que les 173 paires d'apprentissage et les 173 paires de test ne couvrent pas la même région.

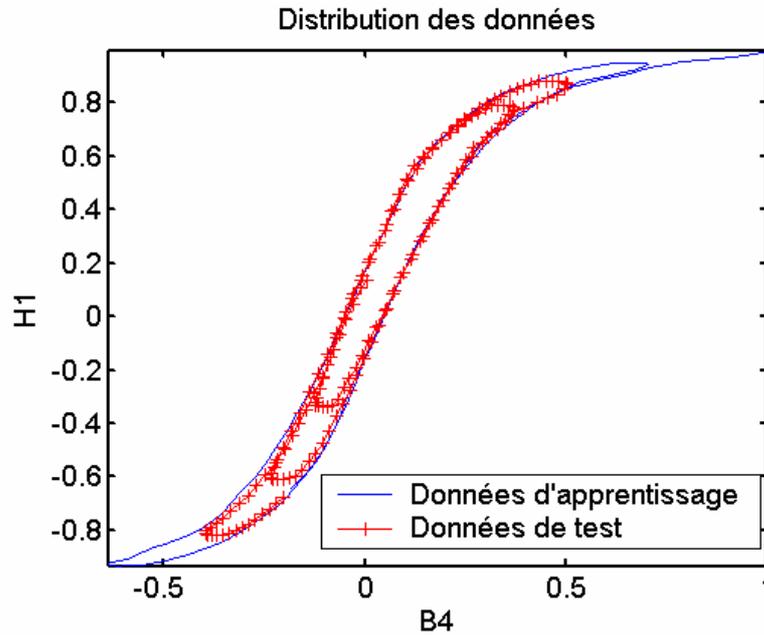


Figure 6.6 Distribution des données

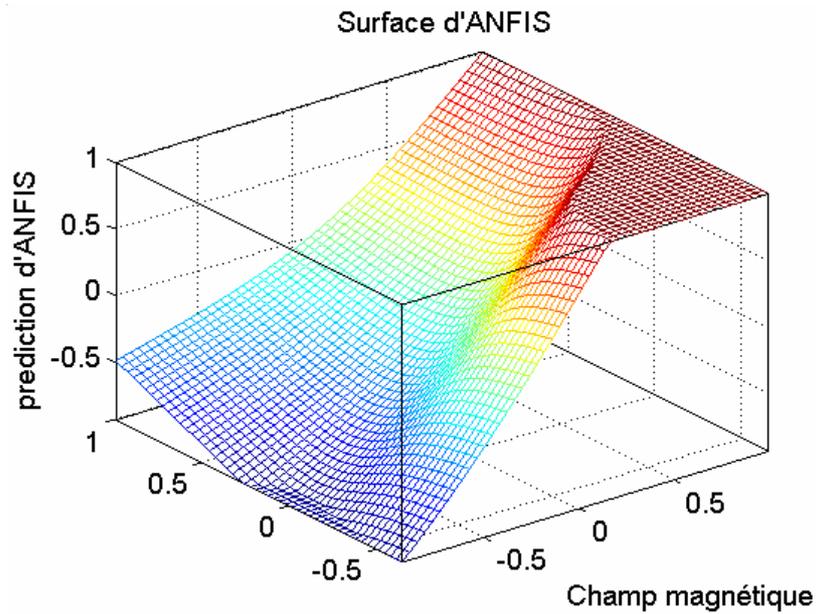


Figure 6.7 Surface d'Anfis

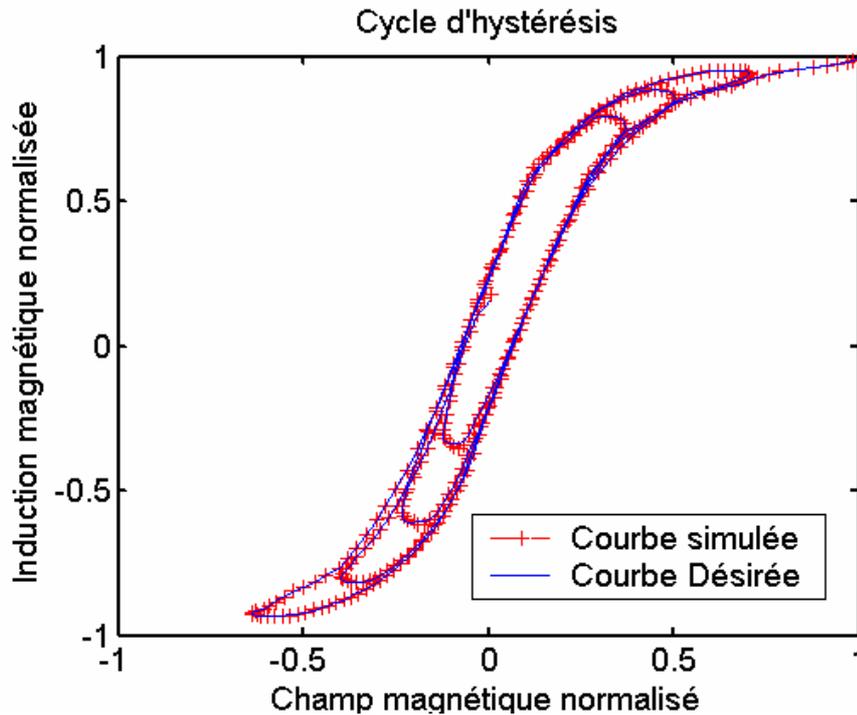


Figure 6.8 Résultats d'apprentissage d'ANFIS. Système à 2 entrées

Le cycle d'hystérésis généré par le modèle neuro-flou proposé est pratiquement superposé avec la courbe générée par le modèle de Jiles-Atherton (figure 6.8), ce qui démontre la capacité d'identification de ce modèle. Dans la figure 6.7, nous avons présenté la surface d'ANFIS, où nous avons montré clairement qu'elle est découpée au maximum et au minimum de la sortie désirée.

Le réseau ANFIS de la figure 6.1 a été programmé par la boîte à outil de la logique floue dans le logiciel Matlab (version 6.5) avec lequel on a construit les règles floues Si-Alors avec leurs fonctions d'appartenance appropriées, tout en respectant les étapes suivantes :

- a- Emploi de la commande `genfis1` pour produire un système FIS initiale
- b- Entrer les paramètres pour l'apprentissage.
 - Le nombre d'itérations.
 - Le nombre de fonctions d'appartenance
 - La tolérance.
- c- Commencer l'apprentissage en utilisant la commande ANFIS.
- d- Arrêter quand la tolérance est satisfaite.
- e- Valider les résultats avec un autre ensemble de données.

Les étapes d'adaptation des paramètres sont montrés dans la figure 6.9, alors que les fonctions d'appartenance initiales et finales de la première et de la deuxième entrée sont représentées dans la figure 6.10.a,b,c,d.

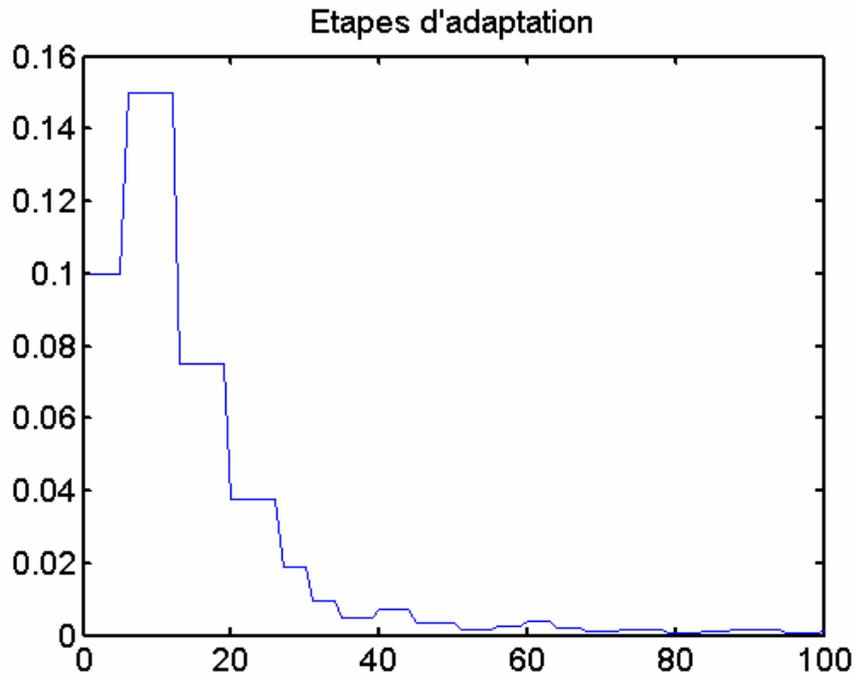


Figure 6.9 Etapes d'adaptation des paramètres d'ANFIS

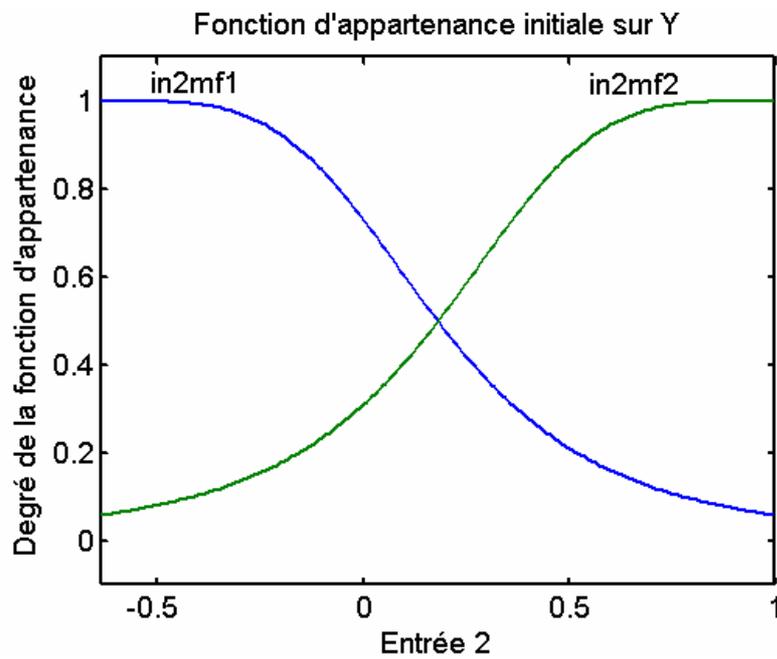


Figure 6.10.a

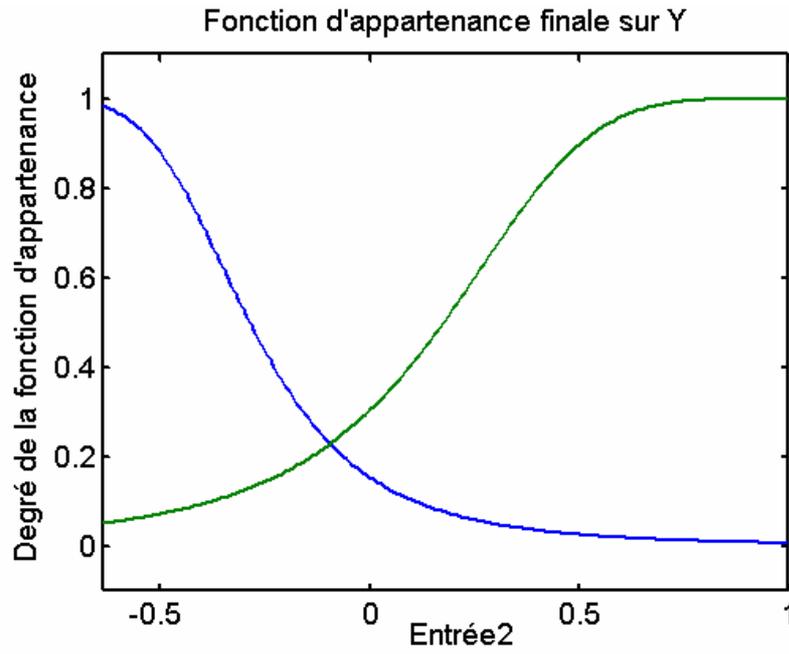


Figure 6.10.b

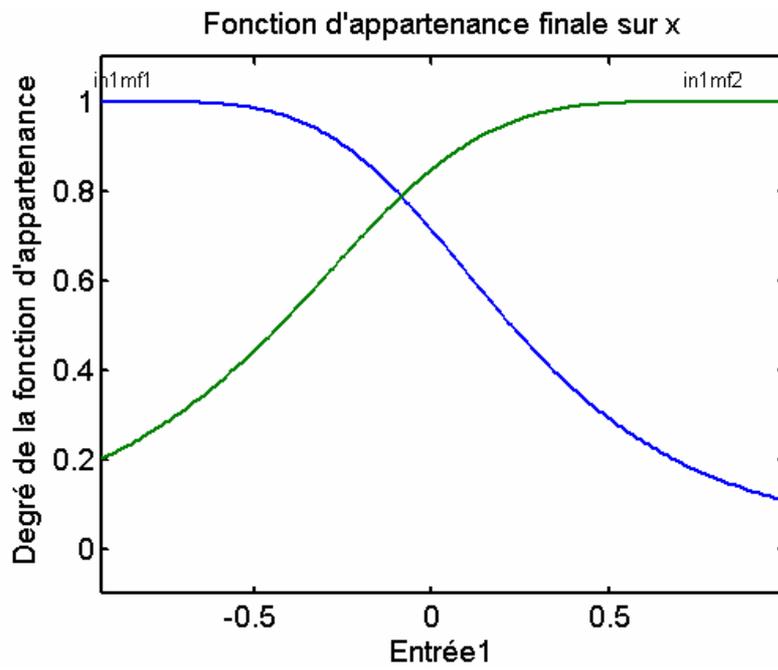


Figure 6.10.c

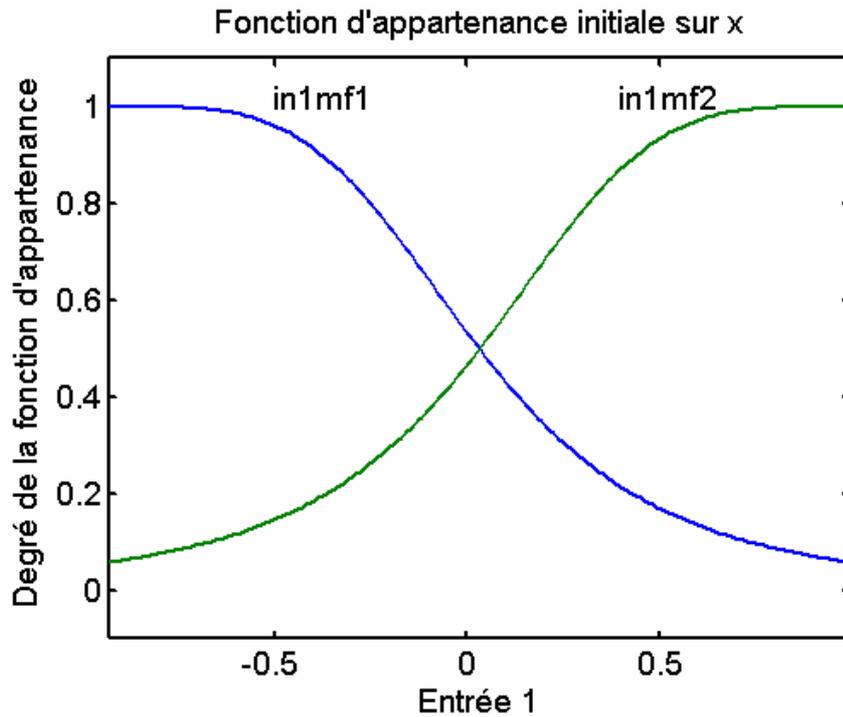


Figure 6.10.d

Figure 6.10 Fonctions d'appartenance initiales et finales des entrées 1 et 2

6.4.3 Résultats

Nous avons proposé une autre approche dans la famille des modèles de l'hystérésis statique des matériaux magnétiques basée sur la technique d'hybridation des réseaux de neurones et de la logique floue (ANFIS), les réseaux de neurones avec leurs capacités d'apprentissage, et la logique floue avec sa capacité de modélisation de connaissances imprécises. Le temps d'exécution de la phase d'apprentissage avec cette technique est très court. Le modèle proposé a été identifié par le cycle d'hystérésis généré par le modèle de Jiles-Atherton. Le jeu de données des points de mesures et leurs tailles ou ceux générés par d'autres modèles existant représente le point fort de cette technique. Les limites inhérentes de cette logique de modélisation séduiront très probablement de nombreux chercheurs dans le domaine de la modélisation des matériaux magnétique et la prise de leurs comportements complexes dans des calculs par éléments finis.

Par soucis de caractérisation et de simulation des dispositifs électromagnétiques, nous avons présentés une nouvelle approche de modélisation du cycle d'hystérésis statique basée sur une technique hybride neuronale et floue. Le modèle neuro-flou proposé combine à la fois les avantages d'apprentissage des réseaux de neurones et de la décision de la logique floue. Le cycle d'hystérésis obtenu par ce modèle reconstitue parfaitement le cycle généré par le modèle de Jiles-Atherton. Dans la section suivante, nous nous intéressons au développement d'un modèle dynamique de comportement des pièces ferromagnétiques.

Les études du comportement dynamique des systèmes magnétiques pratiques avec prise en compte du phénomène d'hystérésis sont de grande importance dans l'électrotechnique. Comme alternative aux modèles physiques et empiriques, nous allons mettre nos efforts à la recherche et au développement d'un modèle qualitatif dynamique. La construction de la structure du modèle neuro-flou recherché exige la disponibilité de données expérimentales sur des cycles dynamiques. Cependant, la difficulté de mise en place d'un dispositif expérimentale nous a fait pensé à utiliser des données générés par un modèle puissant ayant déjà fait preuve de sa puissance et de sa qualité de modélisation des cycles dynamiques. Notre choix a été fixé sur le modèle mathématique du physicien Allemand Preisach (Preisach, 1935).

6.5. Développement d'un modèle dynamique neuro-flou

6.5.1 Modèle de Preisach

Le modèle de Preisach est discuté en détail dans les références (Ouled Amor, 2000), (Brokate et al, 1996) et (Mayergoyz, 1991) sur lesquelles cette section est basée. Le modèle de Preisach représente bien le comportement du matériau magnétique. Dans ce modèle, la valeur de la magnétisation $M(t)$, ($t \geq t_0$) dépend non seulement de $M(t_0)$ mais aussi des extrema et des minima de l'entrée. Le modèle de Preisach considère une infinité d'hystérons élémentaires $\bar{\gamma}_{\alpha\beta}[H(t)]$ (figure 6.11).

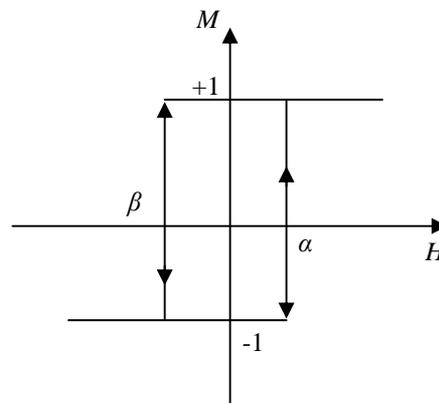


Figure 6.11: Opérateur hystérétique élémentaire

où α et β correspond aux maxima et aux minima du vecteur d'entrée ($\beta \leq \alpha$) où la sortie du modèle commute entre +1 et -1. La réponse du modèle est déterminée par la sommation des hystérons sur toutes les valeurs possibles de commutation.

$$M(t) = \iint_{\alpha \geq \beta} \rho(\alpha, \beta) \bar{\gamma}_{\alpha\beta}[H(t)] d\alpha d\beta \quad (6.29)$$

$$\bar{\gamma}_{\alpha\beta}[H(t)] = \begin{cases} +1 & \text{if } H \geq \alpha \\ -1 & \text{if } H \leq \beta \end{cases} \quad (6.30)$$

Avec $\rho(\alpha, \beta)$ est la distribution de Preisach. Elle est invariable avec l'état magnétique du matériau $M(t)$ résultant de l'application du champ $H(t)$. ils existent dans la littérature plusieurs types de fonction de distribution pouvant être employée dans le modèle de Preisach. Pour cette étude, nous avons choisi la fonction de Lorentz modifiée (Ouled Amor, 2000).

$$\rho(\alpha, \beta) = \frac{Km^2}{\left(m + \left(\frac{\alpha}{H_c} - n\right)^2\right) \left(m + \left(\frac{\beta}{H_c} + n\right)^2\right)} \quad (6.31)$$

K : coefficient de correction,
 H_c : le champ coercitif.

6.5.2 Comportement dynamique du phénomène d'hystérésis

L'effet de fréquence sur le cycle d'hystérésis est présenté par une approche phénoménologique. Elle consiste à la présentation de l'effet fréquentielle par le paramètre n de la fonction de distribution de Lorentz modifiée.

$$n_f = n_{dc} \left(1 + \varepsilon \sqrt{f^\eta}\right) \quad (6.32)$$

Avec n_f est la valeur de n à une fréquence donnée et n_{dc} est la valeur de n en statique, ε et η sont des coefficients caractéristiques. Cette approche ne peut être utilisée que si la courbe d'évaluation du champ coercitif sur la marge de fréquence étudiée et à partir de laquelle on peut identifier celle du paramètre n (figure 6.12). Malgré la contrainte d'identification et de mesure que demande cette méthode, elle présente l'avantage d'avoir le cycle d'hystérésis à une fréquence donnée à partir des paramètres prélevés sur le cycle statique et de la courbe d'évolution du champ coercitif en fonction de la fréquence.

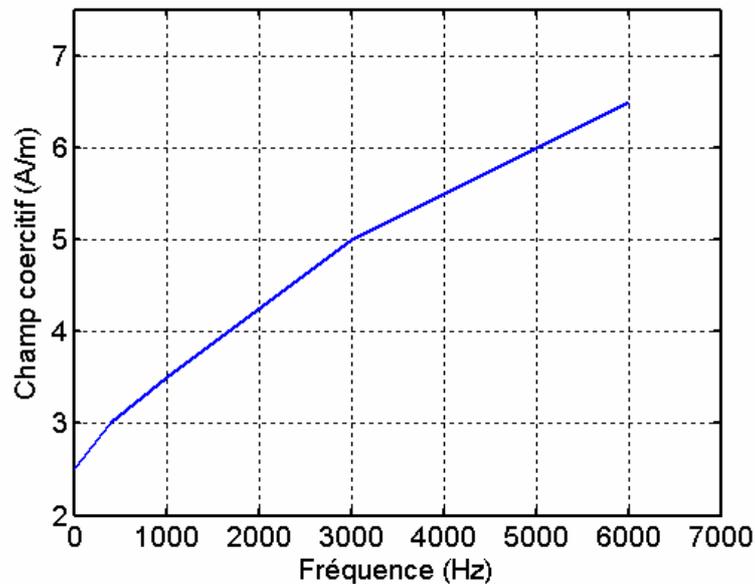


Figure 6.12 : Champ coercitif en fonction de la fréquence

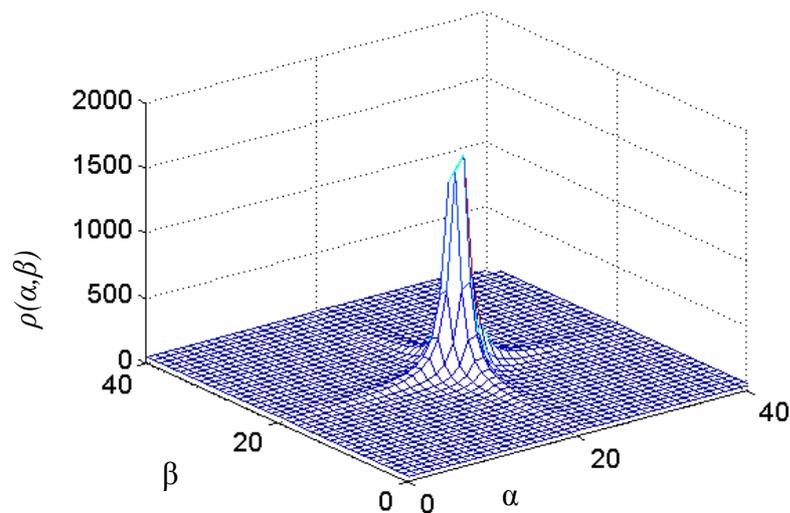


Figure 6.13: La fonction de distribution pour $K=2270$, $m=0.02$, $n=0.1$ & $H_c=55$

Les courbes mesurées ont été pris sur un cadre Epstein à l'école d'enseignement technique de Nante, en employant des tôles Fe-Si (3wt%) d'épaisseur 0.35mm, largeur 30mm et longueur 280mm. La fréquence de fonctionnement est fixé à 0.5 hertz. Les paramètres employés pour valider le modèle d'hystérésis sont : $m = 0.02$, $n = 1$, $H_c = 55 A/m$ et $K = 2270$ et pour le comportement fréquentielle $\varepsilon = 3.7 \cdot 10^{-3}$ et $\eta = 1.4$. La Fig 6.13 montre la fonction de distribution correspondante dans le plan de Preisach pour le matériau utilisé. Dans (Ouled Amor, 2000), toutes les caractéristiques physiques du matériau du dispositif expérimental utilisé pour l'acquisition de données sont largement décrites.

6.5.3 Résultats de simulation numérique

La détermination de la relation entre l'entrée et la sortie du modèle d'hystérésis se fait par les étapes suivantes:

- L'utilisation d'un échantillon de haute qualité de données expérimentales (entrée-sortie)
- Apprentissage du modèle dynamique d'hystérésis.
- Validation du modèle entraîné.

À la différence de la méthode d'identification utilisée par les réseaux neuronaux, ANFIS détermine la structure du modèle automatiquement selon les données d'apprentissage. Des techniques semblables mais différentes que celles utilisées par les réseaux de neurones, le modèle ANFIS exige deux paires de données, à savoir les données d'apprentissage et les données de validation. Les données d'apprentissage sont les paires d'entrée-sortie utilisées pour la détermination des paramètres du modèle neuro-flou (nombres de neurones utilisés, les règles floues et les fonctions d'appartenance utilisées,...etc), mais les données d'identification sont employées pour examiner les capacités de généralisation du système neuro-flou établi par les données d'apprentissage à chaque cycle. Dans ce travail, la méthodologie de modélisation consiste en une manipulation de données expérimentales des cycles dynamiques composés de 1610 paires de données $(H(t), B(t))$, 10 vecteurs d'entrées candidat pour le modèle Anfis sont employés. Après réduction du nombre effectif de points, nous avons employé les 802 premières paires comme données d'apprentissage et les 802 paires restantes pour l'identification (Mordjaoui, juin 2007),(Mordjaoui, Sep 2007). Les premières sont utilisées pour former le modèle neuro-flou recherché, tandis que le deuxième ensemble de points a été employé pour vérifier l'exactitude et l'efficacité du modèle ANFIS généré (validation du modèle neuro-flou).

Nous avons ensuite entraîné la structure ANFIS pour seulement une epoch et chaque ANFIS a quatre règles afin de déterminer le meilleur modèle avec une petite erreur de RMS par la combinaison de divers candidats.

Dans le tableau 6.1, nous pouvons voir que le modèle ANFIS avec B3 et H6 comme paires d'entrées a la plus petite erreur d'apprentissage, ainsi il est raisonnable de choisir ce modèle pour ces avantages déjà présentés. Notons que la durée de génération du meilleur modèle est 3.6250s.

Tableau 6.1 Erreur d'apprentissage et d'identification des différents modèles

Modèle	Erreur d'apprentissage	Erreur de test
model = 1: B1 H1	0.0615	0.2698
model = 2: B1 H2	0.0569	0.2680
model = 3: B1 H3	0.0537	0.2544
model = 4: B1 H4	0.0514	0.2360
model = 5: B1 H5	0.0497	0.2169
model = 6: B1 H6	0.0485	0.1990
model = 7: B2 H1	0.0444	0.1633
model = 8: B2 H2	0.0385	0.1836
model = 9: B2 H3	0.0340	0.1876
model = 10: B2 H4	0.0307	0.1813
model = 11: B2 H5	0.0282	0.1703
model = 12: B2 H6	0.0264	0.1579
model = 13: B3 H1	0.0280	0.0679
model = 14: B3 H2	0.0233	0.0945
model = 15: B3 H3	0.0194	0.1092
model = 16: B3 H4	0.0164	0.2698
model = 17: B3 H5	0.0141	0.2680
<i>model = 18: B3 H6</i>	<i>0.0124</i>	<i>0.2544</i>
model = 19: B4 H1	0.0863	0.2360
model = 20: B4 H2	0.0837	0.2169
model = 21: B4 H3	0.0818	0.1990
model = 22: B4 H4	0.0806	0.1633
model = 23: B4 H5	0.0797	0.1836
model = 24: B4 H6	0.0791	0.1876

Après la sélection du meilleur modèle adapté, nous faisant trainer le réseau ANFIS pendant 300 epochs, cependant, la courbe de convergence d'ANFIS est montré dans figure 6.14. Les paramètres optimaux ont été obtenus au moment où l'erreur de test a atteint le minimum d'erreur indiqué par un petit cercle vert.

La figure.6.15 montre la distribution des données ; elle montre que les données d'apprentissages et de test ne couvrent pas la même région. La courbe d'hystérésis dynamique désirée et la courbe générée par le modèle neuro-flou ont été montrées dans figure 6.16.

La structure d'ANFIS montrée dans figure 6.1 a été mise en application en employant le logiciel MATLAB (version 6.5 de MATLAB avec la boîte à outils de logique floue), il emploie 1604 paires de données sur 300 périodes d'apprentissages et l'étape d'adaptation des paramètres du modèle a eu une valeur initiale de 0.1.

Les étapes d'adaptations des paramètres du modèle ANFIS sont montrées dans la figure 6.17 Avec quatre fonctions d'appartenances arbitraires (le nombre de fonctions d'appartenances assignées à chaque variable d'entrée est choisi arbitrairement en examinant les données désirées d'entrée-sortie et/ou par test et le minimum d'erreur), ainsi le nombre de règle est fixé à 16, et après la durée de simulation de 66.1720s pour l'apprentissage et les données de validation pour 300 périodes, l'erreur de formation du modèle était 0.0012 et celle du test est 0.0806.

La figure 6.18 présente les fonctions d'appartenances initiales et finales de la première et de la deuxième entrée en utilisant une fonction bell-shaped.

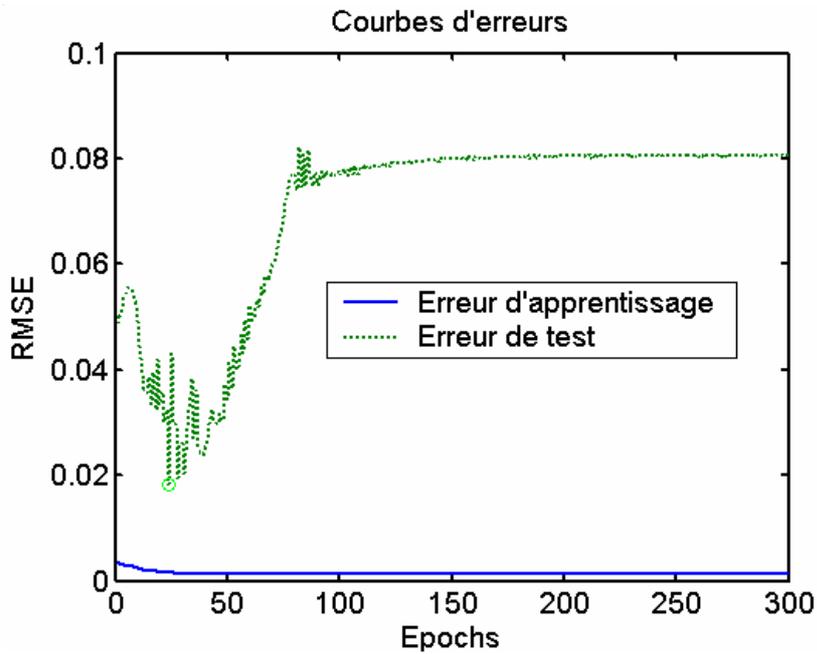


Figure 6.14 performance d'Anfis

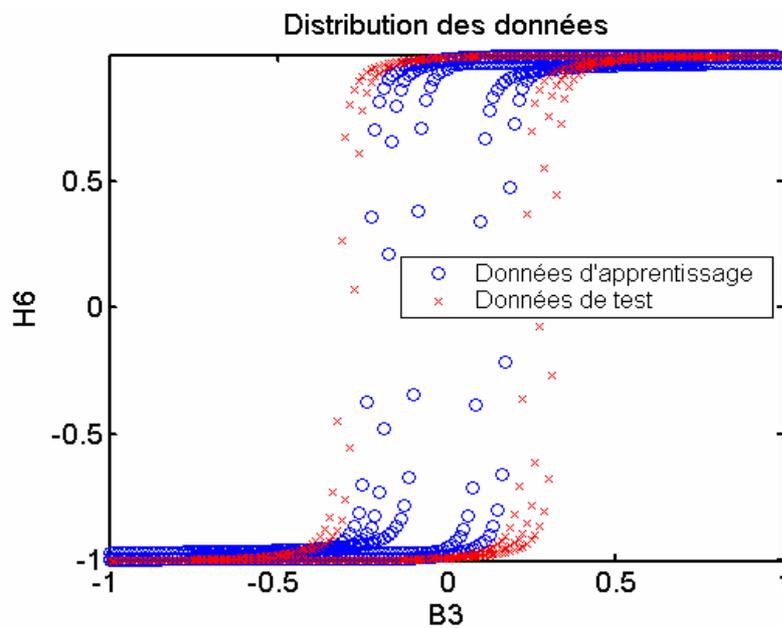


Figure 6.15 Distribution des données

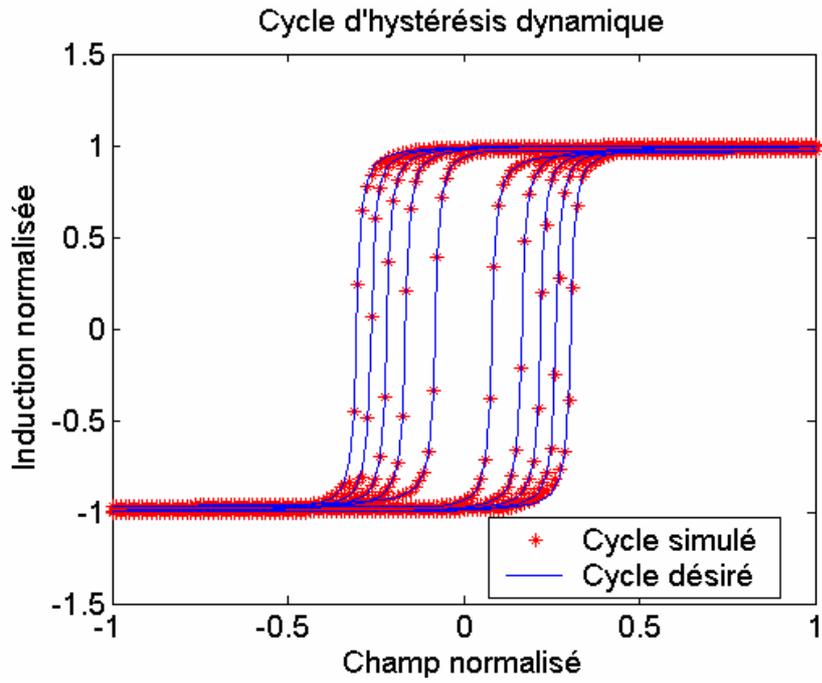


Figure 6.16 Hystérésis dynamique généré par le modèle ANFIS et la courbe d'hystérésis désirée.

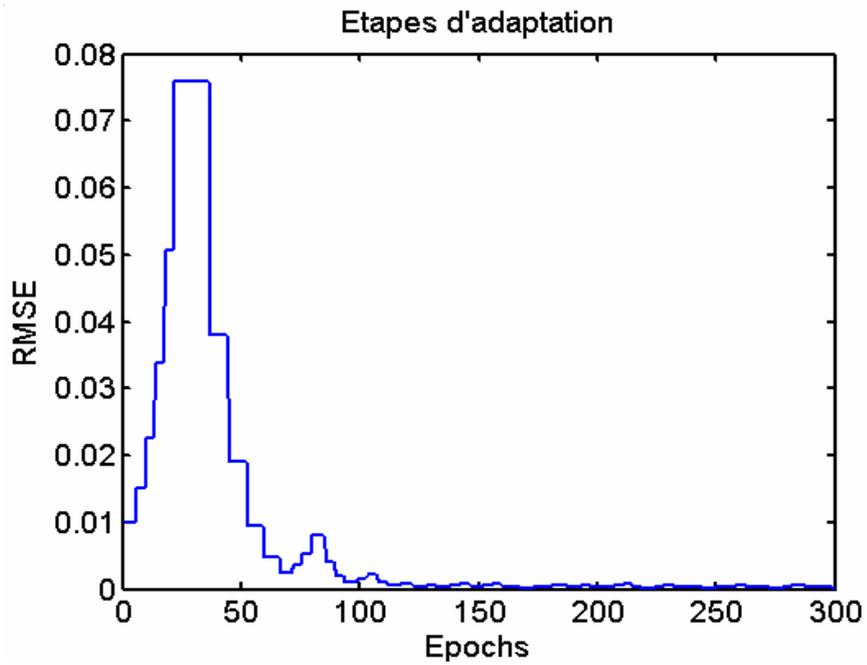
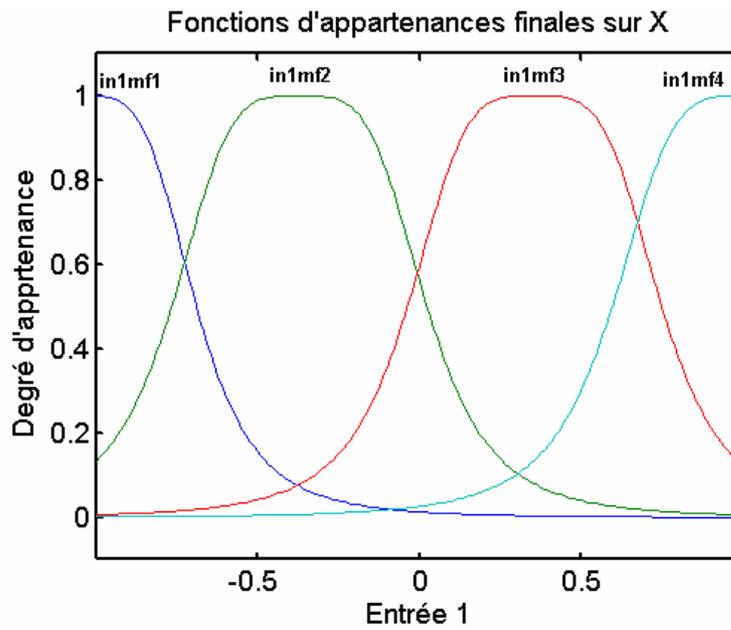
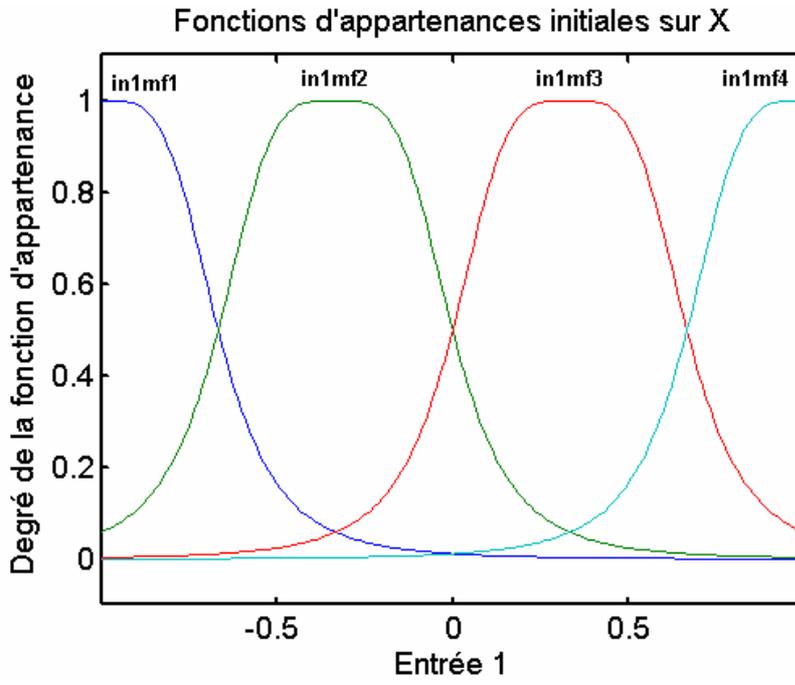


Figure 6.17 Adaptation des paramètres de Anfis



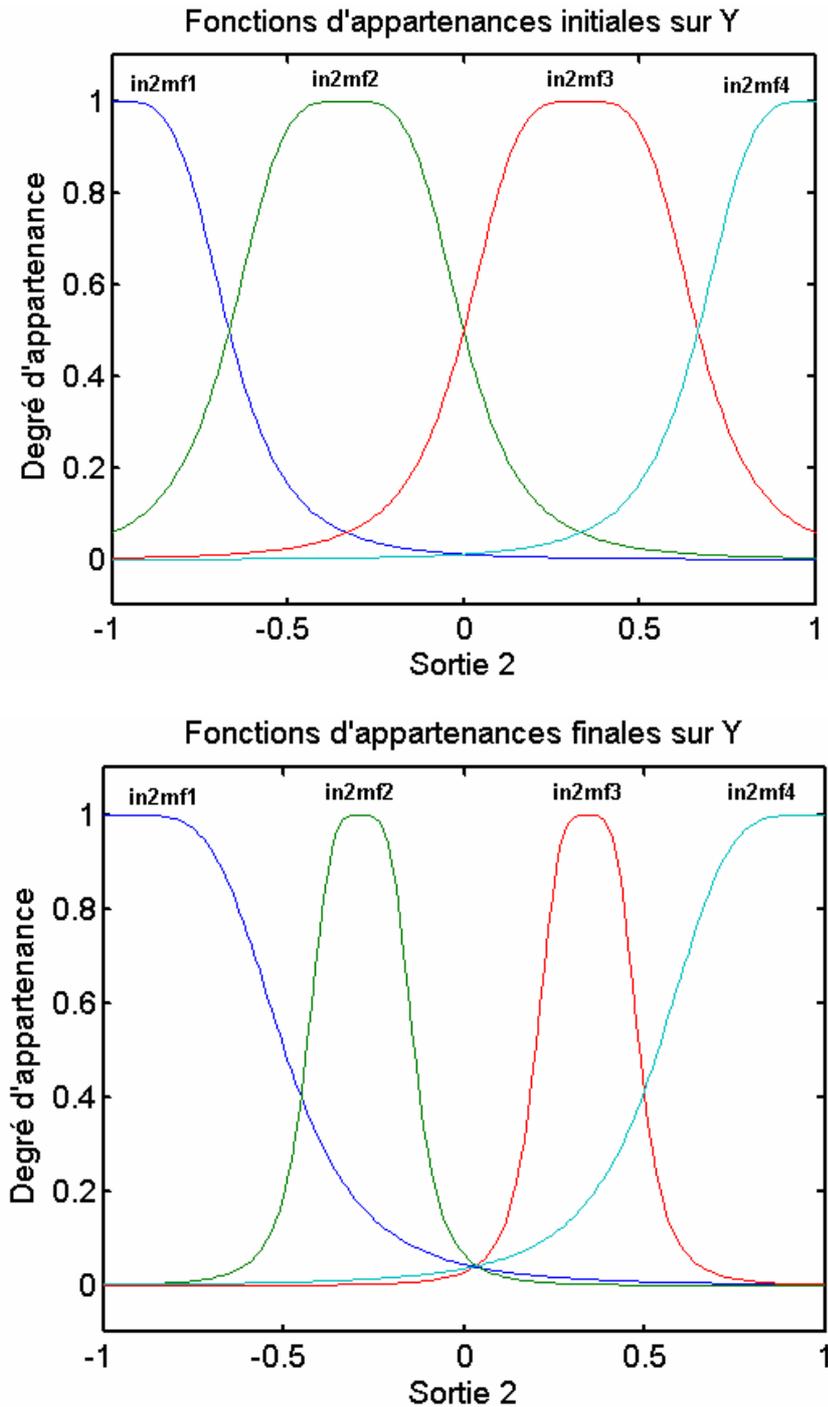


Figure 6.18 Fonctions d'appartenance Initiales et finales. (a) première entrée (b) Deuxième entrée du meilleur modèle.

Le modèle ANFIS utilisé ici contient un total de 72. paramètres, dont 24 sont les paramètres des prémisses (non-linéaires) et 48 sont des paramètres conséquents (linéaires).

Le tableau 6.2 récapitule toutes les caractéristiques du réseau utilisé.

Table 6.2 Caractéristiques du modèle Neuro-flou

Nombre de neurones	53
Nombres de paramètres des prémisses	24
Nombre des paramètres conséquents	48
Nombre total des paramètres	72
Nombre des paires de données d'apprentissages	802
Nombre des paires de données de test	802
Nombres des règles floues	16

6.5.4 Discussion des résultats et conclusion

Les résultats de validations et les différentes courbes présentées montre clairement que nous avons réussi à développer un modèle neuro-flou dynamique pour les dispositifs ferromagnétiques. Les courbes générées par simulation indique que le modèle neuro-flou était capable de reproduire d'une manière exacte le cycle d'hystérésis généré par le modèle de Preisach dynamique. Nous avons montré qu'après apprentissage et test du modèle, que ce dernier prédit le comportement dynamique du matériau utilisé avec une minimum d'erreur. Par conséquent, le modèle proposé peut être facilement employé dans l'analyse et le calcul du champ par la méthode des éléments finis des structures électromagnétiques.

Conclusion générale

Conclusion générale

Conclusion générale

Les travaux présentés dans ce mémoire s'articulent autour du thème de la modélisation du comportement des matériaux magnétiques et en particulier le phénomène d'hystérésis. Ces travaux sont basés sur l'utilisation des techniques de l'intelligence artificielle. Dans la première partie de nos travaux, nous nous sommes intéressés aux matériaux magnétiques et à l'interprétation de leurs comportements dans le cas de l'application d'un champ magnétique. Une classification de ces matériaux et une description détaillée du phénomène d'hystérésis ont été décrites. Nous avons également positionné le problème de la modélisation de l'hystérésis et son importance en génie électrique.

Dans le deuxième chapitre, une étude bibliographique a été faite sur les différents modèles analytiques et numériques de l'hystérésis magnétique et nous avons présenté en détail le modèle historique du physicien Allemand Preisach.

Nous avons ensuite présenté les fondements théoriques de la logique floue et des réseaux de neurones ainsi que les réseaux hybrides neuro-flous. En effet, au cours des dernières années la discipline a évolué d'une façon graduelle vers une utilisation pratiquement exclusive des systèmes flous et neuro-flous dans lesquels le conséquent des règles utilise des variables numériques sous formes de fonction plutôt que des variables linguistiques. Ensuite, dans le cadre de ce travail, nous avons présenté les différents systèmes neuro-flous actuellement employés dans de nombreux domaines industriels. En effet, ces systèmes sont utilisés principalement lorsque le modèle mathématique du système physique étudié est difficile à élaborer. Ils exploitent des règles floues tirées d'une expertise humaine pour modéliser le comportement dynamique du système. Ce sont une des catégories de systèmes hybrides les plus développées. Nous avons également présenté les différents algorithmes de groupage associés aux systèmes neuro-flous hybrides, la mise en place des techniques d'apprentissages à partir des données mesurées et des techniques d'induction des règles.

A partir des propriétés d'approximation des fonctions par des réseaux de neurones multicouches à propagation directe, nous avons proposé un modèle d'hystérésis quasi-statique validé par le modèle décrit dans les travaux de Nakmahachalasint. La précision du modèle augmente avec l'utilisation d'un très grand nombre de données entrée-sortie.

Pour la construction de modèles flous, nous avons abordé plusieurs algorithmes de classifications floues tels que l'algorithme FCM (clusters hypersphériques), l'algorithme GK (clusters hyperellipsoïdaux), l'algorithme de Gath et Geva et enfin l'algorithme d'expertation-Maximisation (EM). Les résultats montrent qu'un bon apprentissage ne donne forcément pas une bonne validation, cependant, l'intervention de l'expert reste indispensable pour pouvoir obtenir de bons résultats.

Au sixième chapitre, nous avons réussi à mettre en évidence un modèle d'hystérésis statique généralisé au comportement dynamique des matériaux ferromagnétiques par utilisation d'un système neuro-flou adaptative. Les résultats obtenus montrent une très grande corrélation avec le modèle dynamique de Preisach. Le jeu de données des points de mesures et leurs tailles ou ceux générés par d'autres modèles existants représente le noyau de cette technique. Les limites inhérentes de cette logique de modélisation séduiront très probablement de nombreux chercheurs dans le domaine de la modélisation des matériaux magnétique et la prise de leurs comportements complexe dans des calculs éléments finis.

Nous considérons à présent, par la suite quelques-unes des perspectives qui nous semble les plus intéressantes à étudier :

- L'extension des techniques intelligentes et en particulier les systèmes adaptatifs aux développements de modèles vectoriels de l'hystérésis magnétique qui tient en compte de l'anisotropie du matériau.
- Implantation de ces modèles intelligents dans des codes de calculs éléments finis pour l'étude des performances des dispositifs utilisés en génie électrique.

Références bibliographiques

Références bibliographiques

Références bibliographiques

Abonyi. J (2003), *Fuzzy Modeling Identification for Control*. Birkhäuser, Boston.

Abraham. A (2005), Adaptation of Fuzzy Inference System Using Neural Learning, StudFuzz 181, 53–83

Abraham. A (2001), Neuro-Fuzzy Systems: State-of-the-art Modeling Techniques. In J. Mira and A. Prieto (Eds), *Connectionist Models of Neurons, Learning Processes, and Artificial Intelligence*, Springer-Verlag, pp. 269-276.

Adly. A. A and Abd-El-Hazif. S. K (1998), Using Neural Networks in the Identification of Preisach-Type Hysteresis Models. *IEEE Trans. on Magn.*, vol.34, pp. 629-635.

Adly. A. A, Mayergoz. I. D (1997), Accurate modeling of vector hysteresis using a superposition of Preisach type models”, *IEEE Transactions on Magnetics*, vol. 33(5): p. 4155-4157.

Akbaba (1991), A modified Frölich's type equation for accurate modeling of magnetizing characteristics of magnetic cores. *Electrical Machines and Power Systems*, Vol.19, pp 303-311.

Alfredo de blas del hoyo (2005), Modélisation de l'hysteresis magnétique et son implantation dans le calcul numérique des machines électriques. Thèse en Espagnole. Université polytechnique de Barcelona.

Amir. N (2002), Modélisation de l'hystérésis dans les matériaux magnétiques et introduction de modèles dans le logiciel de simulation aux éléments finis Flux 3D. Thèse de l'INPG, Génie électrique, Grenoble.

Arbaoui. F (2006), Architectures neuro-floues pour identification et commande de bras manipulateurs. Thèse de doctorat d'état. Université Badji Mokhtar Annaba.

Azzerboni. B, Carpentieri. M, Finocchio. G, Ipsale. M and La Foresta. F (March-April 2003), Fuzzy Approach to Modeling Scalar Hysteresis. *Proceedings of the IEEE International Magnetism Conference*, Boston, MA, USA.

Babuska. R, Roubos. J. A. Verbruggen. H. B (1998), Identification of MIMO systems by input-output TS models. *IEEE International Conference on Fuzzy Systems*, Anchorage, USA, vol.1, pp.657-662.

Babuska R (1995), *Fuzzy toolbox for matlab. Reference guide (Version 3.0)*, delft University of technologie, Delft, the Netherlands.

Babuska. R (2002), *Fuzzy modeling and identification toolbox. Users guide*. Control Engineering Laboratory, Faculty of Information Technology and Systems, Delft University of Technology, Delft, The Netherlands, version 3.3, ed. 2002 (Available at

<http://www.dcsc.tudelft.nl/~babuska/>).

Balasko. B, Abonyi. J et Balazs. L , Fuzzy clustering and data analysis toolbox for use with matlab.

Beattie. J. R (1989), Computer modelling of the magnetic behaviour of selected ferromagnetic and ferrimagnetic materials. Tesis doctoral. Queen's University. Kingston, Ontario.

Benabou. A (2002), Contribution à la caractérisation et à la modélisation de matériaux magnétiques. INP Lille, Thèse de Doctorat / Génie Electrique.

Bensaid. A.M, Hall, L.O., Bezdek. J, Clarke, L.P, Silbiger, M.L, Arrington, J.A.

Murtagh, R.F (1996), Validity-guided (re)clustering with applications to image segmentation, *IEEE Transactions on Fuzzy Systems*, vol.4, pp.112-123.

Bergqvist. A.J, Lundgren. A, Engdahl. G (1997), Experimental testing of an anisotropic vector hysteresis model. *IEEE Transactions on Magnetics*, vol. 33(5): p. 4152-4154.

Bernard. Y, Mendes. E, Bouillault. F (2001), Dynamic hysteresis modeling based on Preisach's model", conférence Compumag 13ème, Evian France.

Bertotti, (1998) Hysteresis in magnetism. Academic Press. San Diego, 1998.

Bertotti. G, Basso. V, Pasquale. M (1993), Application of the Preisach Model to the calculation of magnetization curves and power losses in ferromagnetic materials. *IEEE Transactions on Magnetics*.

Bezdek. J. C (1980), A convergence theorem for the fuzzy isodata clustering algorithms, *IEEE Transactions on Pattern Analysis and Machine Intelligence- PAMI*, vol.2, n1, pp.1-8.

Bezdek. J. C (1981), Pattern Recognition with Fuzzy Objective Function. Plenum Press, New York.

Bezdek J. C et Dunn. J. C (1975), Optimal fuzzy partitions: A heuristic for estimating the parameters in a mixture of normal distributions. *IEEE Transactions on Computers*, pages 835-837.

Biorci. B, Pescetti, Nuovo Cimento (1958), 7, p.830

Bishop. C. M (1995), Neural Networks for Pattern Recognition. Oxford University Press, Oxford.

Boucheron. S (1992), théorie de l'apprentissage, Edition Hermès science.

- Bossavit. A, Bouillart. F, Chaussecourte. P, Ossart. F (1995)**, Modélisation numérique en électrotechnique, calcul des champs, modélisation des machines et des matériaux. Document de cours
- Bosq. D, Lecontre. J. P (1987)**, Théorie de l'estimation fonctionnelle. Edition: Economica Paris
- Bottauscio. O, Chiampi. M, Chiarabaglio. D, Ragusa. C, Repetto. M (...)**, ferromagnetic hysteresis and magnetic field analysis ISC newsletter Technical article pp 3-7
- Bozorth, R. M. (1978)**, Ferromagnetism. IEEE Press, ISBN 0-7803-1032-2.
- Brissonneau. P (1997)**, Magnétisme et matériaux magnétiques. Hermès.
- Brokate. M, Sprekels. J (1996)**, Hysteresis and Phase Transitions. New York: Springer-Verlag,
- Brown. W. F (1940)**, Theory of the approach to magnetic saturation. Physical Review, vol. 58: p. 736-743.
- Brown. W. F (1941)**, The effect of dislocations on magnetization near saturation. Physical Review, vol. 60: p. 139-147.
- Buckley. J. J et Hayashi. Y (1994)**, Fuzzy neural networks : A survey. Fuzzy sets system. Vol : 66, pp : 1-13.
- Burel G (1991)**, Réseaux de neurones en traitement d'images: des modèles théoriques aux applications industrielles, Thèse de doctorat de l'université de Bretagne occidentale.
- Chevalier, T (1999)**, Modélisation des pertes fer dans les machines électriques/ Application à la machine asynchrone. INPG/ENSIEG/LEG, Grenoble, Thèse de Doctorat / Génie électrique.
- Chevalier, T et al (2000)**, A new dynamic hysteresis model for electrical steel sheet. Physica B, vol. 275: p. 197-201.
- Chikasumi. S (1997)**, Physics of Ferromagnetism. Oxford university Press.
- Chikazumi, (1964)** Physics of magnetism. Wiley and Sons. New York, 1964
- Claude. T (1992)**, les réseaux de neurones artificiels, introduction au connexionnisme, cours, exercices et travaux pratiques.
- Comon. P (1991)**, "Classification supervisée par des réseaux multicouches", Traitement du signal, Vol. 6, n° 6, p. 387-407.

Cottrell M., Girard b., Girard Y., Mangears M (1993), Times series and neural network: a statistical method for weight elimination. 1st European symposium on artificial neural networks, Brussels (Belgique), D facto Editeur, p. 157-64.

Craik y Tebble, (1965), Ferromagnetism and ferromagnetic domains. Wiley and Sons. New York.

Daniel. R (2006), Contribution à la surveillance des systèmes de production en utilisant les techniques de l'intelligence artificielle. Rapport d'habilitation à diriger des recherches, université de Franche-Comté de Besançon.

Del vicchio. P, Salvini. A (2000), Neural networks and Fourier descriptor macromodeling dynamic Hysteresis. IEEE Trans. Magn., vol. 36, pp. 1246–1249.

Della Torre. E (1998), A Preisach approach to magnetic viscosity. IEEE trans mag. Vol: 34 pp. 1276-1278.

Della torre. E, Yanick. L, Emre Yarimbiyik. A, Michael Donahue. J (2004), Differential Equation model for accommodation magnetization. IEEE Trans. Magn vol. 40, pp 1499-1505

Demirli. K and Muthukumaran. P (2000), Fuzzy System Identification with Higher Order clustering. Journal of Intelligent and Fuzzy Systems, Vol. 9, No. 3-4, pp. 129-158.

Dimitré M, Dupre´. L, De Wulf. M and Melkebeek. J (2001a), modeling of quasistatic hysteresis with feed-forward neural networks ", Journal of applied physics, volume 99, N° 11, pp 6737-6739.

Dimitré M, Dupre´. L, De Wulf. M and Melkebeek. J (2002), J. Appl. Phys. **91**, 8322 .

Dimitré M, Maes. J et Melkebeek. J (2001b), IEEE Trans. Magn. **37**, 2740.

Dimitre Makaveev, Luc Dupre´ , Marc De Wulf, and Jan Melkebeek (2003), Combined Preisach–Mayergoyz-neural-network vector hysteresis model for electrical steel sheets. Journal of applied physics, volume 93, N° 10, pp 6638-6640.

Dunn, J (1974), A fuzzy relative to ISODATA process and its use in detecting compact well separated clusters, Journal of Cybernetics, vol.3, n3, pp.32-57.

Dupré. L. R, Gyselinck. J. J, Melkebeek. J. A (1998), Complementary Finite Element Method in 2D magnetics taking into account a vector Preisach Model", IEEE Transactions on Magnetics, vol. 34(5): p.3048-3051.

Dupré. L. R, Van Keer. R, Melkebeek. J.A (1997), An iron loss model for electrical machines using the Preisach Theory", IEEE Transactions on Magnetics, vol. 33(5): p. 4158-4160.

- Durant. E (1968)**, Magnétostatique, Edition Masson et C^{ie}.
- Fraisse. H et al (1995)**, Modeling of a non-linear conductive magnetic circuit. Part 2: bond graph formulation. IEEE Transactions on Magnetics, vol. 31(6): p. 4068-4070.
- Francisco Riganti Fulginei and Alessandro Salvini (Marsh 2005)**, Soft computing for the identification of the Jiles-Atherton Model Parameters. IEEE Transactions on Magnetics, vol. 41, no. 3, pp.1100-1108.
- Friedberg. R, Paul. D.I (1975)**, New Theory of coercive force of ferromagnetic materials”, Physical Review Letters, vol. 34(19): p. 1234-1237.
- Friedman. G, Cha. K, Huang. Y and Kouvel. J (2000)**, IEEE Trans. Magn. 36,3185.
- Gath and Geva (1989)**, Unsupervised optimal fuzzy clustering IEEE Transactions on Pattern Analysis and Machine Intelligence 7: pp. 773-781.
- Grisales. P. V. H (2007)**, Modélisation et commande floues de type Takagi-Sugeno appliquées à un bioprocédé de traitement des eaux usées. Thèse de doctorat de l’université Paul Sabatier –Toulouse III et l’université de Los Andes Colombie.
- Goodenough. J.B (1954)**, A Theory of domain creation and coercive force in polycrystalline ferromagnetics”, Physical Review, vol. 95(4): p. 917-932.
- Gustafson. D.E., Kessel. W.C (1979)**, Fuzzy clustering with a fuzzy covariance matrix, Proceedings of the IEEE CDC, San Diego, CA, USA, pp.761-766.
- Hakan. S (2001)**, Design of Powder Core Inductors. Licenciante thesis, Lund university
- Hayashi. Y et Buckley. J. J (1994)**, Approximations between fuzzy expert systems and neural networks, International Journal of Approximate Reasoning, 10. 63-73.
- Hebb D.O (1949)**, The Organisation of the Behaviour. Wiley, New York.
- Hervé. R (2004)**, Construire un modèle flou par classification floue. Rapport final, Stage de fin d’études. Ecole nationale supérieure d’électricité et de mécanique de l’institut national polytechnique de Lorraine.
- Hodgdon. M. L (1988)**, Mathematical Theory and Calculations of Magnetic Hysteresis Curves. IEEE Trans. on Magnetics, Vol. 24, pp. 3120-3122.
- Hollaus. K, Birò. O (2002)**, Derivation of a complex permeability from the Preisach model. IEEE Transactions on Magnetics, vol. 38(2): p. 905-908.
- Hong. S. K, Kim. H. K, Jung. H. K (1998)**, Formulation of the Everett function using least square method. IEEE Transactions on Magnetics, vol. 34(5): p. 3052-3055.

- Horváth. G (1995)**, Neural Networks with Technical Applications (Hungarian). Mûgyetemi Kiadó.
- Ivanyi. A (1997)**, Hysteresis models in electromagnetic computation. Akadémiai kiadó, Budapest, Hungary.
- Jang J. S (1992)**, Self-learning fuzzy controllers based on temporal backpropagation. IEEE Trans Neural Network, 3 (5):714–723.
- Jang J. S. R (1993)**, Anfis : Adaptive-network based fuzzy inference system, IEEE Transactions on systems, Man, and Cybernetics, Vol.23 pp. 665-685.
- Jang. J. S, Sun. C. T (March 1995)**, Neuro-Fuzzy Modeling And Control. Proceeding of the IEEE, vol.83, No.3.
- Jang. J. S, Sun. C. T and Mizutani. E (1997)**, Neuro-Fuzzy and Soft Computing. Prentice Hall.
- Jiles, D. C (1998)** Introduction to magnetism and magnetic materials. (2^a Edition). Chapman & Hall, London.
- Jiles, D. C., Atherton, D. L. (1983)**, "Ferromagnetic hysteresis", *IEEE Transactions on Magnetics*, vol. 19, no. 5, pp. 2183-2185.
- Jiles, D.C, Atherton. D.L (1986)**, Theory of Ferromagnetic Hysteresis. Journal of Magnetism and Magnetic Materials, vol. 61: p. 48-60.
- Jiles. D. C (1991)**, Introduction to Magnetism and Magnetic Materials. Chapman et Hall.
- Jufer, Apostolides (1976)**, An analysis of eddy current and hysteresis losses in solid iron based upon simulation of saturation and hysteresis characteristics. IEEE Transactions on Power Applications and Systems, Vol.95, No.4, pp 1786-1794.
- Khodja, L (1997)**, Contribution à la classification floue non supervisée. Thèse de Doctorat de l'Université de Savoie, France.
- Kosko B.(1992)**, Neural networks and fuzzy systems: A dynamical systems approach to machine intelligente, Engelwood Cliffs.
- Kosko. B (1992)**, Fuzzy systems as universal approximators. Proc IEEE Int Conf on Fuzzy Systems, San Diego, CA, 1153–1162.
- Kosko. B (juin,1992)**, Fuzzy function approximation. Proceedings of the international joint conference on neural networks, Baltimore, Maryland. Vol. 1, pp. 209-213.

Kuczmann. M, Iványi. A (2001), Scalar Hysteresis Model Based on Neural Network. IEEE International Workshop on Intelligent Signal Processing, Budapest, Hungary, May 24-25, pp.143-148.

Kuczmann. M, Iványi. A (2002), Neural Network Based Vector Hysteresis Operator, *Proceedings of the Tenth Biennial IEEE CEFC*, Perugia, Italy, June 16-19, p.259.

Kuczmann. M, Iványi. M (2002), Neural Network Model of Magnetic Hysteresis. *Compel*, vol.21, no.3, pp. 364-376.

Kuczmann. M, Iványi. M (Mars 2002), A New Neural-Network-Based Scalar Hysteresis Model. *IEEE Trans. on Magn.*, vol.38, no.2, pp. 857-860.

Landman. D and Britcher. C. P (2001), Experimental Investigation of Multielement Airfoil Lift Hysteresis due to Flap Rigging. *Journal of Aircraft*, vol. 38, no. 4, pp. 703-708.

Laure-Line Rouve (1996), Prise en compte du comportement magnétique fréquentiel des tôles FeSi en modélisation électrotechnique. Thèse de doctorat, Institut national polytechnique de Grenoble.

Lee, G. et J.-S. Wang (2001). Efficient Neuro-Fuzzy Control Systems for Autonomous Underwater Vehicle Control, *IEEE International Conference on Robotics and Automation*, Seoul, Corée.

Ljung. L (1997), System identification. Theory for the user. Prentice Hall. New York.

Ljung. L et Glad. T (1994), Modeling of dynamic systems. Prentice Hall, New Jersey.

Lorquet. V (1992), Etude d'un codage semi-distribué adaptatif pour les réseaux de neurones multicouches Application au diagnostic, à la modélisation et à la commande, Thèse de doctorat de L'ENST Paris.

Mariela. C.L (2003), Sur les modèles flous adaptatifs dynamiques. Thèse de doctorat de L'INSA de Toulouse.

Marthouret. F, Masson. J.P, Fraisse. H (1995), Modeling of a non-linear conductive magnetic circuit. Part 1: Definition and experimental validation of an equivalent problem. *IEEE Transactions on Magnetics*, vol. 31(6): p. 4065-4067.

Maurizio Cirrincione, Rosario Miceli, Giuseppe Ricco Galluzzo and Marco Trapanese (Sep 2002), Preisach Function Identification by neural networks. *IEEE Transactions on Magnetics*, vol. 38, no. 5, pp.2421-2423.

Mayergoyz, Abdel-Kader, Emad (1984), On penetration of electromagnetic fields into non linear conducting ferromagnetic media. *Journal of Applied Physics*. Vol.53, pp 618-629.

Mayergoyz. I. D (1991), Mathematical Models of hysteresis. Springer-Verlag. New york.

Mayergoyz. I. D, Adly. A. A, Friedman. G (1990), New Preisach type models of hysteresis and their experimental testing”, Journal of Applied Physics, vol. 67(9): p. 5373-5375.

Mayergoyz. I. D, Friedman. G (1987), Isotropic vector Preisach model of hysteresis. Journal of Applied Physics, vol. 61(8): p. 4022-4024.

Mayergoyz. I. D, Friedman. G (1988), Generalized Preisach Model of Hysteresis. IEEE transactions on Magnetics, vol. 24(1): p. 212-217.

Mayergoyz. I.D (1986), Mathematical models of hysteresis. Phys. Rev. Letters 56.

Mordjaoui. M, Chabane. M, Boudjema. B et Daira. R (2007), Qualitative ferromagnetic hysteresis modeling’, Journal of computer science, volume 3(6), pp: 399-405.

Mordjaoui. M, Chabane. M, Boudjema. B (Sep 2007), Qualitative modelling for dynamic magnetic Hysteresis. International Aegean Conference on Electrical Machines and Power Electronics and Electromotions Joint Conference, Bodrum-Turkey.

Mordjaoui. M, Chabane. M, Boudjema. B et Daira. R (Mai 2007), Qualitative Modelling for ferromagnetic hysteresis cycle’, XXI international conference on computer, electrical, and systems science, and engineering, pp 411-417, Vienna Austria.

Mordjaoui. M, Chabane. M, Boudjema. Daira. R (2007), Qualitative Modelling for ferromagnetic hysteresis cycle’, International journal of electrical, computer and systems engineering, volume: 01 N° 01 pp 50-56.

Mordjaoui. M, Chabane. M, Boudjema (Juin 2007), Dynamic Magnetic Hysteresis Modeling With an adaptive Neuro Fuzzy Inference System International Journal of Computational Cognition. Vol.5 N°2. (<http://www.ijcc.us>).

Mueller. T. J (SEP 1985), The Influence of Laminar Separation and Transition on Low Reynolds Number Airfoil Hysteresis. Journal of Aircraft, vol. 22, no. 9, pp. 763-770.

Narendra K., Pathasarathy K (1991), Gradient methods of optimization of dynamical systems containing neural networks. IEEE Trans. On neural networks Vol 2, 2, p. 252-62.

Nasar S.A, Xiong F.U (1994), Eddy-current losses in a tubular linear induction motor. IEEE Transactions on Magnetics, Vol.30, N° 4, pp 1437-1445.

Néel. L (1944), Les lois de l'aimantation et de la subdivision en domaines élémentaires d'un monocristal de Fer. Journal de Physique et le Radium, Tome 5, série 8(11): p. 241-251.

Olivier Maloberti (2006), Contribution à la modélisation de la dynamique d'aimantation dans les matériaux magnétiques doux. Caractérisation et simulation. Thèse de L'INP Grenoble.

Ouchtati. S (2007), Segmentation et reconnaissance des chaînes numériques manuscrites. Thèse de doctorat en science. Université Badji Mokhtar. Annaba

Ouled Amor. Y (2000), Contribution à la Modélisation de l'Hystérésis Magnétique en vue de l'Analyse par Éléments Finis des Systèmes de Chauffage par Induction. (Thèse de Doctorat), Université de Nantes, France.

Ouled Amor. Y, Alves. F, Féliachi. M (2000), Modeling of magnetic hysteresis with modified Lorentzian function. CEFC'2000 juin 4 -7.

Paibon. N, Khai. D. T. Ngo et Loc. Vu-coq (2002), A static hysteresis model for power ferrite. IEEE TRANSACTIONS ON POWER ELECTRONICS, VOL. 17, NO. 4. pp. 453-460.

Pal, N. et J. Bezdek (1995). On cluster validity for fuzzy C-means model, *IEEE Trans.Fuzzy syst.*, Vol 3.

Park. G.S, Kahn. S.Y (1993), Implementation of hysteresis characteristics using the Preisach model with M-B variables. IEEE Transactions on Magnetics, vol. 29(2): p. 1542-1545.

Piecuch. M (2007), les matériaux magnétiques: de la boussole à l'électronique de spin. Site internet http://www.canal-u.education.fr/themes_1/sciences_fondamentales/physique/

Preisach, F. (1935), "Über die magnetische nachwirkung", Zeitschrift für Physik, vol. 94, N°. 5-6 pp. 277-302.

Raulet. M.A et al (2000), Test of the sample geometry independence of a dynamic hysteresis behavioral model of magnetic materials. Journal of Magnetism and Magnetic Materials, vol. 215-216: p. 620-622.

Raulet. M.A et al (2004), The Magnetic Field Diffusion equation Including Dynamic Hysteresis. IEEE Transactions on Magnetics, vol. 42(2): p. 872-875.

Raulet. M.A, Masson. J.P, Gaude. D (1998), Introduction d'une représentation dynamique de matériau dans l'équation de diffusion du champ magnétique", European Physical Journal of Applied Physics, vol. 1: p. 73-76.

Rodbell. D.S, Bean. C.P (1956), Some properties of the coercive force in soft magnetic materials”, Physical Review, vol. 103(4): p. 886-891.

Rosenblatt F (1960), Perceptron Simulation Experiment », Proc of the IRE, 3, 48.

Ruspini. E (1969), A new approach to clustering, Information and Control, vol.15, pp.22-32.

Saghafifar. M, Kundu. A and Nafalski. A (2002a), Dynamic magnetic hysteresis modeling using Elman recurrent neural network. International Journal of Applied Electromagnetics and Mechanics, IOS Press, Amsterdam, vol. 13, pp.209-214.

Saghafifar. M, Kundu. A and Nafalski. A (2002b), Dynamic magnetic hysteresis modeling using Elman recurrent neural network. International Journal of Applied Electromagnetics and Mechanics, IOS Press, Amsterdam, vol. 13, pp.209-214.

Saghafifar. M, Nafalski. A (2001), An improved model of magnetic Hysteresis. Japan Society of Applied Electromagnetics and Mechanics (JSAEM) Studies in Applied Electromagnetics and Mechanics, vol. 11, pp. 145-150.

Saghafifar. M, Nafalski. A (2002), Magnetic hysteresis modelling using dynamic neural networks. Japan Society of Applied Electromagnetics and Mechanics (JSAEM) Studies in Applied Electromagnetics and Mechanics, vol. 14, JSAEM, Kanazawa, Japan, pp.293-299.

Saint-Jean. B (1976), Electrotechnique et machines électriques, Edition Eyrolles, France.

Saliah. H. H, Lowther. D. D (1997), A Neural Network Model of Magnetic Hysteresis for computational magnetics. IEEE Trans. Magn., vol 33, N° 05, pp 4146-4148.

Salvini. A and Fulginei. F. R (March 2002), Genetic Algorithms and Neural Networks Generalizing the Jiles-Atherton Model of Static Hysteresis for Dynamic Loops. IEEE Transactions on Magnetics, vol. 38, no. 2, pp. 873-876.

Salvini. A, Coltelli. C (2001), Prediction of dynamic hysteresis under highly distorted exciting fields by neural networks and actual frequency transplantation. IEEE Trans. Magn., vol. 37, pp. 3315–3319.

Salvini. A, Fulginei. F. R and Coltelli. C (May 2003), A Neuro-Genetic and Time-Frequency Approach to Macromodeling Dynamic Hysteresis in the Harmonic Regime. IEEE Transactions on Magnetics, vol. 39, No. 3, pp. 1401-1404.

Salvini. A, Riganti Fulginei. F (2002), Genetic algorithms and neural networks loops. IEEE Trans. Magn., vol. 38, pp. 873–876.

Salvini.A, Fulginei. F. R (2001), Genetic algorithm and neural network generalizing the Jiles-Atherton model of static hysteresis for dynamic loops, conférence Compumag 13ème, Evian France.

Siamak Tafazoli, Mathieu Leduc and Xuehong Sun (Sep 2006), Hysteresis Modeling using Fuzzy Subtractive Clustering. International journal of computational cognition, vol. 4, No. 3, pp 15-27.

Soderstrom. T, Stoica. P (1989), System identification, Prentice Hall.

Stoner. E. C and Wohlfarth. E. P (1948), A mechanism of magnetic hysteresis in heterogenous alloys. Philos. Trans. R. Soc., vol. A240, pp. 599–642.

Stoner. E.C, Wohlfarth. E.P (1947), A mechanism of magnetic hysteresis in heterogeneous alloys”, Phil. Trans. R. Soc. London, vol. A240: p. 599-642.

Szczyglowski. J (2001), Influence of eddy currents on magnetic hysteresis loops in soft magnetic materials”, Journal of Magnetism and Magnetic Materials, vol. 223: p. 97-102.

Takagi. T (1990), Fusion technology of fuzzy theory and neural network, Survey and future directions. In Proc. Int. Conf. Fuzzy logic neural networks. Lisuka, Japan, pp13-26.

The MathWorks, Inc (1998), Fuzzy Logic Toolbox.

Thierry GAUTREAU (2005), Estimation des pertes fer dans les machines électriques. Modèles d(hystérésis loss surface et application aux machines synchrones à aimants. Thèse de l’INP Grenoble.

Trutt F.C, Erdelyi E.A, Hopkins R.E (1968), Representation of the magnetization characteristics of DC machines for computer use. IEEE Transactions on Power Application and Systems, Vol.87, pp 665-669.

Tsukamoto. Y (1979), An approach to fuzzy reasoning method in M.Gupta, R.K. Ragade, and R. R. Yager (Eds), Advances in Fuzzy Set Theory and Applications, Amsterdam, pp, 137-149.

Vajda. F, Della torre. E (1993), Characteristics of the complete moving hysteresis model. Journal of Applied Physics, vol. 73(10): p.5833-5835.

Vernescu-Spornic. Kedous-Lebouc. C, A, Spornic. S. and Ossart. F (2000), Physica B 275, 99.

Wang. L. X (1995), Adaptative Fuzzy System And Control : Design And Stability Analysis. PRENTICE HALL.

Wei. J. D, SUN. C.T (1998), Constructing hysteretic Memory in neural Networks. IEEE Transactions on systems, Man and Cybernetics-Part B : Cybernetics, 30 N°2, pp.113-119.

Widrow B., Hoff M.E (1960), « Adaptative Switching Circuits ». 1960 WESCON CONV. Rec, 4, p., 96-140.

Williams. H. J, Shockley. W, Kittel. C (1950), Studies of the propagation velocity of a ferromagnetic domain boundary. Physical review 80 (6), pp 1090-1094.

Wilson. K. P. R, Ross. J. N, Brown. D (2001), Optimizing the Jiles–Atherton model of hysteresis by a genetic algorithm. IEEE.Trans. Magn., vol. 37, pp. 989–993. Genetic algorithms and neural networks loops,” *IEEE Trans. Magn.*, vol. 38, pp. 873–876.

Wong C.C, (1988), A dynamic hysteresis model IEEE Transactions on Magnetics, Vol 24 pp 1966-1968.

Xie. X. L et Beni. G. A (1991), Validity measure for fuzzy clustering. IEEE Trans. PAMI, 3(8):841{846.

Xu. Q, Refsum. A (1997), Neural network for representation of hysteresis loops. IEE proc-Sci Meas technol, Vol 144, No.6, pp 263-266.

Yann. M (2001), Les réseaux neuro-flous

Yann. Morere (1998), Les Réseaux de Neurones Récurrents.

Yen. J and Langari. R (1999), Fuzzy Logic Intelligence, Control and Information. Prentice Hall.

Yu. J, Cheng. Q, Huang. H (2004), Analysis of the weighting exponent in the FCM, IEEE Transactions on Systems, Man and Cybernetics-Part B: Cybernetics, vol.34, n1, pp.634-639.

Zadeh L. A (1965), Fuzzy sets. Information and Control. 8: 338–353