

Université du Québec  
INRS-Eau

**UTILISATION DES RÉSEAUX DE NEURONES POUR LA  
CARTOGRAPHIE DES MILIEUX HUMIDES À PARTIR D'UNE SÉRIE  
TEMPORELLE D'IMAGES RADARSAT-1**

Par

**Hosni Ghedira**

Thèse présentée pour l'obtention du grade de *Philosophiae Doctor* (Ph.D.)  
en sciences de l'eau

Spécialité : télédétection

Jury d'évaluation

Examineur externe	M. François Cavayas, Ph.D. Université de Montréal
Examineur externe	M. Djemel Ziou, Ph.D. Université de Sherbrooke
Examineur interne :	M. Bénié Goze, Ph.D. Université de Sherbrooke
Directeur de thèse	Mme Monique Bernier, Ph.D. INRS-Eau
Codirecteur de thèse	M. Taha Ouarda, Ph.D. INRS-Eau

Août 2002



## REMERCIEMENTS

Je tiens à remercier ma directrice de recherche Madame Monique Bernier pour avoir accepté de diriger ce travail, pour son support financier et ses commentaires scientifiques toujours pertinents. Ses conseils et suggestions ont été très stimulants et fort utiles tout au long de ma thèse. Je tiens également à remercier mon co-directeur Monsieur Taha Ouarda pour son aide et ses encouragements fort appréciés. J'aimerais le remercier tout particulièrement pour ces commentaires constructifs, son intérêt et ses judicieux conseils.

Mes remerciements les plus sincères vont à mes chers parents Salah et Naïma et à ma chère épouse Mouna qui m'ont toujours soutenu dans les moments les plus difficiles. Merci de tout cœur de m'avoir permis d'en arriver là.

Je tiens finalement à remercier le Fonds pour la Formation de Chercheurs et l'Aide à la Recherche (FCAR) action concertée Radarsat-1 pour leur soutien financier.



## RÉSUMÉ

Cette recherche visait à évaluer l'utilité des images Radarsat-1 dans la cartographie des milieux humides et à tester l'efficacité des réseaux de neurones pour la classification de ces milieux.

Au Québec, les milieux humides représentent 9 % du territoire. L'étude de ces vastes territoires très diversifiés et très complexes représente un véritable défi qui nécessite l'intégration de nouvelles méthodes et l'utilisation d'outils complémentaires aux méthodes conventionnelles de terrain. Toutefois, la superficie étendue du territoire ainsi que la nécessité d'un suivi continu et efficace rendent la télédétection le meilleur outil rentable pour contrôler et surveiller ces milieux. La télédétection radar représente un outil intéressant grâce à sa fréquence d'acquisition élevée et surtout, son indépendance relative face aux conditions météorologiques et d'illumination. De plus, les milieux humides, avec leur diversité végétale et leur spécificité hydrologique, réunissent la majorité des facteurs influençant l'interaction de l'onde radar avec la scène observée soit l'humidité, la physionomie végétale, la rugosité et la densité de la flore.

La région du Lac St-Jean (48°50' Nord et 72°00' Ouest) a été choisie comme site d'étude. Cette région contient une diversité de milieux humides regroupés au nord et à l'est du lac. Six images Radarsat en mode standard (S1 et S7) ont été acquises dans le cadre de ce projet. L'analyse de ces images a montré que les deux modes d'acquisition S1 et S7 sont deux outils complémentaires pour une cartographie précise des milieux humides. Ils permettent une bonne délimitation entre ces milieux et les milieux avoisinants (S1) et peuvent détecter la variation de la végétation à l'intérieur du milieu humide (S7).

Les analyses de séparabilité effectuées sur les classes végétales des milieux humides ont montré que les images acquises en mode S1 ne donnent pas une grande discrimination entre ces classes. Cependant, le mode d'acquisition S7 reste plus sensible à la variation de la composition végétale à l'intérieur des milieux humides malgré la faiblesse du signal retourné au satellite. Ceci est dû principalement à l'effet négatif de l'humidité du sol sur la rétrodiffusion en mode S1. Le seul apport des images acquises en mode S1 reste leur pouvoir discriminatoire entre les milieux humides (toutes classes confondues) et les milieux forestiers avoisinants.

En outre, ces analyses de séparabilité et les résultats de classification ont montré que l'ajout de la texture au processus de classification augmente considérablement la précision des résultats. En effet, les mesures de texture sont avérées très utiles pour ressortir les informations

dissimulées dans les images radar et pour discriminer les différentes composantes structurales des milieux humides.

Pour atteindre le deuxième objectif, une méthode classification des images radar par réseaux de neurones a été développée. Cette méthode a été adaptée aux images Radarsat-1 en tenant compte de leurs caractéristiques spécifiques et en exploitant la diversité des informations contenues dans chaque bande de données. Pour se faire, nous avons optimisé les paramètres extérieurs et intérieurs du réseau (architecture du réseau, nature des intrants, paramètres d'apprentissage, seuil de décision,... etc.) pour extraire le maximum d'informations des données disponibles.

Une comparaison entre la méthode de classification par maximum de vraisemblance et la méthode des réseaux de neurones a montré que cette dernière offre une performance supérieure quand il s'agit des classes végétales des milieux humides. Toutefois, la méthode du maximum de vraisemblance est plus performante quand il s'agit de classier les milieux forestiers.

# TABLE DES MATIÈRES

<b>REMERCIEMENTS .....</b>	<b>iii</b>
<b>RÉSUMÉ .....</b>	<b>v</b>
<b>TABLE DES MATIÈRES .....</b>	<b>vi</b>
<b>LISTE DES FIGURES .....</b>	<b>xi</b>
<b>LISTE DES TABLEAUX .....</b>	<b>xv</b>
<b>CHAPITRE 1. INTRODUCTION .....</b>	<b>1</b>
1.1. OBJECTIFS DE LA RECHERCHE.....	5
1.2. CONTRIBUTIONS ATTENDUES.....	5
1.3. HYPOTHESES DE LA RECHERCHE.....	6
1.4. PRESENTATION DE LA THESE .....	8
<b>CHAPITRE 2. TELEDETECTION RADAR DES MILIEUX HUMIDES .....</b>	<b>9</b>
2.1. INTRODUCTION .....	9
2.2. CARACTERISTIQUES DES CAPTEURS ET DES IMAGES RSO.....	9
2.2.1. <i>Formation d'une image radar</i> .....	10
2.2.2. <i>Polarisation</i> .....	11
2.2.3. <i>La fréquence et les bandes radar</i> .....	12
2.2.4. <i>Angle d'incidence</i> .....	17
2.2.5. <i>Sensibilité du signal radar à l'humidité</i> .....	19
2.3. TELEDETECTION DES MILIEUX HUMIDES.....	22
2.3.1. <i>Utilisation des données optiques (visible et proche infrarouge)</i> .....	22
2.3.2. <i>Utilisation des capteurs radar</i> .....	23
2.3.3. <i>L'interaction du signal radar avec les milieux humides</i> .....	28
2.4. CONCLUSION .....	32
<b>CHAPITRE 3. ACQUISITION ET TRAITEMENT DES DONNEES.....</b>	<b>35</b>
3.1. SITE D'ETUDE .....	35
3.2. ACQUISITION DES IMAGES .....	36
3.2.1. <i>Critères du choix du mode Standard</i> .....	36
3.2.2. <i>Choix de l'angle d'incidence</i> .....	38
3.3. ACQUISITION DES DONNEES SUR LE TERRAIN.....	41
3.4. INTERPRETATION VISUELLE DES IMAGES BRUTES .....	45
3.4.1. <i>Images S1</i> .....	46
3.4.2. <i>Images S7</i> .....	47
3.5. INTERPRETATION ANALYTIQUE DES IMAGES BRUTES.....	47
3.6. CORRECTION RADIOMETRIQUE.....	50
3.7. CORRECTION GEOMETRIQUE.....	52
3.7.1. <i>Introduction</i> .....	52
3.7.2. <i>Les principes de base de la méthode « Ortho »</i> .....	53
3.7.3. <i>Théorie de la méthode polynomiale</i> .....	54
3.7.4. <i>Choix d'une méthode de correction géométrique</i> .....	56
3.8. MESURE DE LA TEXTURE .....	57
3.8.1. <i>Définition de la texture</i> .....	57
3.8.2. <i>Calcul de la matrice de dépendances des niveaux de gris (GLCM)</i> .....	58
3.8.3. <i>Extraction des mesures de texture</i> .....	59

3.8.4.	<i>Choix de la taille de fenêtre</i> .....	60
3.8.5.	<i>Analyse de corrélation</i> .....	66
3.9.	ANALYSE DE SEPARABILITE.....	68
<b>CHAPITRE 4. INTRODUCTION AUX RESEAUX DE NEURONES .....</b>		<b>73</b>
4.1.	INTRODUCTION.....	73
4.2.	UTILISATION DES RESEAUX DE NEURONES EN TELEDETECTION .....	74
4.3.	ARCHITECTURE D'UN RESEAU DE NEURONES.....	75
4.4.	FORMAT DES DONNEES .....	76
4.4.1.	<i>Niveau d'entrée</i> .....	76
4.4.2.	<i>Niveau de sortie</i> .....	77
4.5.	TRANSFERT DES DONNEES ENTRE LES NEURONES.....	78
4.6.	APPRENTISSAGE DU RESEAU.....	80
4.7.	LA THEORIE DE LA METHODE DE RETROPROPAGATION .....	81
4.7.1.	<i>Minimisation de l'erreur par rétropropagation</i> .....	82
4.7.2.	<i>Signal d'erreur</i> .....	83
4.7.3.	<i>La règle généralisée du delta</i> .....	85
4.7.4.	<i>Taux d'apprentissage</i> .....	86
4.8.	AUTRES METHODES DE CLASSIFICATION SUPERVISEE.....	87
4.8.1.	<i>Méthode de la distance minimale</i> .....	88
4.8.2.	<i>Méthode des parallélépipèdes</i> .....	90
4.8.3.	<i>Méthode du maximum de vraisemblance</i> .....	91
4.9.	COMPARAISON ENTRE LES METHODES DE CLASSIFICATION .....	94
4.10.	ÉVALUATION DE PRECISION D'UNE CLASSIFICATION .....	96
4.10.1.	<i>Matrice de confusion</i> .....	97
4.10.2.	<i>Analyse descriptive d'une matrice de confusion</i> .....	98
4.10.3.	<i>Analyse analytique d'une matrice de confusion</i> .....	99
<b>CHAPITRE 5. MISE AU POINT DU RESEAU DE NEURONES .....</b>		<b>103</b>
5.1.	INTRODUCTION.....	103
5.2.	PREPARATION DES PARAMETRES EXTERNES DU RESEAU.....	103
5.2.1.	<i>Préparation des groupes d'apprentissage</i> .....	104
5.3.	CONFIGURATION DU RESEAU .....	107
5.3.1.	<i>Choix d'architecture</i> .....	107
5.3.2.	<i>Configuration du niveau d'entrée</i> .....	110
5.4.	AJUSTEMENT DES PARAMETRES D'APPRENTISSAGE .....	112
5.4.1.	<i>Taux d'apprentissage</i> .....	113
5.4.2.	<i>le momentum</i> .....	123
5.4.3.	<i>La fonction d'activation</i> .....	124
5.5.	SUPERVISION DE L'APPRENTISSAGE DU RESEAU .....	124
5.5.1.	<i>Apprentissage du réseau</i> .....	125
5.5.2.	<i>Critères d'arrêt d'apprentissage</i> .....	126
5.5.3.	<i>Mesure de la performance du réseau</i> .....	127
5.6.	CONCLUSION .....	128
<b>CHAPITRE 6. CLASSIFICATION DES IMAGES .....</b>		<b>129</b>
6.1.	SELECTION DES INTRANTS .....	130
6.2.	EFFET DU SEUIL DE DECISION.....	131
6.3.	OPTIMISATION DES INTRANTS.....	137
6.3.1.	<i>Six images brutes</i> .....	137
6.3.2.	<i>Six mesures de texture Moyenne</i> .....	139
6.3.3.	<i>Six mesures de texture Écart type</i> .....	141
6.3.4.	<i>Six mesures de texture Corrélation</i> .....	142
6.3.5.	<i>Trois textures moyennes extraites de trois images S7</i> .....	143
6.3.6.	<i>Trois textures moyennes extraites des trois images S1</i> .....	145
6.3.7.	<i>Trois textures pour l'image S1 et trois textures pour l'image S7</i> .....	146

6.3.8.	<i>Deux textures pour l'image S1 et deux textures pour l'image S7.</i>	148
6.3.9.	<i>Dix-huit mesures de texture (3 par image)</i>	149
6.3.10.	<i>Deux composantes principales.</i>	151
6.3.11.	<i>Évaluation des combinaisons d'intrants</i>	152
6.4.	COMPARAISON DES RESULTATS AVEC CELLES OBTENUS AVEC LA METHODE DU MAXIMUM DE VRAISEMBLANCE.	154
6.4.1.	<i>Comparaison descriptive des résultats</i>	155
6.4.2.	<i>Comparaison analytique des résultats</i>	158
6.5.	CLASSIFICATION DE L'IMAGE	163
6.5.1.	<i>Le temps d'opération de la méthode</i>	163
6.5.2.	<i>Effet du seuil de décision sur la classification.</i>	164
6.5.3.	<i>Gradient de la végétation.</i>	168
<b>CHAPITRE 7. CONCLUSION</b>		<b>171</b>
7.1.	VERIFICATION DES HYPOTHESES.	171
7.1.1.	<i>Le potentiel de l'imagerie radar pour la cartographie des milieux humides.</i>	172
7.1.2.	<i>Réseaux de neurones.</i>	174
7.2.	ORIENTATION DES TRAVAUX ULTERIEURS.	177
<b>CHAPITRE 8. BIBLIOGRAPHIE</b>		<b>179</b>
<b>CHAPITRE 9 ANNEXE A</b>		<b>189</b>
<b>CHAPITRE 10 ANNEXE B</b>		<b>205</b>

## LISTE DES FIGURES

<b>Figure 2-1.</b>	Mécanismes de dispersion d'une onde radar	13
<b>Figure 2-2.</b>	Les effets des paramètres structuraux de la végétation sur la rétrodiffusion totale d'un signal radar émis en bandes L, C et X et en polarisation HH (Kasischke and Christensen, 1990).	16
<b>Figure 2-3.</b>	Les effets des paramètres structuraux de la végétation sur la rétrodiffusion totale d'un signal radar émis en bandes L, C et X et en polarisation VV (Kasischke and Christensen, 1990).	17
<b>Figure 2-4.</b>	Effet de l'angle d'incidence sur la rétrodiffusion radar (Lewis <i>et al.</i> , 1998)	18
<b>Figure 2-5.</b>	Effet de la constante diélectrique moyenne ( $\epsilon$ ) et de l'angle d'incidence sur la rétrodiffusion radar (Ulaby <i>et al.</i> , 1982a).	20
<b>Figure 2-6.</b>	Mécanismes d'interaction dans un milieu arboré.	29
<b>Figure 2-7.</b>	Mécanismes d'interaction dans un milieu arbustif (sans troncs).	29
<b>Figure 3-1.</b>	La zone couverte par les deux modes d'acquisitions	38
<b>Figure 3-2.</b>	Classes principales et secondaires de la végétation des milieux humides	42
<b>Figure 3-3.</b>	Photographies acquises dans les 4 classes	43
<b>Figure 3-4.</b>	Mosaïque des photos aériennes (échelle 1:15000) de la région d'étude	44
<b>Figure 3-5.</b>	Apparence des milieux humides dans une image S1	45
<b>Figure 3-6.</b>	Comportement du signal radar pour les différentes classes	48
<b>Figure 3-7.</b>	Distribution statistique des valeurs de la rétrodiffusion à l'intérieur d'une tourbière	52
<b>Figure 3-8.</b>	Correction géométrique d'une image du lac Saint-Jean	56
<b>Figure 3-9.</b>	Orientations possibles pour le calcul de la GLCM	59
<b>Figure 3-10.</b>	Exemple de calcul de la GLCM (PCI Geomatics, 1997)	59
<b>Figure 3-11a.</b>	Effet de la taille de fenêtre sur la texture Moyenne	63
<b>Figure 3-11b.</b>	Effet de la taille de fenêtre sur la texture Écart Type	64
<b>Figure 3-11c.</b>	Effet de la taille de fenêtre sur la texture Corrélation	65
<b>Figure 3-12a.</b>	Variation temporelle de la texture Moyenne en fonction de classes	67
<b>Figure 3-12b.</b>	Variation temporelle de la texture Corrélation en fonction de classes	68
<b>Figure 3-12c.</b>	Variation temporelle de la texture Écart Type en fonction de classes.	68
<b>Figure 3-13a.</b>	Variation temporelle des indices de séparabilité pour la texture Moyenne	70

<b>Figure 3-13b.</b>	Variation temporelle des indices de séparabilité pour la texture Écart Type	70
<b>Figure 3-13c.</b>	Variation temporelle des indices de séparabilité pour la texture Corrélation	71
<b>Figure 3-13d.</b>	Variation temporelle des indices de séparabilité pour les images brutes	71
<b>Figure 4-1.</b>	Architecture d'un réseau multicouches	76
<b>Figure 4-2.</b>	Connexions d'un élément processeur (nœud j).	78
<b>Figure 4-3.</b>	Fonctions d'activation.	79
<b>Figure 4-4.</b>	Apprentissage du réseau	80
<b>Figure 4-5.</b>	Préparation des données pour une analyse multi-temporelle.	86
<b>Figure 4-6.</b>	Critères de classification par la méthode de la distance minimale.	89
<b>Figure 4-7.</b>	Critères de classification par la méthode des parallélépipèdes.	91
<b>Figure 4-8.</b>	Critères de classification par la méthode de maximum de vraisemblance.	94
<b>Figure 5-1a.</b>	Effet du taux initial sur l'entraînement du réseau (taux = 0,01)	116
<b>Figure 5-1b.</b>	Effet du taux initial sur l'entraînement du réseau (taux = 0,05)	116
<b>Figure 5-1c.</b>	Effet du taux initial sur l'entraînement du réseau (taux = 0,1)	117
<b>Figure 5-2a.</b>	Effet du seuil de tolérance ( $x$ ) sur l'apprentissage ( $x = 10\%$ )	118
<b>Figure 5-2b.</b>	Effet du seuil de tolérance ( $x$ ) sur l'apprentissage ( $x = 2\%$ ).	119
<b>Figure 5-2c.</b>	Effet du seuil de tolérance ( $x$ ) sur l'apprentissage ( $x = 4\%$ )	119
<b>Figure 5-3a.</b>	Comportement de l'apprentissage avec un taux d'accélération élevée (1,10)	120
<b>Figure 5-3b.</b>	Comportement de l'apprentissage avec un faible taux d'accélération (1,01)	121
<b>Figure 5-3c.</b>	Comportement de l'apprentissage avec un taux d'accélération égal à 1,05	121
<b>Figure 5-4a.</b>	Comportement de l'apprentissage avec taux de freinage égal à 0,5	122
<b>Figure 5-4b.</b>	Comportement de l'apprentissage avec taux de freinage égal à 0,9	122
<b>Figure 5-5.</b>	Évolution de l'erreur au cours de l'apprentissage.	126
<b>Figure 5-6.</b>	Description schématique de la phase d'apprentissage	128
<b>Figure 6-1a.</b>	Effet du seuil de décision : Milieu humide arbustif	134
<b>Figure 6-1b.</b>	Effet du seuil de décision : Milieu forestier	134
<b>Figure 6-1c.</b>	Effet du seuil de décision : Milieu humide fortement arboré	135
<b>Figure 6-1d.</b>	Effet du seuil de décision : Milieu humide moyennement arboré	135
<b>Figure 6-2.</b>	Évolution de l'apprentissage du réseau avec six images brutes.	137
<b>Figure 6-3.</b>	Évolution de l'apprentissage du réseau avec six mesures de la texture Moyenne.	139

<b>Figure 6-4.</b>	Évolution de l'apprentissage du réseau avec six mesures de la texture Écart Type.	141
<b>Figure 6-5.</b>	Évolution de l'apprentissage du réseau avec six mesures de la texture Corrélation.	142
<b>Figure 6-6.</b>	Évolution de l'apprentissage du réseau avec 3 textures moyennes extraites des trois images S7	143
<b>Figure 6-7.</b>	Évolution de l'apprentissage du réseau avec 3 textures moyennes extraites des trois images S1	145
<b>Figure 6-8.</b>	Évolution de l'apprentissage du réseau avec 6 textures (3 S1 et 3 S7).	147
<b>Figure 6-9.</b>	Évolution de l'apprentissage du réseau avec 4 textures (2 S1 et 2 S7).	148
<b>Figure 6-10.</b>	Évolution de l'apprentissage du réseau avec 18 textures (3 par image).	150
<b>Figure 6-11.</b>	Évolution de l'apprentissage du réseau avec deux composantes principales.	151
<b>Figure 6-12.</b>	Comparaison entre les deux méthodes de classification: maximum de vraisemblance et réseaux de neurones	156
<b>Figure 6-13a.</b>	Distribution statistique des classes : texture Moyenne de l'image S1 (août).	160
<b>Figure 6-13b.</b>	Distribution statistique des classes : texture Écart Type de l'image S1 (août)	160
<b>Figure 6-13c.</b>	Distribution statistique des classes : texture Corrélation de l'image S1 (août).	161
<b>Figure 6-14a.</b>	Distribution statistique des classes : texture Moyenne de l'image S7 (avril).	161
<b>Figure 6-14b.</b>	Distribution statistique des classes : texture Écart Type de l'image S7 (avril).	162
<b>Figure 6-14c.</b>	Distribution statistique des classes : texture Corrélation de l'image S7 (avril).	162
<b>Figure 6-15a.</b>	Effet du seuil de décision sur la classification (seuil = 0,2).	165
<b>Figure 6-15b.</b>	Effet du seuil de décision sur la classification (seuil = 0,4).	166
<b>Figure 6-15c.</b>	Effet du seuil de décision sur la classification (seuil = 0,6).	167
<b>Figure 6-15d.</b>	Effet du seuil de décision sur la classification (seuil = 0,8).	168
<b>Figure 6-16.</b>	Gradient de la végétation.	169
<b>Figure 6-17.</b>	Vérification du gradient de la végétation.	170

## LISTE DES TABLEAUX

<b>TABLEAU 2-1.</b>	Facteurs influençant la quantité d'énergie retournée vers le capteur	11
<b>TABLEAU 2-2.</b>	Les bandes radar	12
<b>TABLEAU 2-3.</b>	Modes d'acquisition d'images du Radarsat-1 ( <i>source : RSI</i> )	19
<b>TABLEAU 3-1 :</b>	Dates et modes d'acquisition des images	36
<b>TABLEAU 3-2.</b>	Sources de distorsions géométriques	53
<b>TABLEAU 3-3.</b>	Corrélation moyenne entre les différentes mesures de la texture	66
<b>TABLEAU 4-1.</b>	Méthodes de classification les plus utilisées dans les logiciels commerciaux de traitement (Smits <i>et al.</i> , 1999).	88
<b>TABLEAU 4-2.</b>	Calcul des précisions à partir d'une matrice de confusion (Congalton, 1991)	97
<b>TABLEAU 5-1.</b>	Exemples d'architectures extraites de la littérature.	108
<b>TABLEAU 5-2.</b>	Effet de l'architecture du réseau de neurone sur la performance de la classification	109
<b>TABLEAU 5-3.</b>	Optimisation des paramètres liés au taux d'apprentissage	123
<b>TABLEAU 6-1.</b>	Effet du seuil de décision sur la performance de la classification.	133
<b>TABLEAU 6-2.</b>	Évaluation par Statistique-Z de la similarité des classifications obtenues par différents seuils de décision.	136
<b>TABLEAU 6-3.</b>	Matrices de confusions obtenues avec les six images brutes.	138
<b>TABLEAU 6-4.</b>	Matrices de confusions obtenues avec six textures Moyenne.	140
<b>TABLEAU 6-5.</b>	Matrices de confusions obtenues avec six textures Écart Type.	141
<b>TABLEAU 6-6.</b>	Matrices de confusions obtenues avec six textures Corrélation.	143
<b>TABLEAU 6-7.</b>	Matrices de confusions obtenues avec trois textures Moyenne (S7).	144
<b>TABLEAU 6-8.</b>	Matrices de confusions obtenues avec trois textures Moyenne (S1).	147
<b>TABLEAU 6-9.</b>	Matrices de confusions obtenues avec 3 textures S1 et 3 textures S7.	147
<b>TABLEAU 6-10.</b>	Matrices de confusions obtenues avec 2 textures S1 et 2 textures S7.	149
<b>TABLEAU 6-11.</b>	Matrices de confusions obtenues avec 18 textures (3 par image).	150
<b>TABLEAU 6-12.</b>	Matrices de confusions obtenues avec deux composantes principales	151
<b>TABLEAU 6-13.</b>	Tableau récapitulatif des résultats obtenus pour les différentes combinaisons d'intrants.	153
<b>TABLEAU 6-14.</b>	Évaluation des précisions par un test Z	154

<b>TABLEAU 6-15.</b>	Matrices de confusions obtenues par maximum de vraisemblance avec trois combinaisons d'intrants.	157
<b>TABLEAU 6-16.</b>	Comparaison analytique entre les réseaux de neurones et le maximum de vraisemblance.	158
<b>TABLEAU 6-17.</b>	Vérification de la complémentarité entre le mode S1 et le mode S7	159

# CHAPITRE 1

## Introduction

---

Les milieux humides ont été définis par Dansereau (1957) comme étant un ensemble de sites qui forment une zone de transition entre les écosystèmes aquatiques et les écosystèmes purement terrestres. Ces écosystèmes de très forte productivité biologique, avec une faune et une flore assez abondante et diversifiée, jouent un rôle indispensable dans le cycle vital de certaines d'espèces animales et végétales. Les milieux humides jouent aussi un rôle clé dans l'équilibre hydrologique de leur environnement essentiellement grâce à la présence d'une végétation majoritairement hygrophile (tolérante à de longues périodes d'inondations). Ainsi, les milieux humides agissent comme une éponge géante naturelle en absorbant les excès d'eau pendant les inondations et en alimentant lentement les cours d'eau pendant des périodes suffisamment longues de sécheresse.

Selon l'évaluation la plus récente, les milieux humides occupent 170 millions d'hectares soit 17 % du territoire canadien (Gorham, 1990). Cette superficie représente le quart de tous les milieux humides de la planète. Le Québec est l'une des provinces canadiennes les mieux pourvues en milieux humides (9 % de son territoire) et leur superficie atteint 11,7 millions d'hectares (Gorham, 1990). Ces milieux sont particulièrement abondants le long du Saint-Laurent ainsi que dans les zones au relief peu accidenté, comme les basses terres du Lac Saint-Jean, de l'Abitibi et de la Baie James. Ces milieux ont fait l'objet de plusieurs études qui ont permis de mieux connaître leur diversité écologique (Buteau *et al.*, 1994).

L'intérêt manifesté à l'égard des milieux humides est de plus en plus croissant. En effet, en plus de leur valeur écologique, les milieux humides constituent une ressource importante qui peut être valorisée de plusieurs façons telles que la conservation, la récolte de la tourbe à des fins horticoles et l'exploitation forestière. Ainsi, du point de vue hydrologique, l'emplacement et

l'étendu des milieux humides représentent des composantes importantes dans le mécanisme hydrique global d'un bassin versant. On peut citer, à titre d'exemple, les centrales hydroélectriques de la Baie James pour lesquelles les milieux humides occupent une grande partie de leurs bassins versants.

L'omniprésence de milieux humides dans le paysage québécois rend nécessaire l'intégration de leurs différentes composantes dans un système d'information géographique. Ce système sera très utile pour plusieurs intervenants dans le domaine de la gestion des ressources naturelles. Une délimitation précise de ces vastes territoires et une étude approfondie de leurs différentes composantes représentent un véritable défi vu leur forte diversité et leur accessibilité souvent difficile. Une cartographie précise de ces milieux nécessite l'intégration de nouvelles méthodes et l'utilisation d'outils complémentaires aux méthodes conventionnelles de terrain. Il est donc important de disposer d'un système d'information qui permette d'observer, d'analyser et de classer les milieux humides à coûts modérés afin de connaître leur évolution dans le temps et dans l'espace. La télédétection peut jouer ainsi un rôle important pour accomplir cette tâche.

Les progrès réalisés dans l'utilisation des données à référence spatiale ont mis en évidence l'utilité de la télédétection comme outil de surveillance des milieux humides (Seuthé et Buteau, 1994). En effet, par comparaison avec les méthodes traditionnelles de terrain, la télédétection permet de couvrir des vastes superficies rapidement et à peu de frais. De plus, la nature spécifique et les conditions difficiles des milieux humides font de la télédétection un outil intéressant pour contrôler, inventorier et surveiller ces vastes territoires. Cette technique est devenue ainsi une source privilégiée d'acquisition des données dans plusieurs applications et surtout celles liées à la cartographie de l'occupation du sol.

Dans les dix dernières années, la mise sur pied de trois programmes majeurs d'observation de la Terre par les satellites radar, soit ERS-1 et 2 (Europe), J-ESR-1 (Japon) et Radarsat-1 (Canada) a suscité un intérêt grandissant pour l'utilisation de ce type de données dans des applications assez diversifiées. Maintenant, les images radar sont devenues un outil indispensable dans plusieurs applications en s'appuyant sur des bases théoriques solides de la physique de l'interaction de l'onde radar avec la scène observée. Les images radar ont ainsi dépassé l'étape dans laquelle elles étaient utilisées comme moyen de compenser le manque de disponibilité ou d'accessibilité des images optiques.

La complexité de la théorie derrière la formation d'une image radar a joué en faveur des données optiques étant donné la facilité relative dans leur interprétation et le lien relativement direct qui existe entre la scène observée et l'apparence de l'image obtenue. Les données optiques nécessitent ainsi moins de connaissances dans leur interprétation puisque leur principe de base ressemble plus ou moins au fonctionnement de l'œil humain. Toutefois, en dépit des avantages de l'observation de la Terre par des techniques conventionnelles de télédétection, il existe deux limitations majeures liées à l'utilisation des données optiques. En premier lieu, la présence des nuages et la dépendance à l'illumination solaire limite l'utilisation des capteurs optiques agissant dans les bandes du visible et du proche infrarouge du spectre électromagnétique. En second lieu, les satellites conventionnels d'observation de la Terre à haute résolution ont un problème de périodicité des observations (26 jours pour SPOT-HRVIR et 16 jours pour Landsat-TM). La combinaison de ces deux paramètres limite beaucoup l'utilisation des données optiques dans des applications d'observation de la Terre. Le radar représente alors une alternative intéressante grâce à sa fréquence d'acquisition élevée et surtout, grâce à son pouvoir d'observer la surface de la terre dans la plupart des conditions atmosphériques, même sous l'obscurité ou en présence de nuages (RSI, 1995). En plus de ces avantages, les images radar restent une source d'informations appréciable dans le cas où la discrimination entre les différentes classes est basée sur des paramètres liés à l'humidité et la densité végétale comme les milieux humides.

La classification des images représente l'étape la plus importante dans un processus complet d'analyse numérique et de traitement d'images. Cette étape consiste à identifier la classe à laquelle appartient chacun des pixels pour créer à la fin une carte thématique qui représente un assemblage d'étiquettes (ou des classes) associé aux éléments de la scène analysée. Actuellement, il existe plusieurs méthodes de classification des données de télédétection basées souvent sur des principes statistiques comme la méthode du maximum de vraisemblance et la méthode du K-plus proche voisin (*K-nearest neighbour*) ou sur des principes arithmétiques comme la classification par distance minimale (Richards, 1993). Ces méthodes traditionnelles de classification fonctionnent bien avec des données Landsat-TM mais elles ne sont pas vraiment appropriées aux données radar à cause de leurs propriétés différentes aux autres données de télédétection comme, par exemple, la présence de chatoiement (Smits, et al., 1999).

L'utilisation des réseaux de neurones en télédétection a commencé à la fin des années quatre-vingts (1988), soit deux ans après le lancement par Rumelhart et al. (1986) de l'algorithme

d'apprentissage par rétropropagation (Kanellopoulos and Wilkinston, 1997). Les réseaux de neurones constituent actuellement le sujet de beaucoup de recherches, en raison de leurs propriétés intéressantes d'apprentissage de modèles non linéaires et leurs possibilités d'application à des problèmes de classification, de diagnostic, de prédiction et de contrôle de procédés (Kanellopoulos and Wilkinston, 1997, Kimes *et al.*, 1998). En télédétection, les réseaux de neurones ont été généralement utilisés comme outil de classification non paramétrique qui ne nécessite pas l'établissement d'un modèle statistique des classes. La comparaison entre les méthodes conventionnelles de classification et les réseaux de neurones montre d'une façon évidente le potentiel de ces derniers à apporter de nouvelles approches et à améliorer la précision d'une classification (Bendiktsson and Sveinsson, 1997). Les deux avantages majeurs des réseaux de neurones en télédétection sont les suivants :

- Les réseaux de neurones représentent une approche non paramétrique qui ne nécessite pas une connaissance *a priori* de la distribution statistique des classes. Cette caractéristique nous évite de fixer des conditions préalables sur la nature de la distribution qui ne sont pas toujours exactes. Par exemple, dans la plupart des applications de la méthode de maximum de vraisemblance, on suppose a priori que la distribution des valeurs numériques des pixels est normale (Gaussienne) pour chaque classe (Paola and Schowengerdt 1995). Toutefois, cette condition n'est pas toujours honorée puisque pour certaines classes, la distribution peut être asymétrique, bi-modale ou même aléatoire surtout quand il s'agit d'une classification d'un milieu naturel.
- Contrairement aux méthodes conventionnelles de classification, les réseaux de neurones considèrent différemment l'apport de chaque source de données (images multi-dates et multi-angles d'incidences) pour la prise de décision d'appartenance à une classe donnée (Bendiktsson and Sveinsson, 1997). Cet avantage permet la mise en évidence de la spécificité de chaque source, ce qui permet de renforcer le poids de certaines informations. Ce phénomène est couramment observé dans les séries temporelles des images radar puisque les caractéristiques physiques d'une classe donnée varient considérablement d'une date à une autre.

Le choix des réseaux de neurones comme outil de classification des milieux humides a été motivé principalement par les deux avantages cités précédemment. Nous essayons donc dans le cadre de cette thèse de ressortir le maximum d'informations des images disponibles pour une classification la plus précise possible. Cependant, afin de trouver la configuration idéale d'un

réseau de neurones pour classifier des données radar, il faut d'abord commencer par une adaptation rigoureuse des paramètres externes et internes du réseau tout en tenant compte de la nature et de l'origine physique des données. Ainsi, nous prenons en considération les caractéristiques spécifiques aux images radar en exploitant la diversité d'informations contenue dans le pixel en prenant comme référence la physique de l'interaction entre l'onde radar et le milieu observé.

### ***1.1. Objectifs de la recherche***

L'objectif principal de cette recherche est de développer une méthodologie de classification des images Radarsat-1 par réseaux de neurones pour identifier les grandes classes physiologiques des milieux humides. La méthode développée permet à la fois de tenir compte de la nature spécifique des images de Radarsat-1 et des caractéristiques physiques des milieux humides. Pour ce faire, deux objectifs secondaires ont été poursuivis. Le premier consiste à comprendre le comportement du signal radar émis par Radarsat-1 face aux différentes composantes des milieux humides et étudier les effets de l'angle d'incidence et de la date d'acquisition sur l'énergie retournée au satellite. Le second vise d'établir un mode de fonctionnement ou d'emploi pour les différentes étapes de classification des données Radarsat-1 par réseaux de neurones en partant de la préparation des données et jusqu'à la production de la carte thématique. Dans cette optique, nos efforts ont été concentrés pour établir une méthodologie d'optimisation des paramètres internes et externes du réseau de neurones pour qu'il puisse extraire le maximum d'informations des données radar et produire une classification adéquate des milieux humides avec une précision supérieure à celle obtenue par les méthodes conventionnelles.

### ***1.2. Contributions attendues***

Deux contributions majeures sont attendues de cette recherche. La contribution la plus importante concerne la réalisation d'une méthodologie originale de classification par réseaux de neurones adaptée aux images radar. Le développement de cette méthode a nécessité une étude approfondie de l'influence des paramètres internes du réseau de neurones et la sélection de ces paramètres pour une meilleure performance du classificateur. Cette performance a été évaluée dans un contexte de classification d'une région dominée par les milieux humides en utilisant une série d'images multi-dates et multi-angles d'incidences de Radarsat-1. La

deuxième contribution consiste à évaluer le potentiel des données Radarsat-1 pour la cartographie des milieux humides. Cette évaluation a été basée sur une compréhension des phénomènes physiques qui interviennent au moment de l'interaction entre le signal radar et la couverture végétale de la scène observée. La compréhension de ces phénomènes physiques a permis aussi de mieux cibler le choix des intrants du réseau et d'améliorer la performance du classificateur.

### **1.3. Hypothèses de la recherche**

La définition des objectifs de cette thèse a été basée sur plusieurs hypothèses liées au choix de l'imagerie radar pour la cartographie des milieux humides et au choix de réseau de neurones comme algorithme de classification. Ces hypothèses seront par la suite analysées et vérifiées. Des recommandations liées à leur applicabilité dans un contexte réel seront présentées à la fin de la thèse.

#### ***Pourquoi le radar ?***

Les milieux humides, avec leur diversité végétale et leur spécificité hydrologique, réunissent la majorité des facteurs influençant l'interaction de l'onde radar avec la scène observée soit l'humidité, la physionomie végétale, la rugosité et la densité de la flore. En fait, il a été démontré dans des études précédentes que la sensibilité du signal radar à l'humidité et à la structure végétale du milieu observé joue un rôle dans la discrimination entre plusieurs types de couvertures végétales (Ulaby *et al.*, 1986 et Kasischke and Bourgeau-Chavez, 1997). Un des objectifs de cette thèse consiste à vérifier cette hypothèse dans une application visant la discrimination entre différents types de couvertures végétales de milieux humides avec des données Radarsat-1.

Une deuxième hypothèse liée au choix de l'imagerie radar comme source d'information a été aussi avancée. Cette hypothèse stipule que les micro-ondes radar émises avec un faible angle d'incidence sont capables de pénétrer une couverture arborée et fournir ainsi des informations sur son substrat. Cette caractéristique de l'imagerie radar serait très utile pour une délimitation précise entre les milieux humides et les milieux forestiers. En effet, une délimitation entre ces deux milieux s'avère une tâche difficile avec des images optiques en raison de la forte ressemblance de la couverture arborescente généralement dense dans la zone limitrophe des

milieux humides (Sader *et al.* 1995, Warner, 2000). La seule différence entre un milieu forestier et un milieu humide fortement arboré réside dans la composition de son substrat (sol et végétation). Cette zone limitrophe a été définie par Buteau *et al.* (1994) comme étant la limite supérieure des milieux humides. Elle est le lieu où s'opère le passage entre les sols hydromorphes (engorgés d'eau) et les sols non hydromorphes. Les données micro-ondes peuvent "théoriquement" jouer un rôle dans la discrimination entre ces deux milieux. En fait, le pouvoir des micro-ondes radar de pénétrer des couvertures arborées et leur sensibilité à l'humidité du sol présentent un potentiel fort intéressant dans la discrimination de ces zones.

Le satellite canadien Radarsat-1 offre la possibilité d'acquérir des images en choisissant parmi une multitude de modes d'acquisitions (angles d'incidences et superficies d'images). Une étude détaillée sur l'effet de l'angle d'incidence sur les mécanismes d'interaction entre le signal radar et la couverture végétale est présentée au troisième chapitre. La troisième hypothèse de cette thèse est que l'utilisation d'un ensemble d'images acquises avec des angles d'incidences différents peut apporter une autre dimension dans la discrimination d'une part entre les milieux humides et les milieux avoisinant et d'autre part entre les composantes végétales des milieux humides. L'utilité d'une série d'images multi-angles d'incidences sera testée et évaluée en tenant compte de son effet sur la précision globale de la classification.

### ***Pourquoi les réseaux de neurones ?***

Deux hypothèses liées au choix des réseaux de neurones comme outil de classification ont aussi été adoptées. Premièrement, les réseaux de neurones tiennent compte différemment de l'apport de chaque source des données fournies au réseau dans une classification. Cette caractéristique importante est parmi les points forts souvent évoqués quand il s'agit de comparer les réseaux de neurones aux méthodes conventionnelles de classification. Deuxièmement, les réseaux de neurones sont supérieurs aux méthodes conventionnelles de classification quand il s'agit de classifier un milieu hétérogène dont la normalité de la distribution statistique des classes n'est pas toujours vérifiée.

La disponibilité d'une série multi-dates et multi-angles d'incidences nécessite la considération d'une façon différente du rôle de chaque information dans le processus de classification. Par exemple, l'ajout d'une image peut être bénéfique dans l'identification d'une classe donnée mais apporte de la confusion pour d'autres classes. Les réseaux de neurones, avec leur structure complexe, doivent identifier automatiquement l'apport de chaque source de données dans le

processus de classification en amplifiant sa contribution positive pour certaines classes et en minimisant toute influence négative sur les autres classes.

#### **1.4. Présentation de la thèse**

Cette thèse s'inscrit dans le cadre général des travaux de recherche visant à élargir les champs d'applications des images Radarsat-1. Après cette introduction, nous présentons un aperçu sur les bases théoriques de l'imagerie radar. Les concepts théoriques de l'interaction de l'onde radar avec les composantes végétales des milieux humides sont présentés au troisième chapitre. Le quatrième chapitre se concentre sur les différentes étapes de traitement des données en partant de l'acquisition des images et jusqu'à leur préparation à la classification. Le cinquième chapitre présente la théorie des réseaux de neurones et leur mode d'emploi ainsi qu'une brève comparaison entre cette technique et d'autres méthodes de classification. Le sixième chapitre constitue la principale partie de la thèse. Il aborde les étapes suivies pendant le développement de la méthode de classification. Les résultats de cette classification sont présentés au septième chapitre où ils sont comparés avec ceux obtenus avec la méthode du maximum de vraisemblance. Le dernier chapitre regroupe les conclusions et les recommandations de cette étude.

# CHAPITRE 2

## Téledétection radar des milieux humides

---

### ***2.1. Introduction***

Ce chapitre est divisé en deux principales parties. La première partie (§ 2.2) présente, d'une manière générale, les mécanismes physiques qui interviennent lors de la formation d'une image radar. La compréhension de ces phénomènes physiques nous permettra de bien cibler nos choix d'intrants dans les étapes suivantes de la thèse. La deuxième partie de ce chapitre (§ 2.3) présente le potentiel de l'imagerie radar pour la cartographie des milieux humides. Cette section comprend aussi une revue de littérature sur l'utilisation de la télédétection en général et de l'imagerie radar en particulier dans des applications liées aux milieux humides.

### ***2.2. Caractéristiques des capteurs et des images RSO***

Le principe de la télédétection radar consiste à observer les propriétés de la scène illuminée par le système d'acquisition en analysant la quantité d'énergie retournée au satellite. L'image radar est en effet une présentation synthétique de la scène observée. Elle réunit en un tout spatial un ensemble des données numériques qui résultent de l'interaction entre l'onde radar émise par le capteur et la surface observée. Plusieurs facteurs interviennent pendant la formation d'une image, notamment : la physionomie de la couverture végétale, l'humidité du sol et de la végétation ainsi que les paramètres liés à l'onde émise par le satellite tel que l'angle d'incidence, la fréquence, et la polarisation (Ulaby *et al.*, 1982a). Chaque entité numérique, ou pixel, dans une image radar est le résultat d'une combinaison des réactions physiques

généérées par le contact du signal avec une parcelle du terrain visée par le capteur dont la surface est égale à la résolution du satellite (Raney, 1998).

Le RSO (Radar à Synthèse d'Ouverture, SAR en anglais : Synthetic Aperture Radar) est un puissant instrument d'hyperfréquence actif qui opère avec sa propre énergie jour et nuit indépendamment de l'illumination du soleil. Cette technologie radar utilise des techniques spéciales d'enregistrement des données et de traitement de signal afin de simuler (ou synthétiser) des antennes très longues tout en gardant une antenne relativement courte transportable par le satellite (9 mètres pour Radarsat-1). Cette méthode de simulation permet d'avoir une résolution dans la direction du vol (en azimut) suffisamment fine pour la plupart des applications de télédétection (Raney, 1998).

Le RSO est capable de transmettre une impulsion énergétique micro-onde vers la surface de la terre et mesure la quantité d'énergie retournée au satellite après son interaction avec la surface de la terre. Contrairement aux détecteurs optiques, l'énergie micro-onde traverse l'obscurité, les nuages, la pluie, la poussière et le brouillard, facilitant aux capteurs radar la collecte des données en tout temps et dans toutes les conditions atmosphériques. Cela représente un grand avantage dans les régions difficiles à observer par des systèmes d'acquisition qui opèrent dans le visible ou dans le proche infrarouge (Raney, 1998).

### **2.2.1. Formation d'une image radar**

Le fonctionnement de base d'un radar se fait en trois étapes. Au début, le radar transmet un signal (énergie) micro-onde vers une scène avec un angle d'incidence donnée. Par la suite, le signal transmis entre en interaction avec la scène observée et une partie de l'énergie transmise sera retournée vers le capteur c'est qu'on appelle la rétrodiffusion. Le radar mesure enfin l'intensité et le temps de retour (délai) du signal mesuré. Ces mesures seront par la suite compilées pour fournir la valeur numérique du pixel. Ainsi, la formation d'une image radar se fait pixel par pixel, elle est caractérisée par de très grandes variations des niveaux de gris (Ulaby *et al.*, 1982a; Raney, 1998).

La luminance d'un pixel dans une image radar est proportionnelle à l'intensité du signal reçu par le capteur. En effet, l'interaction de l'énergie électromagnétique émise avec la surface illuminée est influencée par la nature des objets observés et par des paramètres d'acquisitions propres au capteur (Tableau 2-1).

**TABLEAU 2-1.** Facteurs influençant la quantité d'énergie retournée vers le capteur (RSI, 1995)

Facteurs liés à la surface observée	Facteurs liés aux paramètres du capteur
<ul style="list-style-type: none"><li>• l'orientation des formes topographiques (angles d'incidences locaux),</li><li>• la rugosité de surface</li><li>• l'épaisseur ou le volume de la couverture de surface (végétation par exemple)</li><li>• l'humidité (propriétés diélectriques)</li></ul>	<ul style="list-style-type: none"><li>• l'angle d'incidence</li><li>• la direction de la visée</li><li>• l'angle d'orientation du satellite</li><li>• la polarisation (voir § 2.2.2)</li><li>• la longueur d'onde du signal (voir § 2.2.3)</li></ul>

Quand le signal radar entre en interaction avec la surface de la terre, il peut être réfléchi, diffusé, absorbé ou transmis (avec un angle de réfraction). La réflexion d'un signal est souvent provoquée par la constante diélectrique du matériau rencontré qui dépend principalement de sa teneur en eau. Les mécanismes de diffusion sont schématisés à la figure 2-1. Les surfaces lisses engendrent une réflexion spéculaire du signal incident suivant la loi de Descartes. Par exemple, si le satellite radar observe un lac calme, le signal envoyé sera réfléchi avec le même angle que le signal incident (figure 2-1-A), dans ce cas, la quantité d'énergie retournée au satellite sera minimale (ou nulle) ce qui donne des zones sombres dans l'image. Le signal réfléchi peut aussi faire un double bond (figures 2-1-C et 2-1-E) et retourner vers le satellite. Dans ce cas, le signal reçu par le satellite sera très important. Dans le cas d'une diffusion volumique, phénomène souvent rencontré dans le cas d'un couvert de neige ou d'un couvert forestier, un pourcentage du signal incident retourne au satellite ce qui donne à la végétation un ton plus clair qu'une surface d'eau calme (figure 2-1-D).

### **2.2.2. Polarisation**

Le mot polarisation fait référence à l'orientation de l'onde électromagnétique émise et captée par le radar. La polarisation d'une image est désignée par deux lettres (H ou V), la première lettre indique la polarisation de la transmission et la deuxième lettre indique la polarisation de la réception. La polarisation du signal radar est un bon indicateur des propriétés de la surface observée. En général, il revient plus d'énergie vers le capteur en polarisation parallèle (HH pour Radarsat-1, VV pour ERS-1) qu'en polarisation croisée (HV ou VH). En plus, le signal retourné au capteur radar à partir d'un objet sera plus faible si cet objet se trouve sur un plan similaire à

la polarisation. Par exemple, une plantation de blé apparaît plus foncée dans une image acquise avec une polarisation verticale VV qu'avec une polarisation horizontale HH.

Pour une même scène, la disponibilité de plusieurs images acquises par des polarisations différentes apporte des informations utiles sur les propriétés physiques de la surface observée. On peut même former un composé couleur de la même scène au moyen d'images acquises avec des polarisations différentes (Baghdadi *et al.*, 2001).

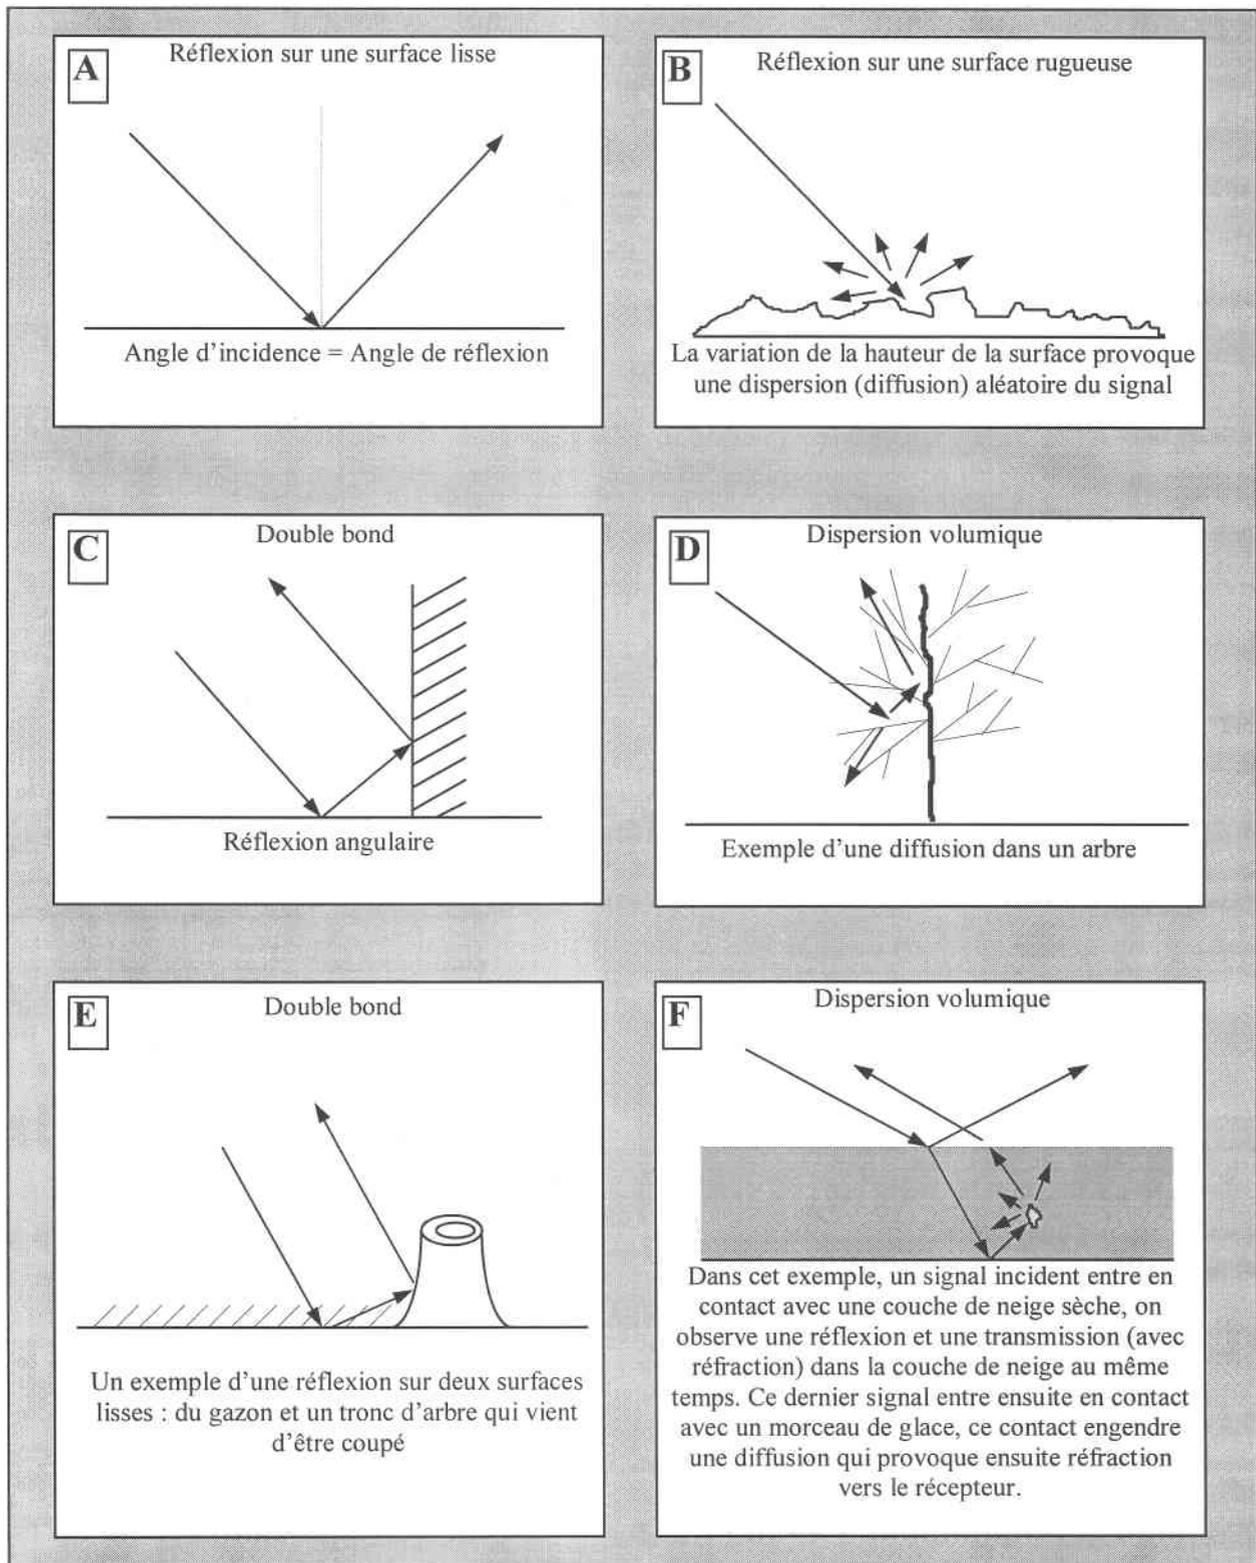
Le satellite canadien Radarsat-1 opère seulement en mode HH et il ne permet pas d'étudier l'effet de polarisation sur une scène observée. Ce handicap sera surmonté avec le satellite Radarsat-2 qui donnera le choix aux utilisateurs de commander des images avec quatre choix de polarisations (HH, VV, HV et VH). Radarsat-2 sera probablement lancé en 2004.

### 2.2.3. La fréquence et les bandes radar

Le choix de la fréquence d'un capteur radar est très important dès la construction du système et dépend principalement des applications envisagées. Toutefois, la fréquence utilisée a un effet majeur sur les informations contenues dans une image RSO. L'onde radar peut être exprimée soit en fréquence (GHz) soit en longueur d'onde (cm). La majorité des capteurs radar opèrent sur des bandes ayant des longueurs d'onde comprises entre 0,5 cm et 133 cm. Ces bandes sont identifiées par des lettres. Le tableau 2-2 donne un aperçu des bandes les plus utilisées en imagerie radar.

**TABLEAU 2-2.** Les bandes radar (Raney, 1998)

<b>Bandes</b>	<b>Fréquence (GHz)</b>	<b>Longueur d'onde (cm)</b>	<b>Plate-formes</b>
<b>X</b>	12,5 à 8	2,4 à 3,8	CV-580 (radar aéroporté) Centre canadien de télédétection
<b>C</b>	8 à 4	3,8 à 7,5	Radarsat-1 & ERS-1 et 2
<b>S</b>	4 à 2	7,5 à 15	ALMAZ satellite soviétique lancé en 1991
<b>L</b>	2 à 1	15 à 30	SEASAT & J-ERS-1
<b>P</b>	225 à 400	75 à 133	NASA JPL AirSAR



**Figure 2-1. Mécanismes de dispersion d'une onde radar**  
(Figure rassemblée et adaptée de diverses sources)

La pénétration de l'onde radar dans le sol augmente avec la longueur d'onde tandis que les ondes courtes sont plus sensibles à la géométrie de la surface comme la rugosité ou la microtopographie (Ulaby *et al.*, 1982a). Par exemple, un radar en bande L est plus adapté à la mesure de l'humidité des sols qu'un radar en bande X. De plus, les radars qui opèrent en basses fréquences (bande L ou bande P) génèrent des ondes qui peuvent pénétrer facilement à travers la couverture forestière et entrent en interaction avec les branches et les troncs d'arbres. Ce phénomène est souvent utilisé pour acquérir des informations sur la biomasse des arbres car le signal retourné au capteur est très influencé par la densité de la surface interne ou la sous-surface des forêts. Par contre, les fréquences élevées comme la bande X, ont plus de tendance à rebondir sur la surface supérieure des arbres et fournissent des informations plus détaillées sur la surface supérieure des cibles observés (Ulaby *et al.*, 1982b). Le satellite canadien Radarsat-1 fonctionne à une seule fréquence soit 5,3 GHz ce qui correspond à une longueur d'onde de 5,6 cm (bande C). Cette bande a l'avantage de fournir en même temps des informations sur la surface supérieure et la sous-surface de la cible observée (RSI, 1995).

Une étude comparative de trois fréquences L, C et X a été effectuée par Kasischke et Christensen (1990). Dans cette étude, les auteurs ont utilisé un modèle de rétrodiffusion radar développé par Ulaby *et al.* (1990) pour évaluer l'effet de quelques paramètres physiques d'une couverture forestière sur la rétrodiffusion totale. Ce modèle a été validé dans un milieu forestier dominé par un espèce d'épinettes (*Pinus taeda L.*). Cette étude a permis aussi d'évaluer l'effet de la polarisation et de la fréquence du signal radar sur la rétrodiffusion. Les auteurs ont testé deux polarisations (HH et VV) et trois fréquences (L, C et X).

Nous avons donné un intérêt particulier à cette étude pour deux principales raisons. Premièrement, il existe une grande ressemblance structurale entre l'espèce végétale étudiée (*Pinus taeda L.*) et l'épinette noire (*Picea mariana*) qui domine largement la végétation arborée des milieux humides au Québec. Deuxièmement, les observations qui peuvent être tirées de cette étude peuvent être très utiles pour comprendre l'effet de certains paramètres de la végétation sur l'interaction des micro-ondes radar C-HH (comme celles de Radarsat-1). Ceci nous donnera des indices sur la discrimination possible des classes qui seront retenues pour cette thèse.

Parmi les paramètres étudiés, nous avons particulièrement porté notre attention sur la hauteur et la densité des arbres. Premièrement, la connaissance de la sensibilité du signal radar à la hauteur des arbres nous aidera à comprendre les différents comportements du signal face à la

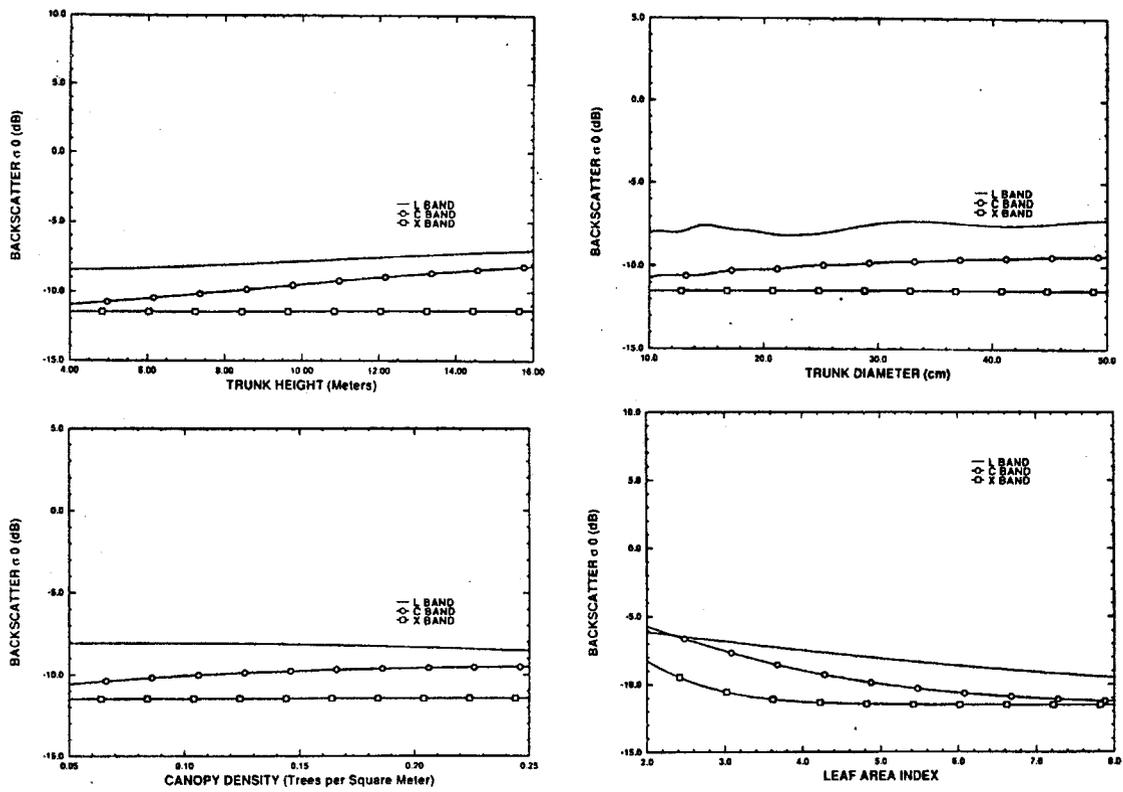
couverture arborée et la couverture arbustive des milieux humides. Deuxièmement, la connaissance de l'effet de la densité moyenne des arbres nous permettra de comprendre le comportement du signal face à une couverture moyennement arborée et une couverture fortement arborée.

En comparant le comportement du signal émis par trois fréquences (L, C et X), on observe que la bande C est la plus sensible à la variation de la densité et de la hauteur des arbres et ceci pour les deux polarisations HH et VV. Toutefois, cette sensibilité reste plus visible avec une polarisation VV (figure 2-3) qu'avec une polarisation HH (figure 2-2). Par exemple, en variant la hauteur d'arbres entre 4 et 16 mètres (figure 2-2), la rétrodiffusion totale augmente de 3 dB pour la bande C-HH en passant de -11 à -8 dB tandis qu'elle reste presque stable (variation inférieure à 0.5 dB) pour les fréquences L et X. Ceci nous laisse entendre que la bande C peut être utile dans la discrimination entre deux classes végétales en se basant sur la différence des hauteurs de leur couverture arborée.

Les mêmes conclusions peuvent être aussi tirées en observant la sensibilité de la bande C à la densité des arbres. Même si cette sensibilité reste faible (1,5 dB en variant la densité entre 0,05 et 0,25 arbres/m<sup>2</sup>) pour la bande C, elle reste supérieure à celles observées pour les bandes L et X (figure 2-3).

Les conclusions qui peuvent être tirées de cette étude sont les suivantes :

- La bande C est plus sensible à la variation de la hauteur et de la densité des arbres que les bandes L et X.
- La polarisation VV est nettement supérieure à la polarisation HH quand il s'agit de discriminer des classes végétales qui peuvent être différenciées par la hauteur et/ou la densité des arbres.



**Figure 2-2.** Les effets des paramètres structuraux de la végétation sur la rétrodiffusion totale d'un signal radar émis en bandes L, C et X et en polarisation HH (Kasischke and Christensen, 1990).

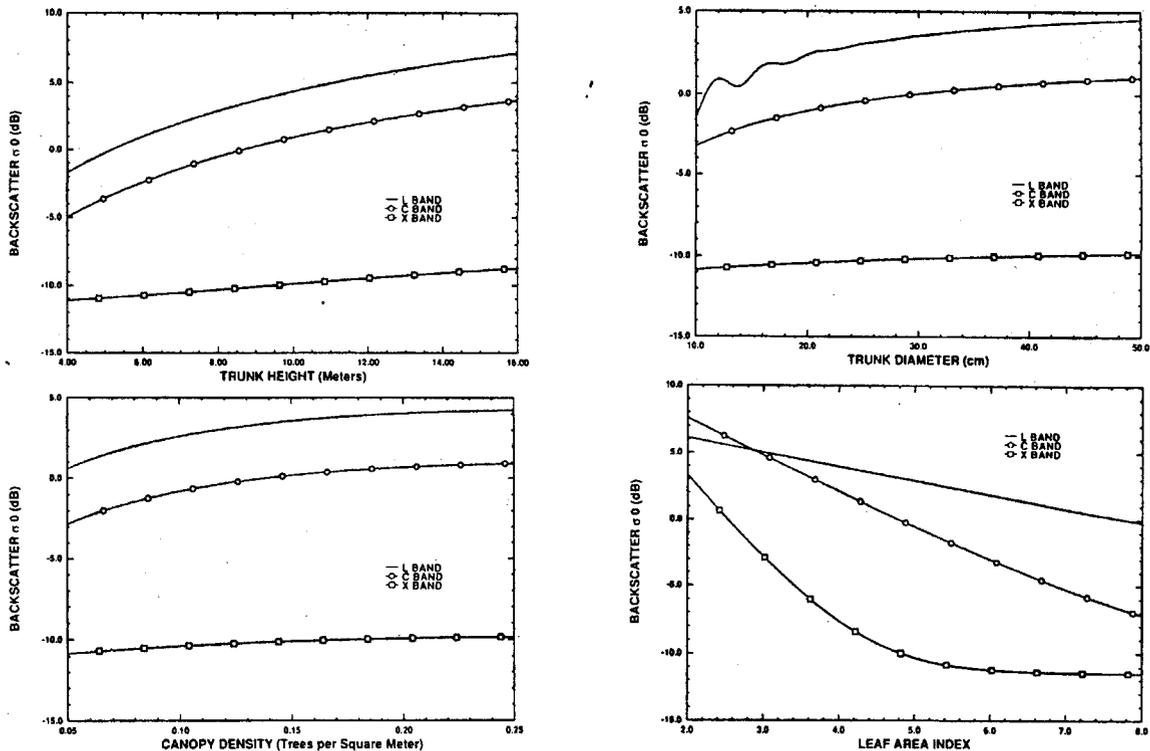
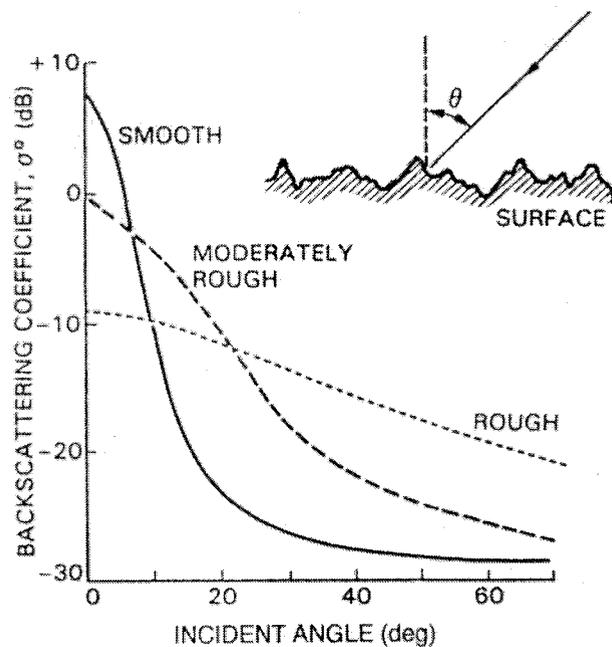


Figure 2-3. Les effets des paramètres structuraux de la végétation sur la rétrodiffusion totale d'un signal radar émis en bandes L, C et X et en polarisation **VV** (Kasischke and Christensen, 1990).

#### 2.2.4. Angle d'incidence

L'angle d'incidence est un paramètre très important dans l'interaction entre le signal et la surface de la terre. Ce paramètre a une grande influence sur le taux de pénétration des micro-ondes à travers une couverture végétale, sur la sensibilité de la rétrodiffusion par rapport à la rugosité de la surface, ainsi que sur l'effet du relief (Bonn et Rochon, 1992). Cependant, l'effet de l'angle d'incidence sur la rétrodiffusion diminue quand la rugosité du sol augmente (figure 2-4). Le choix d'un angle d'incidence dépend de l'information recherchée. Par exemple, si on s'intéresse plus à l'humidité du sol, il a été démontré qu'il est préférable d'utiliser des angles d'incidences compris entre 10 et 20 degrés (Ulaby *et al.*, 1978). Les critères utilisés pour le choix des angles d'incidences dans ce projet sont présentés en détail au troisième chapitre (§ 3.2.2).



**Figure 2-4.** Effet de l'angle d'incidence sur la rétrodiffusion radar (Lewis *et al.*, 1998)

Le graphique de la figure 2-4 montre bien l'effet de l'angle d'incidence sur la rétrodiffusion total pour trois catégories physiques de la surface d'interaction : surface lisse, surface rugueuse et surface moyennement rugueuse. La première observation qu'on peut le constater de ce graphique est que la rétrodiffusion radar est inversement proportionnelle à l'angle d'incidence du capteur quelque soit le degré de rugosité de la surface observée. Toutefois, des surfaces rugueuses restent moins sensibles à la variation de l'angle d'incidence que les surfaces lisses. Cette sensibilité est couramment observée quand les images contiennent des surfaces d'eau calme (pas de vent) qui apparaissent noir (rétrodiffusion très faible) avec des images à angle d'incidence élevé. Ces mêmes surfaces seront plus claires dans des images à faible angle d'incidence à cause d'une plus forte sensibilité aux faibles vagues. Cette caractéristique est couramment utilisée quand il s'agit de délimiter, par l'imagerie radar, l'étendue d'un déversement accidentel d'hydrocarbures dans la mer étant donné que les zones infectées sont plus lisses que les zones voisines (CCRS, 1998).

Radarsat-1 est capable de fournir 25 possibilités de choix d'images en orientant son faisceau sur une plage de 500 km (Tableau 2-3). Selon le mode d'acquisition choisi, les angles d'incidences varient de 10 degrés à 60 degrés. Cette variation permet d'offrir une gamme de faisceaux pouvant balayer des largeurs de couloirs (fauchée) variant entre 35 et 500 km et

obtenir des images avec une résolution variant entre 10 et 100 mètres selon la largeur du couloir utilisé.

**TABEAU 2-3.** Modes d'acquisition d'images du Radarsat-1 (*source : RSI, 1995*)

Mode d'acquisition et d'exploitation du faisceau		Plage de l'angle d'incidence (degrés)	Résolution : largeur et azimuth au sol (m x m)	Largeur de fauchée (km)
Faisceaux à haute résolution	F1	36,8 - 39,9	8,3 x 8,4	57
	F2	39,3 - 42,1	7,9 x 8,4	56
	F3	41,5 - 44,0	7,6 x 8,4	51
	F4	43,5 - 45,8	7,3 x 8,4	50
	F5	45,3 - 47,5	7,1 x 8,4	49
Faisceaux standards	S1	19,4 - 26,8	24 x 27	114
	S2	24,1 - 30,9	20 x 27	113
	S3	31,0 - 37,0	25 x 27	111
	S4	33,6 - 39,4	23 x 27	112
	S5	36,4 - 41,9	22 x 27	112
	S6	41,7 - 46,5	20 x 27	109
	S7	44,7 - 49,2	19 x 27	112
Faisceaux grand angle	W1	19,3 - 30,2	33 x 27	184
	W2	30,1 - 38,9	25 x 27	161
	W3	38,9 - 45,1	21 x 27	112
ScanSAR	SN1	19,3 - 38,9	50 x 50	335
	SN2	30,1 - 46,5	50 x 50	299
ScanSAR	SW1	19,3 - 49,2	100 x 100	518
	SW2	19,3 - 46,5	100 x 100	481
Faisceau prolongé à faible incidence	L1	10,4 - 22,0	39 x 27	167
Faisceaux prolongés à grande incidence	H1	49,0 - 52,4	18 x 27	non disponible
	H2	50,0 - 53,5	18 x 27	non disponible
	H3	51,2 - 54,6	17 x 27	102
	H4	54,4 - 57,1	17 x 27	90
	H5	55,5 - 58,2	16 x 27	non disponible
	H6	56,9 - 59,4	16 x 27	93

Une étude plus détaillée sur les critères utilisés dans le choix des angles d'incidence dans ce projet est présentée au quatrième chapitre (sections §3-2-2).

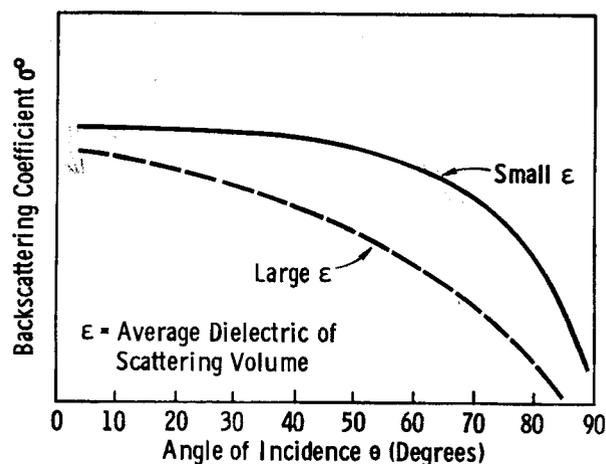
### 2.2.5. Sensibilité du signal radar à l'humidité

Pour les capteurs radar, la constante diélectrique joue un rôle important dans la rétrodiffusion. Cette constante permet d'acquérir des informations sur certaines propriétés volumiques des matériaux observés, comme l'humidité. La valeur de la constante diélectrique est

proportionnelle à l'humidité dans le sol. À cet effet, un sol humide a une constante diélectrique élevée, donc il apparaît plus clair qu'un sol sec dans une image radar (Boisvert *et al.*, 1995b).

La capacité d'une surface à réfléchir, absorber ou transmettre les micro-ondes dépend de ses propriétés diélectriques (Ulaby *et al.*, 1982a). La présence d'humidité dans un corps augmente sa constante diélectrique et amplifie la contribution de la diffusion de volume à la rétrodiffusion totale de la surface observée. La sensibilité de la rétrodiffusion radar à l'humidité est expliquée par le fait que la diffusion de volume d'un objet observé est causée par la discontinuité diélectrique qui existe dans le volume de cet objet. Ces discontinuités sont généralement aléatoirement dispersées dans ce volume (Ulaby *et al.*, 1982a). À cet effet, l'intensité du signal retourné d'une surface donnée peut varier selon l'humidité qu'elle contient. La détection radar de l'humidité dans le sol est basée sur la mesure de la distribution volumique de l'eau dans le sol. Ces informations sont très utiles dans la prévision des sécheresses et dans plusieurs applications en agriculture.

Toutefois, Ulaby *et al.*, (1982a) et Dawson *et al.*, (1997) ont observé que les effets de l'humidité du sol (diffusion de volume) et des paramètres du rugosité de surface (diffusion de surface) ne peuvent pas être dissociés et contribuent conjointement à la rétrodiffusion totale de la surface observée. La contribution exacte de l'humidité à la rétrodiffusion reste difficile à quantifier.



**Figure 2-5.** Effet de la constante diélectrique moyenne ( $\epsilon$ ) et de l'angle d'incidence sur la rétrodiffusion radar (Ulaby *et al.*, 1982a).

Concernant l'effet de la constante diélectrique moyenne ( $\epsilon$ ) sur la variation de la rétrodiffusion radar versus angle d'incidence, Ulaby *et al.*, (1982a) ont observé qu'en augmentant l'angle d'incidence, la rétrodiffusion décroît plus rapidement avec une constante diélectrique élevée qu'avec une constante diélectrique faible (Figure 2-5). Ces observations montrent aussi qu'un milieu très humide est plus sensible à la variation de l'angle d'incidence qu'un milieu sec (ou moins humide). Cette caractéristique va être exploitée dans le cadre de cette thèse en utilisant des données acquises avec deux angles d'incidences différents (S1 et S7). En effet, étant donnée la forte dépendance de la rétrodiffusion d'un milieu humide à l'angle d'incidence utilisé, l'utilisation de deux angles d'incidences peut apporter une dimension supplémentaire à la discrimination entre des milieux à humidité différente.

Plusieurs chercheurs ont utilisé ces caractéristiques pour le suivi de l'évolution des teneurs en eau, le développement et la validation de modèles d'humidité des sols, la distribution spatiale des précipitations, l'estimation des réserves en eau au printemps et à l'automne, la détection de la variabilité hydrique des champs et le rehaussement des problèmes de drainage (Boisvert *et al.*, 1995a).

La constante diélectrique est reliée à l'humidité du sol par une relation polynomiale (Boisvert *et al.*, 1995b). L'énergie micro-onde pénètre le sol à une profondeur qui dépend de la constante diélectrique et des paramètres du capteur comme la polarisation, la fréquence et l'angle d'incidence. La profondeur de pénétration des micro-ondes radar dans le sol est proportionnelle au degré de sécheresse du sol. À cet effet, quand le sol est humide (proche de la saturation), la rétrodiffusion vient principalement de la surface du sol puisque les micro-ondes n'y pénètrent pas (Boisvert *et al.*, 1997). Toutefois, il est difficile d'estimer l'humidité du sol sans tenir compte de la rugosité de la surface surtout dans le cas où on utiliserait une seule configuration radar. Pour une même humidité du sol, une surface lisse a moins de rétrodiffusion qu'une surface rugueuse car le signal rétrodiffusé est dominé par la réflexion spéculaire.

La valeur de la constante diélectrique a une grande influence sur le comportement et sur la direction d'une onde émise par un capteur radar. Cependant, lorsqu'une onde radar entre en contact avec une interface de deux milieux ayant deux constantes diélectriques très différentes, une grande portion de l'énergie incidente se diffuse à l'interface ce qui donne une diffusion de surface. Par exemple, la constante diélectrique de l'eau est largement supérieure à celle de l'air. À cet effet, lorsqu'une onde électromagnétique atteint l'interface air/eau, la majorité de

l'énergie incidente, ou même la totalité, sera réfléchiée en surface. L'eau calme apparaîtra alors en noir sur une image radar. Ce phénomène a été défini par Ulaby *et al.* (1982a,b) comme suit :

$$\sigma_{surface}^0 = A(\epsilon_m) \cdot B(r) \quad (2.1)$$

où  $\sigma_{surface}^0$  est la diffusion de la surface d'un milieu homogène

$A(\epsilon_m)$  est la réflectivité de Fresnel (fonction de la constante diélectrique entre les deux milieux)

$B(r)$  est une fonction qui dépend de la rugosité de la surface

La constante diélectrique ( $\epsilon$ ) est représentée par un nombre complexe ayant la forme suivante :  $\epsilon = \epsilon' + j \cdot \epsilon''$  avec  $j = \sqrt{-1}$  (où  $\epsilon'$  et  $\epsilon''$  représentent respectivement la partie réelle et la partie imaginaire de  $\epsilon$ ).

La valeur de  $\epsilon'$  varie généralement entre 2,5 (pour un sol sec) et 80 pour l'eau. Pour un sol humide, la valeur de  $\epsilon'$  la partie réelle de la constante diélectrique ( $\epsilon'$ ) peut atteindre une valeur maximale de 25 pour un sol saturé d'eau. Le contraste entre un sol sec et un sol humide peut varier selon la composition du sol et la fréquence radar utilisée (Dawson *et al.*, 1997).

### **2.3. Télédétection des milieux humides**

Plusieurs recherches ont été réalisées pour évaluer l'apport de la télédétection dans des applications de suivi et de cartographie des milieux humides (Sader *et al.*, 1995; Ramsey III *et al.*, 1997; Kasischke and Borgeau-Chavez, 1997; Livingston *et al.* 1998; Townsend, 2002). La télédétection représente un outil irremplaçable pour ce genre d'application vu la grande superficie et l'accessibilité difficile des ces milieux. La plupart des capteurs d'observation de la Terre ont été testés dans ces travaux. Il s'agit des plates-formes satellitaires et aéroportées utilisant des capteurs opérant dans le visible, le proche infrarouge et les micro-ondes.

#### **2.3.1. Utilisation des données optiques (visible et proche infrarouge)**

Les données optiques de télédétection ont été largement utilisées pour l'étude des milieux humides (Seuthé et Buteau, 1994; Sader *et al.*, 1995; Ramsey III and Jensen, 1996; Ramsey III *et al.*, 1997 et 1998). Ces données ont l'avantage d'avoir plusieurs bandes spectrales qui

couvrent une large partie du spectre électromagnétique. Ces bandes qui opèrent dans le visible et le proche infrarouge apportent une source d'information diversifiée utile à la discrimination de la végétation dans la scène observée.

Parmi ces études, des données aéroportées optiques (MSS) ont été utilisées par Christensen *et al.* (1988) pour la classification de la couverture végétale des milieux humides en Caroline du Sud (États Unis). Ces auteurs ont obtenu une classification des grandes classes végétales de ces milieux avec une précision comprise entre 84 et 87 %. Toutefois, les erreurs accumulées pendant l'acquisition des images ont affecté considérablement la précision des résultats. Ces erreurs ont été causées essentiellement par l'instabilité du capteur aéroporté produisant une grande distorsion radiométrique et géométrique dans les images.

Concernant l'utilisation des capteurs optiques satellitaires, on peut citer comme exemple Sader *et al.* (1995) qui ont utilisé les trois bandes TM3, TM4 et TM5 de Landsat pour différencier les milieux humides arborés des forêts. Plusieurs méthodes de classifications supervisées et non supervisées ont été utilisées pour discriminer entre des composantes des milieux humides et des milieux forestiers. Les précisions de classification obtenues sont comprises entre 74 % et 82 %. Cependant, les auteurs ont observé qu'une grande confusion existe entre les milieux forestiers et les milieux humides arborés. Celle-ci est due principalement à la grande ressemblance qui existe entre la structure de ces deux classes végétales. Cette confusion reste l'occupation majeure des spécialistes des milieux humides quand il s'agit d'introduire les techniques de télédétection dans leurs outils d'inventaire (Warner, 2000; Garneau, 2000). Nous essayons dans le cadre de cette thèse d'évaluer l'apport des images multi-angles d'incidences de Radarsat-1 dans la discrimination de cette zone limitrophe des milieux humides.

### **2.3.2. Utilisation des capteurs radar**

Kasischke et Borgeau-Chavez (1997) ont défini trois caractéristiques majeures des images radar les rendant uniques dans la cartographie des milieux humides. Ces caractéristiques ne sont pas disponibles avec les capteurs opérant dans le visible et le proche infrarouge. Premièrement, l'énergie micro-onde émise par un radar est capable de pénétrer la plupart des couvertures végétales. Une grande partie de l'énergie rétrodiffusée au capteur sera donc le résultat de plusieurs interactions électromagnétiques au niveau du sol. Deuxièmement, la rétrodiffusion radar d'un milieu couvert par la végétation est très liée à la constante diélectrique du sol et de la végétation. Ainsi, la présence ou l'absence de l'eau au sol affecte

considérablement la signature captée de ces milieux. La troisième importante caractéristique est que les capteurs radar peuvent opérer indépendamment de la couverture nuageuse et de l'illumination solaire.

Dans le cadre du développement d'applications du radar dans des problématiques liées à l'observation de la Terre, plusieurs chercheurs ont testé, depuis le début des années quatre-vingt, la potentialité de cette technologie comme outil de surveillance et de cartographie des milieux humides. Dans le cadre de ces études, plusieurs systèmes radar satellitaires, comme l'ERS-1 et 2 de l'Europe, le JERS-1 du Japon et le SIR-C des États Unis et différents types de capteurs radar aéroportés ont été testés.

Le potentiel d'un RSO aéroporté en bande C a été examiné par Mullins et Leconte (1993) pour détecter le changement de l'humidité dans les milieux humides nordiques dans la région de la baie d'Hudson. Toutefois, avec une simulation de la résolution des données Radarsat-1 en mode Standard, il s'est avéré impossible d'estimer les changements saisonniers des surfaces d'eau à cause de la petite taille des mares dans ce type de milieux. Dans une autre étude, Pope *et al.* (1994) ont montré que la variation de l'écosystème des milieux humides peut être détectée avec des données radar aéroportées et cela dans les trois bandes spectrales P, L et C. Aussi, des données RSO aéroporté (Convair 580 du Centre Canadien de Télédétection) ont été utilisées par Baghdadi *et al.* (2001) pour la discrimination des classes végétales dans des milieux humides de la région d'Ottawa. Dans cet article, les auteurs ont testé une série d'images temporelles acquises avec quatre polarisations différentes (HH, HV, VH et VV). Les meilleurs résultats de classification ont été obtenus avec des images acquises en automne (octobre) avec les polarisations HV (76 %), VH (76 %), et HH (74 %). La polarisation VV a donné le plus faible discrimination entre les classes avec seulement 59 % des pixels classés.

La première application des données satellitaires radar dans la cartographie des milieux humides a été réalisée par Harris et Digby-Argus (1986) dans le centre et l'Est de l'Ontario à l'aide des images acquises par le satellite radar SEASAT (États Unis). Dans cette étude, les auteurs ont montré que les milieux humides peuvent facilement se distinguer de la forêt et des terres agricoles. Toutefois, les auteurs n'ont pas testé l'efficacité de ces images dans la discrimination des composantes végétales des milieux humides.

Des études menées par Kasischke et Borgeau-Chavez (1997) dans le sud de la Floride ont montré l'utilité des images RSO du satellite européen ERS-1 pour inventorier les communautés

végétales des milieux humides. Ils ont réussi à séparer les milieux humides herbacés des milieux humides arbustifs en utilisant deux images acquises à deux périodes différentes correspondant aux périodes humide (octobre) et sèche (avril). Ces auteurs ont montré que la rétrodiffusion radar dans les milieux humides est affectée principalement par la structure de la végétation, l'humidité du sol, la rugosité de la surface et de la présence de l'eau stagnante au dessous des arbres. Ainsi, ils ont montré que l'effet de la présence d'une couche d'eau stagnante sur la rétrodiffusion radar dépend de la composition de la végétation. En effet, une nappe d'eau visible augmente la rétrodiffusion si la végétation est dominée par des arbres ou des arbustes et la diminue dans le cas d'une végétation herbacée.

Toutefois, certaines réticences ont été observées dans l'utilisation de l'imagerie radar pour la cartographie de la végétation étant donné que jusqu'à maintenant, tous les satellites de télédétection radar disposent d'une seule fréquence d'acquisition (C ou L). En effet, une étude menée par Wang *et al.* (1998) ont montré qu'on n'est pas capable de classifier des milieux humides avec une seule image ERS-1 puisque l'information spectrale contenue dans un seul canal n'est pas suffisante pour discriminer plusieurs types de couverture végétale.

Cependant, des analyses multi-temporelles, telle que celle effectuée par Kasischke et Borgeau-Chavez (1997) avec des données radar, ont montré que ce type de données ont certainement un avenir prometteur pour la cartographie et la classification des milieux humides. En effet, le nombre d'images utilisées dans un processus de classification accroît la précision escomptée. Chaque image est en fait considérée comme une bande à part en faisant une analogie avec les images multi-spectrales des capteurs optiques (Milne and Horne, 1998 ; Livingstone *et al.*, 1998, Townsend, 1998).

Dans ce projet, nous essayons aussi de surmonter le problème de la bande unique en utilisant des images avec des angles d'incidences différents. En effet, le satellite Radarsat-1 a ouvert la voie au développement de nouvelles applications en offrant la possibilité de choisir un mode d'acquisition parmi une multitude d'angles d'incidences (tableau 2-3). Depuis sa mise en opération en avril 1996, plusieurs études ont été effectuées (Symposium ADRO, 1998) pour évaluer l'apport de ses données RSO dans plusieurs applications qui touchent la surveillance de l'environnement et l'analyse des ressources naturelles. Plusieurs auteurs ont d'ailleurs compensé la limitation des images Radarsat-1 avec leur bande et polarisation unique (C-HH) en utilisant une série temporelle d'images couvrant le cycle saisonnier du phénomène observé.

Plusieurs travaux ont été effectués pour évaluer la performance de l'imagerie Radarsat-1 dans la cartographie de la couverture végétale des milieux humides. La plupart de ces recherches ont été motivées par la mise en place de programmes de soutien pour promouvoir l'utilisation des données Radarsat-1 dans des applications d'observation de la Terre (Symposium ADRO, 1998). Ces travaux ont été effectués sur des milieux humides au Canada, en Australie, en Russie et aux États Unis. Plusieurs modes d'acquisitions de Radarsat-1 ont été aussi testés : le mode Fin à haute résolution, le mode Standard, et le mode ScanSAR (tableau 2-3).

Parmi ces applications, on trouve Livingston *et al.* (1998) qui ont utilisé une série temporelle des images ScanSAR de Radarsat-1 pour surveiller les changements saisonniers et les inondations dans les milieux humides de la Sibérie. Ils ont ainsi étudié l'influence de la végétation émergente sur la rétrodiffusion radar. Dans le cadre de ces travaux, les auteurs ont réussi de séparer les milieux humides inondés et non inondés avec une précision comprise entre 80 % et 90 % au moyen d'une série temporelle des images ScanSAR (angles d'incidences entre 30 et 38 degrés).

Les données Radarsat-1 en mode ScanSAR ont été aussi utilisées par Milne (1998a,b) avec des données en mode Standard (S4) pour faire un suivi des inondations des milieux humides en Australie. Ces études avaient pour but aussi de détecter les changements survenus dans la structure végétale entre la saison sèche et la saison des précipitations. Le choix de l'imagerie Radarsat-1 a été motivé essentiellement par la sensibilité de la bande C à la structure de la couverture végétale. Cette sensibilité peut être décelée dans l'apparence de la texture de l'image. Ils ont étudié aussi la capacité des données C-HH de détecter la présence de l'eau stagnante au-dessous des arbres. Ces études ont montré la forte sensibilité du signal en mode ScanSAR et S4 à l'humidité du sol et sa grande variation entre la saison sèche et la saison humide. Les auteurs ont conclu qu'une série multi-temporelle des images Radarsat-1 peut donner des résultats comparables à des données optiques multi-bandes.

Le mode d'acquisition Standard de Radarsat-1 a été utilisé par Townsend (1998) pour mesurer l'étendu des inondations dans des milieux humides arborés en Caroline de Nord (États Unis). Dans cette étude, onze images en mode standard (S1, S2 et S6) ont été testées. Les angles d'incidences de ces trois modes varient entre 20° (S1) et 46° (S6). Les dates d'acquisition de ces images ont été choisies en fonction de l'évolution hydrologique du site d'étude. Suite à ces travaux, l'auteur a conclu que tous les modes d'acquisition offrent les mêmes précisions dans la délimitation des zones inondées. Ainsi les images Radarsat-1 en mode Standard sont plus

sensibles au gradient hydrologique de la scène observée qu'à la structure de la végétation. La précision obtenue dans la délimitation des zones inondées est presque semblable pour tous les modes utilisés (S1, S2 et S7) et quelle que soit la composition structurale des arbres (avec ou sans feuilles).

Le mode d'acquisition Fin de Radarsat-1 a été utilisé par Howarth *et al.* (1998) dans l'identification des espèces végétales des milieux humides dans le sud de l'Ontario. Dans cette étude, les auteurs ont intégré des images en mode (F1) et des données ERS-1 aux images optiques (SPOT-XS et Landsat TM). Ils ont ainsi vérifié si l'ajout des données radar peut améliorer l'efficacité d'une classification. Une méthode de classification par maximum de vraisemblance a été utilisée. Les meilleurs résultats (85 %) ont été obtenus en utilisant les bandes 3,4 et 5 de Landsat TM avec le mode Fin de Radarsat-1. Toutefois, une classification avec une seule image Radarsat-1 offre une précision de l'ordre de 58 % ce qui est beaucoup moins performant que celle obtenue avec une image Landsat multi-bandes seule qui est de l'ordre de 80 %. Par contre, cette précision reste supérieure à celle obtenue avec ERS-1 (41 %). Les auteurs ont expliqué cette supériorité des données en mode Fin de Radarsat-1 à la résolution spatiale et à l'angle d'incidence plus élevé de ces derniers.

Toutefois, concernant la cartographie de l'étendu des milieux humides côtiers dans le Sud de l'Ontario, ces mêmes auteurs ont conclu qu'une seule image Radarsat-1 en mode Fin peut être utile. La précision obtenue avec ce mode d'acquisition (92 %) est comparable avec celle obtenue avec l'image SPOT. Néanmoins, les données radar ont plus de risque de confondre la surface du Lac de l'Ontario avec des couvertures végétales des milieux humides.

Comme il a été démontré par Howarth *et al.* (1998), le couplage des images radar avec des données optiques (comme Landsat TM) apporte une amélioration de 5 % dans la précision des résultats et surtout dans la discrimination entre les composantes végétales des milieux humides. Cette option a été écartée dans ce projet étant donné que l'objectif secondaire de la thèse est d'évaluer le potentiel de l'imagerie Radarsat-1 pour la cartographie des milieux humides en se basant sur la physique de l'interaction entre l'onde radar et les composantes de ces milieux.

Cependant, l'inconvénient des données radar de confondre quelques couvertures végétales avec les surfaces d'eau peut être résolu en procédant en deux étapes : (1) délimiter les milieux humides des milieux voisinant et (2) augmenter la précision de la classification en classifiant

uniquement les zones définies comme milieux humides dans la première étape de classification.

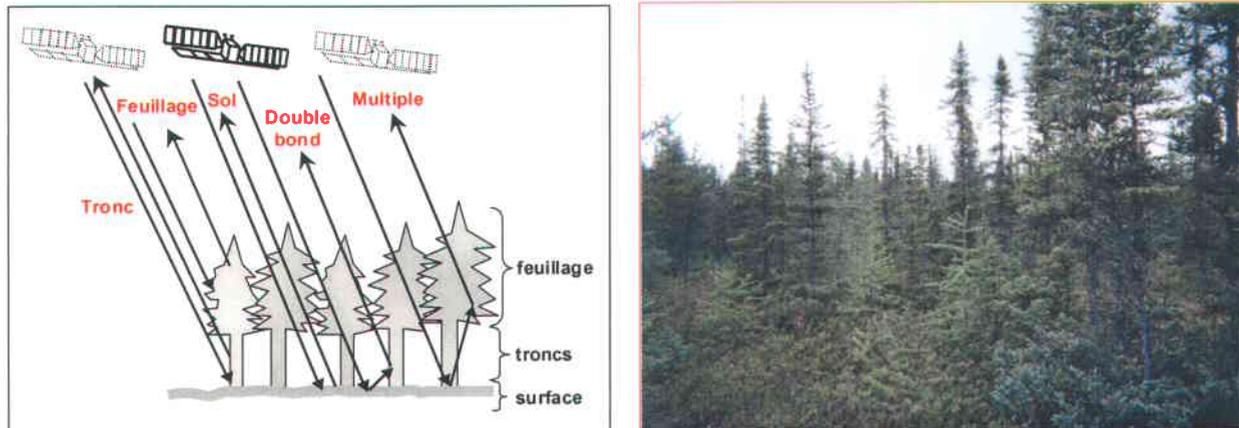
### **2.3.3. L'interaction du signal radar avec les milieux humides.**

Les milieux humides sont constitués d'un mélange complexe de plusieurs types de végétation herbacées, arbustives et arborescentes et des sols mal drainés dominés par une végétation hydrophile submergée ou flottante (Buteau *et al.*, 1994). L'exploration de la capacité de l'imagerie radar pour discriminer les composantes de ces milieux nécessite une connaissance approfondie des mécanismes de rétrodiffusion des micro-ondes radar avec les différentes composantes de la végétation et du sol. Plusieurs travaux de recherche ont été menés pour modéliser l'interaction de l'onde radar avec des différents types de végétation. Ces travaux ont permis d'évaluer l'effet de chaque composante sur la quantité d'énergie retournée au satellite. La vérification de ces modèles dans des applications faisant recours à des données spatiales reste limitée vu que les intrants requis sont difficiles à mesurer sur le terrain sur une grande échelle. En plus, la plupart de ces paramètres ont une distribution aléatoire dans l'espace et dans le temps surtout dans le cas d'un vaste milieu naturel comme les milieux humides.

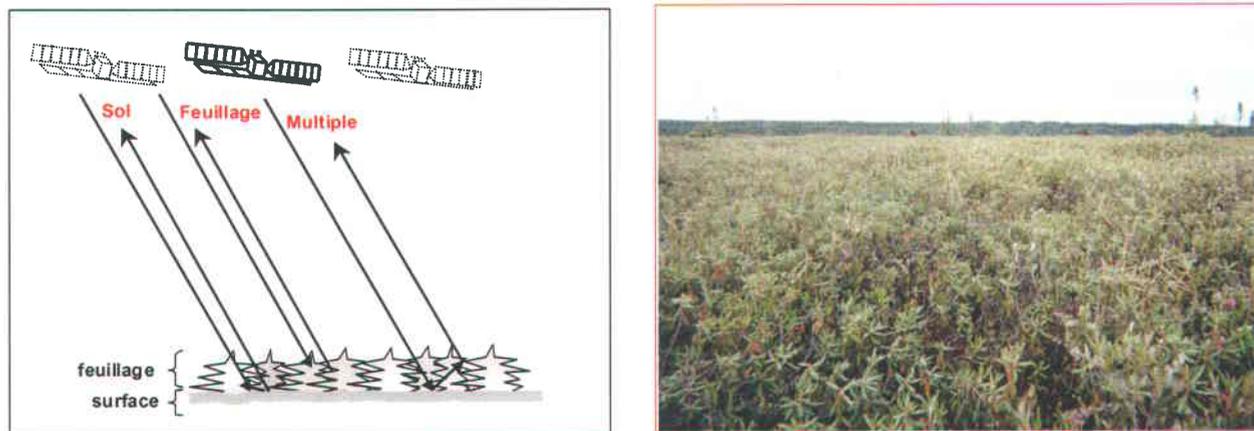
Ulaby *et al.* (1986) ont publié dans un livre de trois tomes une étude complète et détaillée sur la physique de l'interaction des micro-ondes avec la scène observée. La théorie présentée dans ces livres a été prise comme référence dans la plupart des publications liées à la modélisation de l'interaction radar. En partant de ces travaux, nous essayons dans ce chapitre de comprendre les mécanismes qui interviennent lors de l'interaction entre l'onde radar et les composantes végétales des milieux humides. Ceci permettra de bien choisir les intrants (dates et modes d'acquisition) selon les besoins de l'étude et selon l'information escomptée.

La caractéristique fondamentale d'une image radar réside dans la variation spatiale du coefficient de rétrodiffusion radar ( $\sigma^0$ ). Pour comprendre le sens physique qui existe entre ce coefficient et la couverture végétale comme celle des milieux humides, Ulaby *et al.* (1986) ont recommandé de séparer cette couverture en plusieurs niveaux et d'étudier l'effet de chaque niveau sur la rétrodiffusion totale. En utilisant ce principe, Kasischke et Bourgeau-Chavez (1997) ont défini trois niveaux distincts de végétation pour des milieux humides composés des arbres et des arbustes. Le premier niveau, composé de feuillage et de petites branches, représente la couverture supérieure de la végétation qui peut être visible d'en haut. Le deuxième niveau, spécifique aux milieux humides arborés, est composé uniquement de troncs

d'arbres. La surface du sol représente le troisième niveau. Elle peut être couverte par l'eau et elle est généralement dominée par une végétation hydrophile. Cependant, la configuration des milieux humides arbustifs peut être simplifiée en deux niveaux. Les deux figures 2-6 et 2-7 représentent schématiquement, les deux mécanismes d'interaction pour un milieu arboré et un milieu exclusivement arbustif avec des photos prises dans deux milieux humides différents de la région du lac Saint-Jean (Québec, Canada).



**Figure 2-6.** Mécanismes d'interaction dans un milieu arboré (adaptée de Kasischke and Bourgeau-Chavez, 1997).



**Figure 2-7.** Mécanismes d'interaction dans un milieu arbustif (sans troncs) (adaptée de Kasischke and Bourgeau-Chavez, 1997).

D'après des études menées par Dobson *et al.* (1995), la rétrodiffusion radar d'une couverture végétale peut être exprimée de deux façons selon la présence (équation 2.1) ou l'absence des troncs d'arbres (équation 2.2).

$$\sigma_{t-w}^0 = \sigma_c^0 + T_c^2 \cdot T_t^2 (\sigma_m^0 + \sigma_t^0 \cdot \sigma_s^0 + \sigma_d^0) \quad (2.1)$$

$$\sigma_{t-h}^0 = \sigma_c^0 + T_c^2 (\sigma_s^0 + \sigma_m^0) \quad (2.2)$$

Où :

- $\sigma_{t-w}^0$  : Le coefficient de rétrodiffusion totale d'une végétation arborée
- $\sigma_{t-h}^0$  : Le coefficient de rétrodiffusion totale d'une végétation arbustive ou herbacée (non arborée)
- $\sigma_c^0$  : Le coefficient de rétrodiffusion des petites branches et du feuillage
- $\sigma_m^0$  : Le coefficient de rétrodiffusion multiple entre le sol et le feuillage
- $\sigma_t^0$  : Le coefficient de rétrodiffusion direct des troncs
- $\sigma_s^0$  : Le coefficient de rétrodiffusion direct du sol
- $\sigma_d^0$  : Le coefficient de rétrodiffusion d'interaction entre le sol et les troncs d'arbres
- $T_c$  : Le coefficient de transmission des micro-ondes à travers le feuillage
- $T_t$  : Le coefficient de transmission des micro-ondes à travers les troncs d'arbres

Les valeurs de la rétrodiffusion et les coefficients de transmission utilisés dans les équations 3.1 et 3.2 sont directement proportionnelles à la constante diélectrique de la végétation et du sol. Leurs valeurs varient aussi en fonction du type de la végétation, de la longueur d'onde et de la polarisation du signal incident (Kasischke and Bourgeau-Chavez, 1997). Les coefficients de transmission  $T_t$  et  $T_c$  atténuent le signal dans les deux sens (émission et rétrodiffusion) c'est ce qui explique la mise de leurs valeurs au carré. La valeur de ce coefficient dépend de l'angle d'incidence ( $\theta$ ) et de l'épaisseur optique du milieu atténuant ( $\tau$ ), elle est calculée par l'équation 2.3.

$$T^2(\theta) = \exp\left(\frac{-2 \cdot \tau}{\cos(\theta)}\right) \quad (2.3)$$

La rugosité et le coefficient de réflexion sont deux propriétés du sol qui ont un effet non négligeable sur la quantité totale de la rétrodiffusion. En général, une rugosité élevée augmente la rétrodiffusion directe du sol ( $\sigma_s^0$ ) et fait décroître la rétrodiffusion multiple ( $\sigma_m^0$ ) et l'interaction

( $\sigma_d^0$ ). Le coefficient de réflexion du sol dépend directement de la constante diélectrique. Alors, une augmentation de l'humidité du sol fait croître la constante diélectrique et par conséquent la rétrodiffusion directe du sol ( $\sigma_s^0$ ).

La présence d'une couche d'eau au sol a aussi un effet sur la rétrodiffusion des micro-ondes. Toutefois, la présence de l'eau élimine l'effet de la rugosité du sol et fait décroître son coefficient de réflexion. Par conséquent, l'absence de l'effet de la rugosité engendre l'élimination de la rétrodiffusion directe du sol et augmente considérablement la rétrodiffusion multiple ( $\sigma_m^0$ ) et le double bond ( $\sigma_d^0$ ), (Kasischke and Bourgeau-Chavez, 1997).

Si on s'intéresse uniquement à la couverture végétale, l'effet du sol sur la rétrodiffusion radar représente une source indésirable du bruit. Pour éviter l'effet indésirable du sol, Ulaby *et al.* (1986) ont suggéré l'utilisation des angles d'incidences supérieurs à 20 ou 30 degrés. La rétrodiffusion radar décroît rapidement en augmentant l'angle d'incidence entre la normale et 20 degrés. Au-delà de 20 degrés, le coefficient de rétrodiffusion décroît lentement avec l'augmentation des angles d'incidence. Avec des angles d'incidences supérieurs à 20 degrés, le coefficient de rétrodiffusion du sol dépasse rarement 0 dB avec une polarisation HH ou VV et il est souvent inférieur à -10 dB.

D'après une étude comparative de la performance de plusieurs modèles de rétrodiffusion, Ulaby *et al.* (1986) ont conclu que pour une couverture végétale donnée, la contribution de la surface du sol et de la couverture végétale à la rétrodiffusion radar est gouvernée par plusieurs facteurs géométriques et diélectriques de la surface du sol et du volume de la végétation. En effet, la valeur de la rétrodiffusion est largement influencée par les propriétés structurales et diélectriques de la végétation (Dobson *et al.*, 1995).

Plusieurs types de problèmes peuvent être rencontrés lors de la modélisation de l'interaction de l'onde radar avec une couverture végétale (Ulaby *et al.*, 1986). Premièrement, il est très difficile d'établir un modèle qui décrit adéquatement la composition de la végétation (orientation des feuilles et des branches, hauteur et épaisseur des troncs, constante diélectrique des feuilles... etc.). En plus, il est très difficile de synchroniser la mesure de ces paramètres, assez variables, avec le passage du satellite lors de l'acquisition de l'image. L'absence de ces informations oblige souvent les utilisateurs à simplifier l'écriture mathématique de leurs modèles pour arriver à un système d'équations facile à résoudre. Dans d'autres cas, les utilisateurs ont été obligés

de faire des suppositions ou de fixer des hypothèses sur quelques paramètres tout en étant conscients que ceci affecte considérablement la performance de leur modèle.

La plupart des couvertures végétales sont constituée par trois groupes de composantes soit les feuilles, les branches et les fruits. Chacune de ces composantes a une orientation spécifique, une distribution volumétrique et une constante diélectrique propre. En plus, le phénomène de rétrodiffusion devient plus compliqué lorsque la taille de l'une de ces composantes devient semblable à la longueur d'onde émise par le radar (de l'ordre de 5 cm pour Radarsat-1) ce qui est le cas dans plusieurs situations.

Pour évaluer la rétrodiffusion radar d'une couverture végétale complexe, il est nécessaire de procéder étape par étape pour chaque niveau de végétation. Plusieurs modèles ont été développés pour comprendre le cheminement de l'onde radar à travers les composantes de la scène observée et pour évaluer l'apport de chaque composante à la quantité d'énergie retournée au satellite (Ulaby *et al.*, 1990, Dobson *et al.*, 1995, Karam *et al.*, 1995, Magagi *et al.*, 2002a).

Parmi ces travaux, Magagi *et al.*, (2002a) ont adapté un modèle théorique de rétrodiffusion radar d'un couvert de végétation fermée (développé par Karam *et al.*, 1995) à des applications quantitatives de l'interaction du signal radar de Radarsat-1 (C-HH) avec un couvert de végétation ouverte. Cette approche a été utilisée pour simuler les coefficients de rétrodiffusion d'un couvert végétal dominé par les épinettes noires (*Picea mariana*). Cette espèce domine largement la flore des milieux humides dans la région boréale et le Sud de Québec. Par le biais de ce modèle, les auteurs ont mis en évidence que l'humidité du sol et l'angle d'incidence sont les deux principaux facteurs qui déterminent l'importance relative de la diffusion de surface (sol) par rapport à une diffusion de volume (végétation) pour une forêt donnée. Ces conclusions confirment que les observations faites par Ulaby *et al.* (1986) pour une couverture arborée standard peuvent être appliquées à une végétation dominée par l'épinette noire, une espèce omniprésente dans la plupart des milieux humides de Québec. Nous y reviendrons d'ailleurs à la section § 3-2.2 lorsque nous discutons du choix des angles d'incidences.

## **2.4. Conclusion**

Ce chapitre nous a permis de comprendre le comportement du signal radar de Radarsat-1 face aux différentes composantes des milieux humides (objectif secondaire de la thèse) et vérifier

«théoriquement» la validité de la première hypothèse de la thèse qui consiste à évaluer le pouvoir des données Radarsat-1 à discriminer entre les composantes végétales des milieux humides. Le comportement du signal radar avec les grandes compositions végétales des milieux humides sera évalué dans les chapitres suivants dans un contexte réel de classification.



## CHAPITRE 3

### **Acquisition et traitement des données**

---

Ce chapitre est divisé en trois grandes parties. La première partie explique le choix du site d'étude et décrit les données disponibles et les conditions de leur acquisition. La deuxième partie expose une interprétation visuelle et analytique des données. La dernière partie présente les traitements préliminaires effectués sur les données radar brutes avant leur classification par les réseaux de neurones.

#### ***3.1. Site d'étude***

La région du Lac St-Jean a été choisie comme site d'étude dans ce projet. Le choix de cette région a été motivé essentiellement par deux raisons. Premièrement, cette région de Québec contient une diversité de milieux humides qui couvrent de grandes étendues non loin des centres urbains et facilement accessibles par voie terrestre. Deuxièmement, à l'été 1998, la plupart des milieux humides de cette région ont fait l'objet d'un inventaire détaillé de la végétation et de la composition de la tourbe par la société sylvicole de Mistassini. Cet inventaire avait pour but de définir la vocation de ces territoires et d'identifier les milieux propices à l'exploitation (tourbe, forêts, cultures maraîchères...etc.). Ces données, ainsi qu'une image Landsat-TM de la région ont été mis à la disposition de ce projet par le Ministère des ressources naturelles du Québec (MRN). Les milieux humides choisis dans ce projet se trouvent sur les rives Nord et Est du lac St-Jean à une latitude de 48°50' Nord et une longitude de 72°00' Ouest (figure 3-1).

### 3.2. Acquisition des images

Au début du projet, 12 images Radarsat-1 de la région du Lac St-Jean ont été commandées (six en mode S1 et six autres en mode S7) avec deux mois d'intervalle entre chaque deux images. Le choix du nombre et des dates d'acquisitions avait pour but de couvrir le cycle hydrologique des milieux humides par les deux modes S1 et S7 afin d'étudier l'effet de la date d'acquisition sur la rétrodiffusion radar. Cependant, une commande d'image d'hiver en mode S1 et trois images d'automne et d'été en mode S7 ont été annulées à cause d'une programmation prioritaire du satellite (voir tableau 3-1).

Finalement, seulement huit images ont été reçues sur une période allant du 03 août 1998 au 11 juin 1999 (tableau 3-1). Toutes les images ont été acquises en orbite ascendante. Les images ont été calibrées par l'Agence spatiale canadienne (ASC) et livrées en format SGF (16 bits). Les critères utilisés dans le choix du mode d'acquisition Standard et de deux angles d'incidence S1 et S7 sont présentés aux sections §3-2-1 et §3-2-2.

Étant donné le faible relief des milieux humides, la direction d'acquisition (ascendante ou descendante) n'a pas un effet significatif sur les mécanismes d'interaction du signal. Toutefois, nous avons opté pour une orbite ascendante juste pour éviter les effets indésirables de la rosée ou la gelée du matin sur la constante diélectrique de la scène observée. En effet, le passage du satellite au-dessus de notre site d'étude est à 22h26 pour le mode ascendant et à 10h26 pour le mode descendant.

**TABLEAU 3-1 : Dates et modes d'acquisition des images**

<i>Lac Saint-Jean</i>	
S1	S7
03-08-98	04-02-99
14-10-98	13-04-99
01-12-98	31-05-99
24-04-99	
11-06-99	

#### 3.2.1. Critères du choix du mode Standard

Radarsat-1 offre aux utilisateurs toute une gamme de modes d'acquisition grâce à la mobilité de son capteur. Ainsi, le faisceau émis par le satellite peut être conformé et pointé à des angles

d'incidence allant de 10 à 60 degrés, dans des largeurs de fauchée de 45 à 500 kilomètres et à des résolutions allant de 8 à 100 mètres (Agence Spatiale Canadienne). Les différentes modes d'acquisition de Radarsat-1 et leurs caractéristiques sont présentées au tableau 2-3.

Le mode d'acquisition Standard de Radarsat-1 offre un bon compromis entre la superficie couverte par l'image (100 km x 100 km) et la résolution des données qui est de l'ordre de 25 mètres. Le mode d'acquisition Standard offre aussi la possibilité de choisir entre une multitude d'angles d'incidences compris entre 20° et 50° repartis en sept faisceaux (Tableau 2-3). Ainsi, une image en mode standard avec une superficie de 100 km x 100 km, devrait permettre d'avoir une marge confortable pour couvrir, avec deux faisceaux différents, la totalité des milieux humides inventoriés par le MRN en 1998.

Cependant, Radarsat-1 offre aussi le choix d'acquérir des images avec un mode d'acquisition à haute résolution (mode Fin). Ce mode d'acquisition offre une précision nettement supérieure au mode standard avec une résolution d'environ 8 mètres (tableau 2-3). Toutefois, le mode Fin présente deux inconvénients qui limitent son utilisation dans ce projet. Premièrement, une image en mode fin couvre uniquement une superficie d'environ 50 km x 50 km. Cette superficie ne nous permet pas de couvrir, avec deux modes d'acquisition différents, les milieux humides étudiés dans cette région. Deuxièmement, ce mode d'acquisition ne permet pas d'avoir des images à faible angle d'incidence. En effet, le mode fin offre uniquement le choix entre cinq faisceaux avec des angles d'incidences compris entre 37° et 47°. Ceci nous prive des avantages qui peuvent être tirés des images à faibles angles d'incidences comme celles obtenues avec le mode S1 avec un angle d'incidence de l'ordre de 20°.



**Figure 3-1.** La zone couverte par les deux modes d’acquisitions

Cette figure montre les zones couvertes par les deux modes d’acquisition et les milieux humides inventoriés par le MRN. Cette zone est couverte par les deux faisceaux S1 et S7 et elle s’étend sur une superficie de 35 x 40 km. Toutefois, nous avons été obligés de ne pas tenir compte d’une zone humide qui se trouve à l’Ouest du lac car elle est couverte uniquement par les images en mode S1.

### **3.2.2. Choix de l’angle d’incidence**

Il a été démontré dans des travaux antérieurs que, dans la télédétection radar, l’angle d’incidence joue un rôle principal dans les mécanismes d’interaction du signal radar avec la scène observée. Dans ce projet, les deux modes S1 et S7 ont été choisis puisqu’ils représentent les limites supérieure et inférieure des faisceaux du mode standard (voir tableau 2-3). Ce choix doit permettre la validation de la deuxième hypothèse de la thèse qui a motivé le

choix de l'imagerie radar comme outil de cartographie des milieux humides (§1-3). Cette hypothèse consiste à vérifier si l'utilisation de deux angles d'incidences différents a un apport significatif à la précision de la classification des milieux humides. Deux définitions liées à cette hypothèse peuvent être signalées :

- Premièrement, l'interaction des micro-ondes à angle d'incidence élevé (comme celles du mode S7) se fait principalement dans la partie supérieure de la végétation. L'énergie retournée au capteur sera donc influencée pour la diffusion de volume de la partie supérieure de cette couverture végétale. Cette caractéristique permet de réduire au maximum la contribution du sol à la rétrodiffusion totale reçue par le satellite et être ainsi plus sensible à la variation de la structure végétale. La réduction de l'effet du sol engendre une augmentation éventuelle du contraste entre les différentes composantes des milieux humides.
- Deuxièmement, un faisceau radar émis en mode S1 a plus de chance de pénétrer une couverture arborée et être ainsi influencé par l'humidité au sol. La grande sensibilité de ce mode d'acquisition à l'humidité du sol doit éventuellement contribuer à la discrimination entre les milieux humides et les milieux forestiers. Toutefois, étant donnée la faible variation de l'humidité à l'intérieur du milieu humide, cette sensibilité peut engendrer une réduction du contraste entre les différentes composantes de milieux humides.

Dans une étude expérimentale sur l'effet de l'angle d'incidence sur la rétrodiffusion radar au-dessus d'une couverture végétale, Ulaby *et al.* (1986) ont montré que :

- Pour des angles d'incidence proches de 20 degrés, c'est qui est le cas pour le mode S1 du Radarsat-1, la rétrodiffusion totale est fortement dominée par la contribution du sol.
- Pour des angles d'incidence compris entre 20 et 30 degrés, la rétrodiffusion totale devient dominée par la végétation.
- Pour des angles d'incidence supérieurs à 30 degrés, l'effet du sol devient négligeable sur la rétrodiffusion totale qui devient plus sensible à la variation des composantes de la végétation.

Dans cette étude, les auteurs ont conclu aussi que, pour des angles d'incidence supérieurs à 20 degrés (c'est qui est le cas des modes S1 et S7 de Radarsat-1), la rétrodiffusion de la végétation varie entre -10 et 0 dB selon la variation de la structure et de l'humidité de la surface végétale. Si on considère les deux niveaux (sol et végétation), la rétrodiffusion du sol est souvent comprise entre 0,1 et 1 fois la rétrodiffusion de la végétation.

L'effet de l'angle d'incidence sur la rétrodiffusion radar a été aussi démontré par Magagi *et al.* (2002) pour une végétation forestière dominée par les épinettes noires. Des images Radarsat-1 acquises en mode Standard (S1 et S7) ont été utilisées dans cette étude. Suite à plusieurs simulations, les auteurs sont arrivés aux constatations suivantes :

- En mode S1, lorsque la densité de la végétation est faible (<20%), le signal provient essentiellement du sol et la rétrodiffusion est directement proportionnelle à l'humidité du sol. Tandis que, en mode S7, le signal augmente légèrement avec l'humidité du sol et la densité de la forêt.
- Quand la densité de la forêt augmente, le signal en mode S1 perd de la sensibilité aux propriétés du sol, tout comme en mode S7. Toutefois, en mode S1 la végétation contribue peu au signal. Par contre, en mode S7, la contribution de la végétation au signal est plus significative.

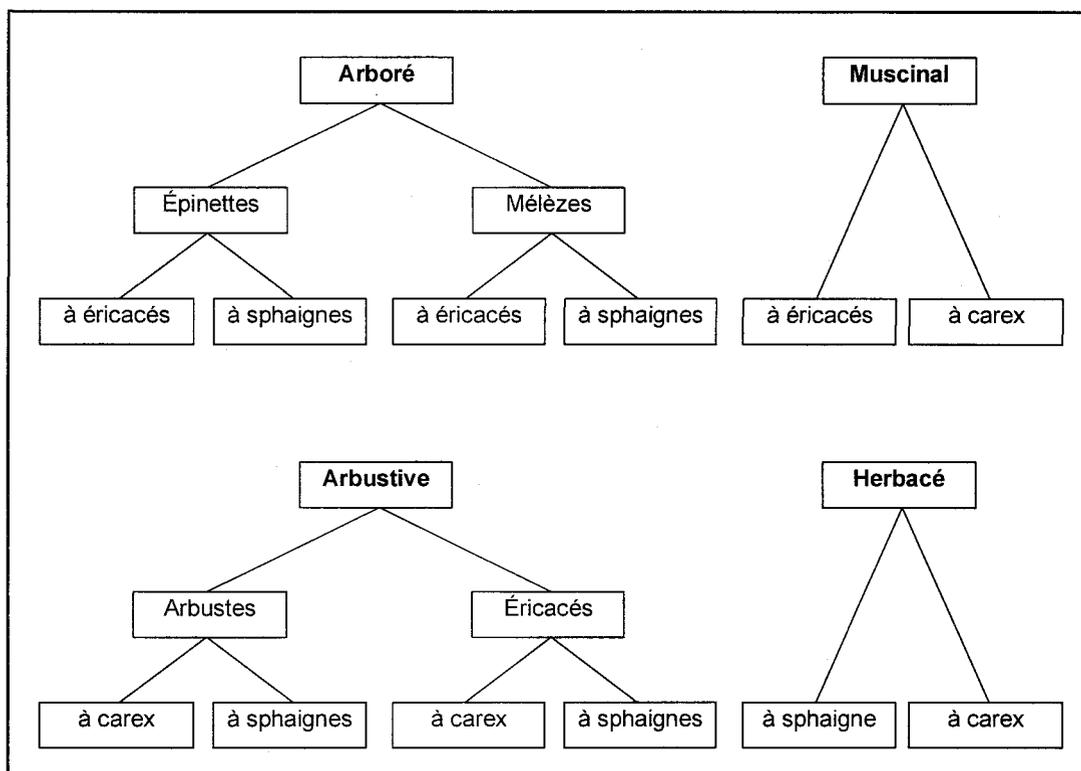
Étant donné leur angle d'incidence proche de la verticale (de 20° à 27°), les ondes radar émises en mode S1 sont beaucoup plus influencées par l'humidité que par la diffusion de volume de la couverture végétale créée par les branches des arbres ou des arbustes (Magagi *et al.*, 2002). En effet, les images acquises en mode S1 seront utiles pour distinguer et délimiter les milieux humides des milieux forestiers. Par contre, les images en mode S7, avec leur angle d'incidence élevé (de 45° à 49°), sont plus utiles pour différencier les surfaces boisées à cause d'une diffusion de volume élevée. En effet, un angle d'incidence élevé fait augmenter la rétrodiffusion des branches des arbres. Les images acquises en mode S7 peuvent être très utiles pour différencier plusieurs types de surfaces boisées à l'intérieur des milieux humides.

Nous vérifions dans les chapitres suivants si ces deux modes d'acquisition sont effectivement complémentaires pour la cartographie des milieux humides. Cette vérification sera effectuée dans un contexte de classification par réseau de neurones. Celle-ci doit permettre l'évaluation de l'effet de l'angle d'incidence sur la rétrodiffusion radar.

### **3.3. Acquisition des données sur le terrain**

À l'été 1999, deux sorties de terrain ont été réalisées dans les milieux humides de la région d'étude. La première a été faite en collaboration avec la société sylvicole de Mistassini. Cette visite nous a permis de tracer les limites des tourbières et de repérer des sites homogènes échantillonnés sur les images RADARSAT en utilisant les coordonnées UTM de ceux-ci. Elle nous a permis aussi de prendre connaissance des données de terrain recueillies à l'été 1998 par la société sylvicole de Mistassini. Ces données ont été recueillies dans le cadre d'un projet d'évaluation du potentiel de mise en valeur des tourbières de la région. La deuxième campagne a été réalisée deux mois plus tard en compagnie de M. Pierre Buteau (géologue, Service des minéraux industriels, MRN). Cette visite a permis de prendre des photos des différentes tourbières et de localiser les grandes classes physiologiques des milieux humides, afin de les raffiner et de les adapter à la classification des images RADARSAT.

Au début, quatre grandes classes liées à la physiologie de la tourbière et 12 classes secondaires ont été définies (figure 3-2). Le choix de ces classes a été basé sur les résultats de l'inventaire de la végétation et de la composition de la tourbe effectué à l'été 1998 par la société sylvicole de Mistassini. Toutefois, en vérifiant la distribution spatiale de ces classes sur le terrain, nous avons conclu qu'il serait impossible d'établir une discrimination précise de ces douze classes à l'aide de l'imagerie Radarsat pour deux principales raisons. Premièrement, il est difficile de tracer des sites d'échantillonnage homogènes d'une superficie suffisante pour chaque classe. La superficie d'une zone homogène de ces classes dépasse rarement la taille d'un carré de quatre pixels (50 x 50 mètres) et le passage d'une classe à une autre se fait souvent dans quelques dizaines de mètres. Deuxièmement, la méthodologie suivie pour l'échantillonnage et le choix des classes pendant l'inventaire ne tient pas compte d'une utilisation éventuelle de ces classes dans une classification par télédétection spatiale. Cette méthodologie est couramment utilisée pour donner une identification botanique des milieux humides. Elle est basée sur une identification taxinomique des plantes et un comptage rigoureux de nombre de tiges de chaque espèce dans une zone carrée de quelques mètres.



**Figure 3-2** : Classes principales et secondaires de la végétation des milieux humides.

Pour surmonter les inconvénients cités précédemment, nous avons choisi quatre autres classes physiologiques qui peuvent théoriquement être discriminées par une série temporelle d'images Radarsat-1 tout en se basant sur la théorie de l'interaction des micro-ondes radar avec la scène observée (chapitres 2 et 3). Ces classes sont composées de trois groupes physiologiques de milieux humides soit les milieux humides arborés, les milieux humides arbustifs et les milieux humides moyennement arborés et d'une quatrième classe pour les forêts limitrophes (figure 3-3). Contrairement aux douze classes citées précédemment, il est possible de localiser des sites d'entraînement homogènes pour ces classes avec une superficie suffisante pour le développement de la méthode de classification. En plus, une cartographie des milieux humides avec ces quatre classes offrira un outil très précieux aux intervenants intéressés par ce genre de milieux.

Les photos de la figure 3-3 montrent un aperçu de ces quatre classes. L'affectation d'une classe à une zone donnée dépend de la densité de la couverture arborée de cette zone. Ainsi, les classes ont été définies comme suit :

1. Une zone est définie comme fortement arborée quand la distance minimale entre deux arbres est toujours inférieure à cinq mètres.
2. Une zone est définie comme moyennement arborée lorsque la majorité des arbres sont distants de 20 mètres ou moins.
3. Une zone est définie comme arbustive lorsque la densité des arbres ne se conforme pas avec les deux conditions précédentes.
4. Un milieu est défini comme forestier lorsque la composition de son sol est minérale contrairement aux milieux humides qui ont un sol organique (tourbe).



Milieu humide arbustif



Milieu humide moyennement arboré

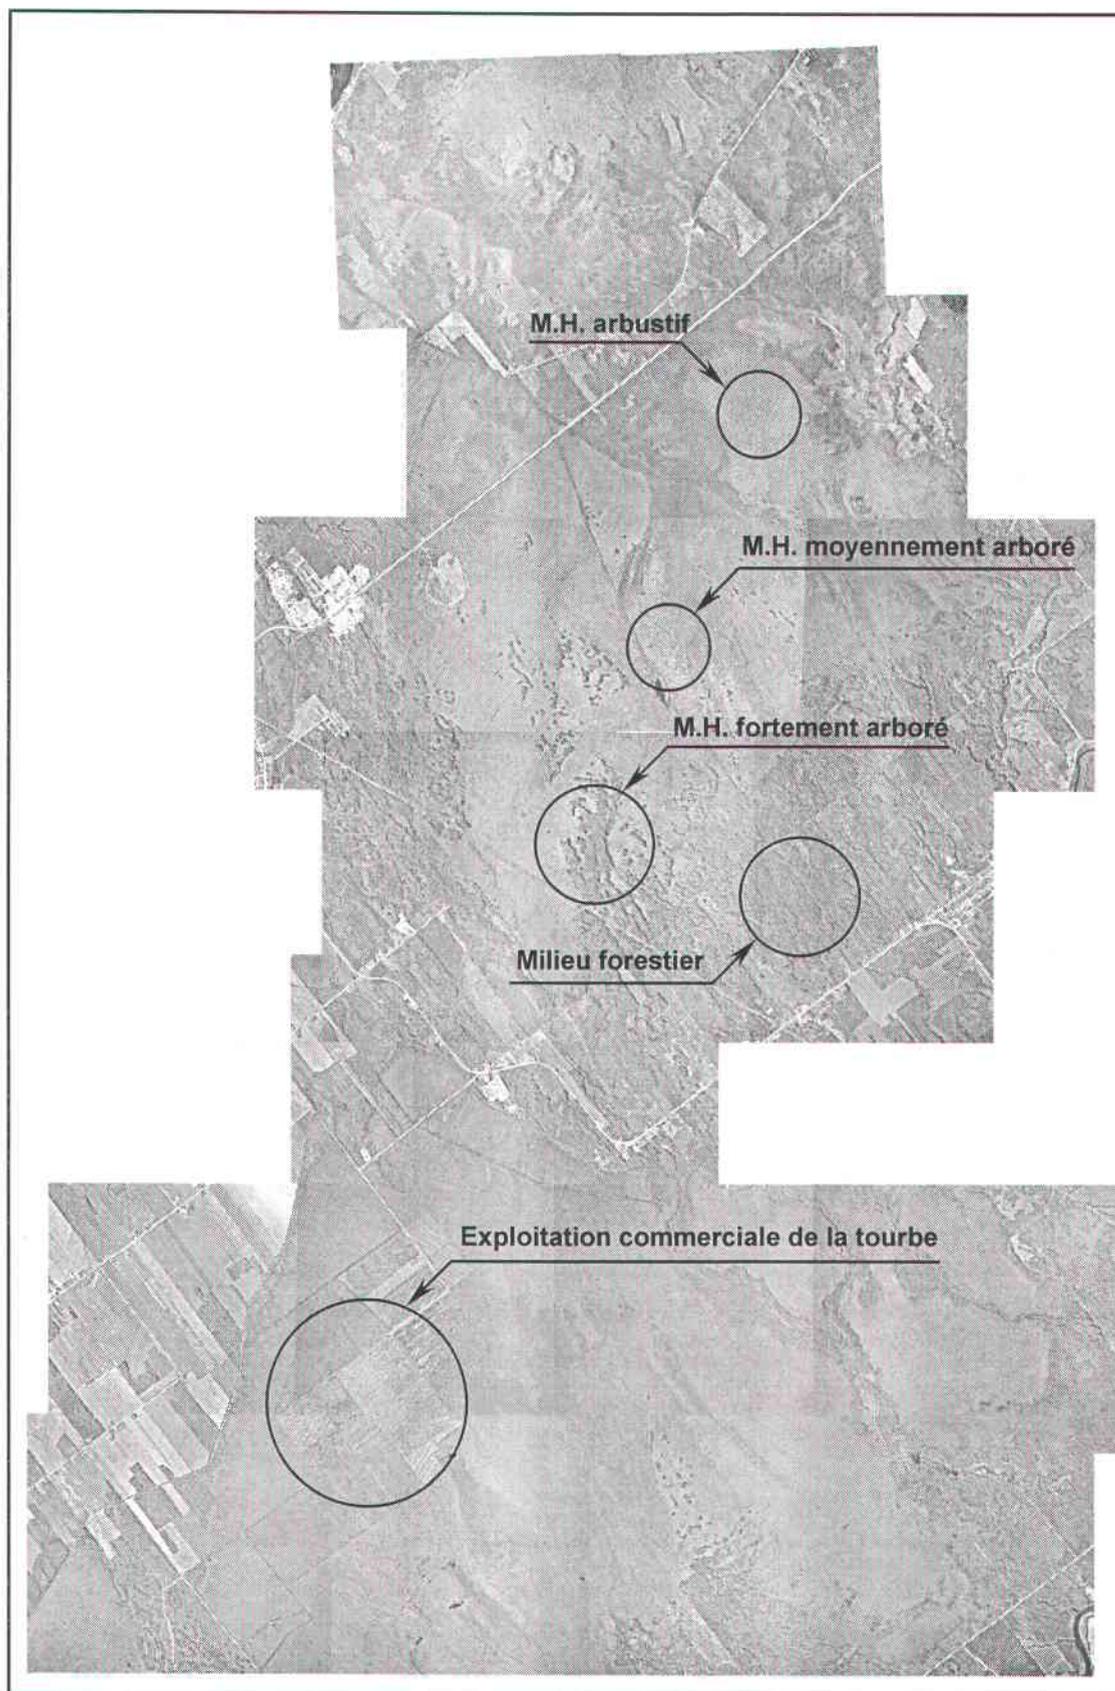


Milieu humide fortement arboré



Milieu forestier

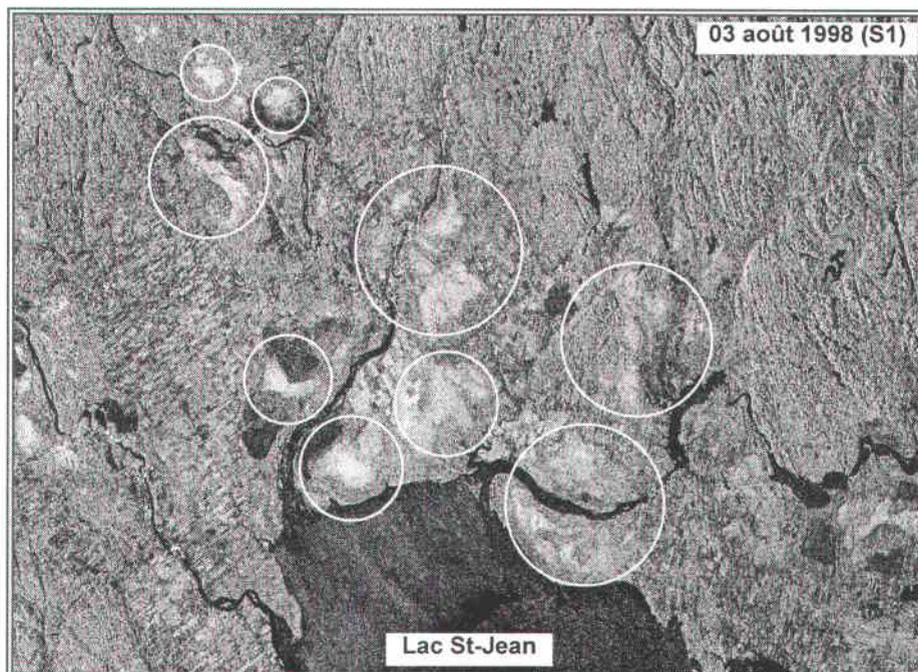
**Figure 3-3.** Photographies acquises dans les 4 classes.



**Figure 3-4.** Mosaïque des photos aériennes (échelle 1 :15000) de la région d'étude

La figure 3-4 montre une mosaïque obtenue à partir de vingt photos aériennes (échelle 1 :15000) de la région d'étude. Cet assemblage a permis de localiser préalablement plusieurs zones d'intérêt dans les milieux humides de la région en tenant compte des classes physionomiques définies précédemment. Une dernière visite de terrain, organisée en juillet 2000, a permis de localiser plusieurs zones homogènes représentant ces quatre classes. Des tracés GPS sous forme des fichiers numériques de ces zones ont été produits sur le terrain à l'aide d'un système GPS à 12 canaux (appareil Lo-K-tor de la firme VIASAT). Les fichiers obtenus ont été traités et incorporés aux images radar à l'aide du logiciel EASI/PACE de PCI.

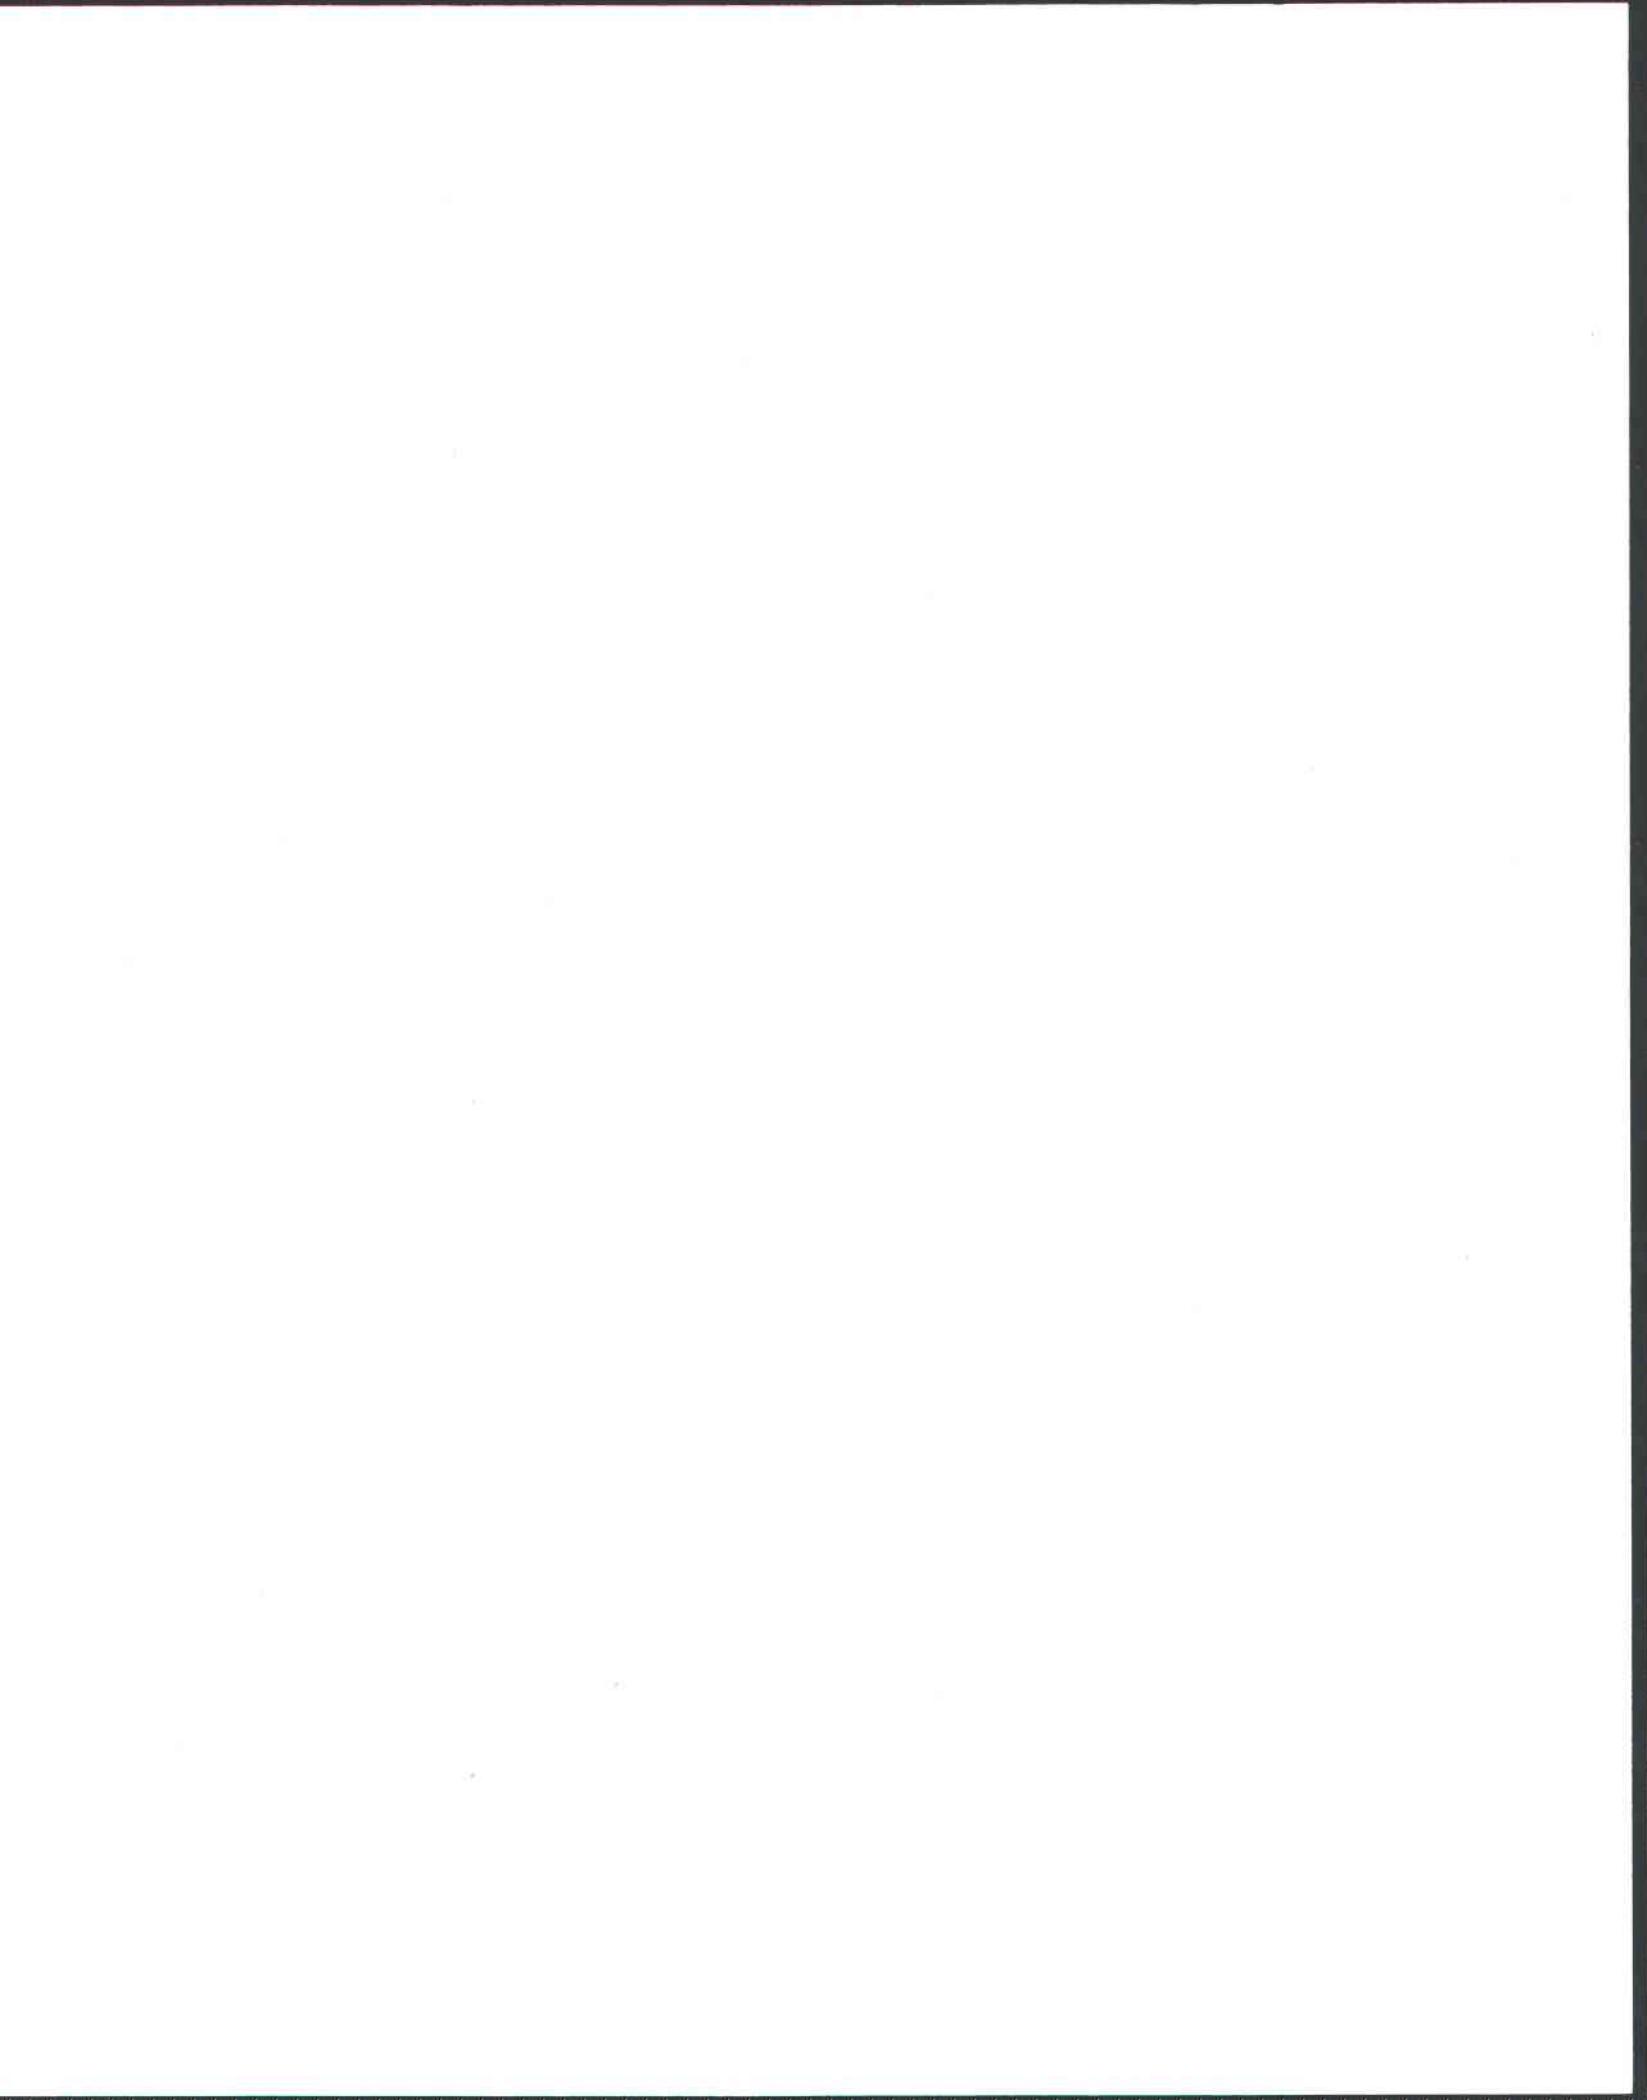
### **3.4. Interprétation visuelle des images brutes**



**Figure 3-5.** Apparence des milieux humides dans une image S1

Une interprétation visuelle des images permet de délimiter les zones ayant une tonalité homogène et d'évaluer le potentiel d'une image donnée à discriminer les grandes classes végétales (figure 3-5). Cette étape d'analyse permet d'avoir une idée globale sur la qualité de l'image et de son potentiel informatif sur les classes présentes dans la scène concernée.

Une simple interprétation visuelle des images acquises de la région du lac St-Jean montre la sensibilité du mode S1 à l'humidité de la scène observée. Cette sensibilité se manifeste par une



rétrodiffusion très élevée des milieux humides arborés et arbustifs par rapport à la forêt avoisinante malgré une physionomie plus ou moins proche (zones encadrées de la figure 3-5). La rétrodiffusion élevée des milieux humides en mode S1 démontre la sensibilité de ce mode d'acquisition à faible angle d'incidence à l'humidité du sol. Cette propriété nous permet de bien délimiter les milieux humides concernés pour une discrimination plus poussée entre les composantes internes de ces milieux.

Les deux sections suivantes présentent une interprétation visuelle des huit images brutes. Les planches de ces images sont présentées à l'annexe B.

### **3.4.1. Images S1**

Les trois images en mode S1 acquises entre le mois de juin et le mois d'octobre offrent le meilleur contraste entre les milieux humides et le milieu forestier avoisinant. Visuellement, aucun changement significatif ne peut être détecté dans les milieux humides naturels entre ces trois dates d'acquisitions. Cette stabilité du signal peut être aussi observée dans le graphique de la figure 3-6. Pour ces trois dates, tous les milieux humides ont une rétrodiffusion nettement élevée par rapport aux autres milieux. En se référant à la théorie de l'interaction des micro-ondes radar avec la scène observée, ces dates d'acquisition représentent la meilleure période de discrimination entre les milieux forestiers et les milieux humides vu l'humidité élevée du sol et de la végétation.

L'image acquise le mois de décembre offre un contraste très faible (ou presque nul) entre les milieux humides et les milieux voisins. En effet, le gel d'hiver réduit la constante diélectrique du sol et de la végétation et diminue considérablement le signal retourné au satellite. Avec cette image, aucune discrimination visuelle ne peut être faite entre les milieux humides et les forêts voisines.

Même si l'image du mois d'avril offre un contraste plus élevé entre les milieux humides et le milieu forestier que celle acquise en décembre. Le contraste reste plus faible que celui obtenu avec les trois images S1 acquises entre le mois de juin et le mois d'octobre (voir annexe B). En effet, il a été démontré dans des études précédentes (Bagdadi *et al.*, 2001, Magagi *et al.*, 2002) que la présence d'une couverture de neige humide affecte le signal rétrodiffusé et réduit la contribution du sol et de la végétation basse des tourbières à la rétrodiffusion totale.

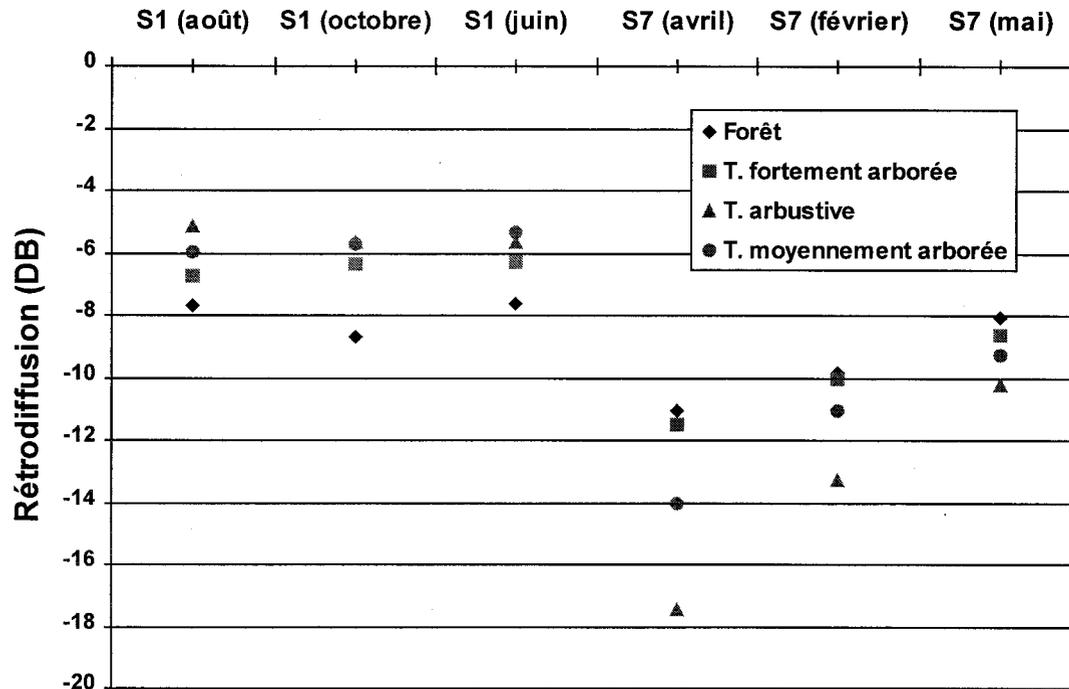
### **3.4.2. Images S7**

Contrairement aux images acquises en mode S1, la rétrodiffusion des milieux humides en mode S7 reste inférieure à la rétrodiffusion des forêts pour les trois dates d'acquisition. Ceci est dû principalement au faible effet du sol et surtout son humidité à la rétrodiffusion totale des micro-ondes à angle d'incidence élevé. Toutefois, les images S7 offrent plus de variabilité à l'intérieur des milieux humides où quelques zones homogènes peuvent facilement être distinguées à l'œil nu (voir Annexe B).

Pour le mode S7, le signal retourné au satellite sera principalement influencé par la structure de la végétation. L'image du 13 avril offre le meilleur contraste entre les composantes internes des milieux humides. La présence des zones fortement et moyennement arborées à l'intérieur des milieux humides est visible à l'œil nu avec une précision comparable à celle observée avec les photos aériennes. Toutefois la limitation entre les milieux humides fortement arborés et les milieux forestiers reste un peu flou et une certaine confusion peut être décelée entre ces deux milieux.

### **3.5. *Interprétation analytique des images brutes***

Faisant suite à cette analyse, six images (3 S1 et 3 S7) ont été conservées pour évaluer leur apport à la classification des milieux humides. Les images éliminées sont celles acquises en mode S1 en décembre (à cause du gel du sol) et le mois d'avril (à cause de l'effet de la neige humide). Le graphique de la figure 3-6 présente une description plus précise du comportement du signal radar face aux grandes compositions végétales des milieux humides pour ces six images. Il donne ainsi une démonstration des principes physiques de l'interaction de l'onde radar présentés aux deuxième et troisième chapitres. Ce graphique démontre aussi la complémentarité entre les deux modes d'acquisition S1 et S7 dans la cartographie des milieux humides. Les histogrammes détaillés avec la moyenne et l'écart type de chaque classe sont présentés à l'annexe A.



**Figure 3-6.** Comportement du signal radar pour les différentes classes

La première observation qu'on peut tirer de ce graphique est que les images en mode S1 ont une rétrodiffusion plus forte que les images S7. En effet, pour les classes végétales (milieux humides et forêts), la rétrodiffusion dépasse rarement le - 8 dB avec le mode S7 et varie entre -8 dB et -5 dB pour les images S1. En fait, il a été démontré par Ulaby *et al.* (1986) que, pour une composition végétale donnée, la quantité d'énergie rétrodiffusée vers le capteur est inversement proportionnelle à l'angle d'incidence.

Pour les images en mode S1, la plus forte rétrodiffusion a été observée pour les milieux humides arbustifs et les milieux humides moyennement arborés. Pour ces deux classes, la rétrodiffusion moyenne est comprise entre - 5 dB et - 6 dB. Cette rétrodiffusion élevée est due principalement à la dominance de l'humidité du sol sur la rétrodiffusion totale étant donné la faible présence des facteurs atténuants comme les arbres. Cependant, l'effet de l'humidité du sol reste présent aussi pour les milieux humides fortement arborés. Même si la rétrodiffusion de cette classe (entre -6 et -7 dB) est inférieure aux milieux humides arbustifs, elle reste supérieure à la rétrodiffusion moyenne des forêts qui varie entre -8 dB et -9 dB selon la date d'acquisition. Ceci s'explique par la forte sensibilité des images à faible angle d'incidence à l'humidité du sol qui est largement différente entre les milieux humides limitrophes fortement

arborés et les milieux purement forestiers. La sensibilité des images S1 à l'humidité d'un sol couvert par la végétation joue un rôle important dans la discrimination entre les milieux humides et les milieux avoisinants. Cette propriété représente l'apport principal des images S1 dans la cartographie des milieux humides. Cependant, le pouvoir discriminatoire du mode S1 des composantes internes des milieux humides reste très faible. En effet, toutes les composantes des milieux humides ont une rétrodiffusion moyenne élevée et plus ou moins semblable (entre -5 dB et -7 dB). Ceci est expliqué par la prédominance de l'humidité du sol sur la rétrodiffusion à faible angle d'incidence. L'humidité du sol est considérée, dans ce cas, comme une source indésirable du bruit. À cet effet, Ulaby *et al.* (1986) ont suggéré l'utilisation des angles d'incidences supérieurs à 30 degrés pour éviter l'effet indésirable de l'humidité du sol et améliorer la discrimination entre les différentes composantes végétales.

La quantité de rétrodiffusion en mode S1 est presque semblable pour les images de l'été et de l'automne (juin, août et octobre). Toutefois, aucun contraste n'a été observé entre les milieux humides et les forêts avoisinantes avec une image d'hiver acquise le mois de décembre. Ceci est expliqué par le gel du sol qui élimine le pouvoir discriminatoire des images S1 basé sur la sensibilité à l'humidité. En plus, le gel de la végétation en hiver augmente sa transmissivité, ce qui fait que le signal devient de moins en moins sensible à la physiologie végétale (Magagiet *al*, 2002).

En observant le comportement du signal radar en mode S7, on voit que la rétrodiffusion est plus sensible aux composantes végétales des milieux humides que le mode S1. Avec le mode S7, la quantité de signal retournée au capteur est clairement proportionnelle à la densité des arbres. La plus faible rétrodiffusion a été observée pour une végétation arbustive tandis que les milieux humides fortement arborés donnent la rétrodiffusion la plus élevée à l'intérieur du milieu. Toutefois, les forêts ont plus tendance à se confondre avec les milieux humides fortement arborés. Cette confusion est due principalement à la ressemblance apparente de ces deux classes et à la faible sensibilité du mode S7 à l'humidité du sol. Pour les trois images acquises en mode S7, la différence entre la rétrodiffusion moyenne des forêts et celle des milieux humides fortement arborés reste inférieure à 0.5 dB.

D'autre part, avec le mode d'acquisition S7, la variation de la rétrodiffusion moyenne est plus marquante d'une date à une autre. Par exemple, la rétrodiffusion des milieux humides arbustifs a varié entre -10 et -18 dB dans un intervalle de cinq mois (février - mai). Toutefois, malgré cette grande variation, la rétrodiffusion moyenne reste sensible à la physiologie végétale et

proportionnelle à la densité des arbres avec un contraste variable d'une date à une autre. On peut dire ainsi que les images en mode S7 sont plus utiles que les images S1 dans la discrimination des composantes végétales des milieux humides.

Pour conclure, on peut affirmer que les deux modes d'acquisition S1 et S7 sont complémentaires pour la cartographie des milieux humides. En fait, les images S1 jouent un rôle important dans la discrimination entre les forêts et les milieux humides grâce à leur sensibilité élevée à l'humidité du sol. Par contre, malgré la quantité d'énergie relativement faible retournée au satellite opérant en mode S7, ce mode d'acquisition reste plus avantageux dans la discrimination entre les composantes internes des milieux humides. Cette complémentarité sera prise en compte dans une classification par réseaux de neurones qui considère différemment l'apport de chaque source d'information dans la prise de décision.

### **3.6. Correction radiométrique**

Les images RADARSAT en mode Standard sont étalonnées par le fournisseur (Radarsat International). Une fois reçues, les images brutes doivent subir une correction radiométrique afin de prendre en compte des paramètres d'acquisition (angle d'incidence et gain de l'antenne). Ces paramètres ont un effet non négligeable sur la quantité d'énergie captée par le satellite. En effet, la correction radiométrique permet d'assurer une uniformité radiométrique acceptable des images multi-temporelles. Pour ce faire, il faut connaître le gain initial de l'antenne ainsi que le gain étendu et l'angle d'incidence pour chaque colonne des pixels (Kennett et Li, 1989b). Ces informations sont fournies sous forme de vecteur avec l'image brute et elles sont prises en compte automatiquement par le logiciel EASI/PACE (PCI Geomatics inc.).

Pour convertir en intensités les valeurs numériques des images brutes, il suffit de calculer pour chaque pixel la valeur de la rétrodiffusion  $\sigma_{ij}^0$  en utilisant l'équation suivante :

$$Intensité = \sigma_{ij}^0 = \left[ \frac{DN_{ij}^2 + A_0}{A_j} \cdot \sin(I_j) \right] \quad (3-1)$$

Où :

- $DN_{ij}$  : La valeur numérique d'entrée du pixel de coordonnées (ligne i, colonne j)
- $A_0$  : Le gain initial

- $A_j$  : Le gain étendu sur la colonne j
- $I_j$  : L'angle d'incidence à la colonne j
- $\sigma_{ij}^0$  : Le coefficient de rétrodiffusion radar du pixel de coordonnées (i , j)

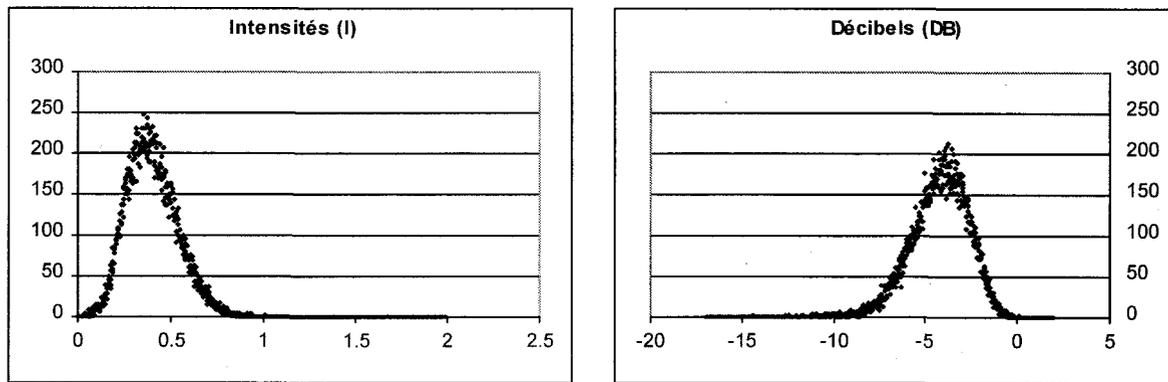
Les images radar sont généralement exprimées en décibels (dB). Ce format permet d'avoir une échelle de  $\sigma_{ij}^{DB}$  proportionnelle aux variations des paramètres qui influencent la rétrodiffusion comme l'angle d'incidence, les propriétés diélectriques et l'état de la surface observée (Ulabyet *al.*, 1982b).

L'utilisation d'un format spécifique des données radar dépend des utilisations et des manipulations envisagées de ces données. En fait, la transformation logarithmique appliquée aux données exprimées en intensités pour les convertir en dB, entraîne des limitations si on veut appliquer des transformations analytiques aux données. Par exemple, pour calculer la moyenne des niveaux des gris d'un groupe des pixels exprimés en dB, on doit utiliser des données en intensités, calculer la moyenne et convertir par la suite le résultat en dB en utilisant l'équation (3.2). Toutefois, on peut conserver nos données en dB si on veut étudier la distribution statistique des pixels dans une classe donnée ou pour comparer la variation de la rétrodiffusion entre les classes (Kennett et Li, 1989a ; Kennett et Li 1989b).

Le calcul de  $\sigma_{ij}^{DB}$  se fait par l'équation suivante :

$$\sigma_{ij}^{DB} = 10 \cdot \log_{10} [\sigma_{ij}^0] \quad (3-2)$$

Le programme XPACE du logiciel EASI/PACE (PCI Geomatics inc.) permet de transformer les données en plusieurs formats : intensités, amplitudes et décibels. Ceci donne plus de flexibilité dans les étapes ultérieures du traitement (filtrage, moyenne des niveaux de gris, classification,...etc.). La figure 3-7 montre un exemple de distribution des valeurs des pixels exprimées en intensités et en décibels à l'intérieur d'une tourbière arbustive uniforme. En analysant visuellement ces deux distributions, on peut voir clairement l'effet de la transformation des valeurs des pixels d'intensités à dB.



**Figure 3-7.** Distribution statistique des valeurs de la rétrodiffusion à l'intérieur d'une tourbière

Cette transformation permet d'avoir une échelle de  $\sigma_{ij}^{DB}$  proportionnelle aux variations des rétrodiffusions et augmente considérablement la sensibilité de l'énergie reçue face aux variations des pixels à faible rétrodiffusion. Cette sensibilité sera très utile plus tard pour la discrimination entre les classes ayant des caractéristiques radiométriques proches ou semblables.

Dans ce projet, nous avons gardé deux formats numériques pour chaque image (décibels et intensités) afin de tester l'effet de la transformation logarithmique sur la précision de la classification par des réseaux de neurones.

### **3.7. Correction géométrique**

#### **3.7.1. Introduction**

La précision de la correction géométrique a une grande influence sur les étapes ultérieures de l'analyse qui nécessitent une superposition parfaite des images. Toutefois, il est presque impossible d'arriver à une correction parfaite à cause des multiples sources d'erreurs qui peuvent entraîner des déformations spatiales et causer des distorsions géométriques aux images. Ces sources d'erreurs peuvent être classées en trois groupes (tableau 3-2).

**TABLEAU 3-2 : Sources de distorsions géométriques**

L'environnement observé	Erreurs des systèmes de mesure	Mouvement de la plate-forme pendant l'acquisition
- la rotation de la Terre pendant l'acquisition de l'image, - la courbure de la Terre, variation de l'altitude du sol, - les effets de la topographie	- largeur du champ de vision de détecteurs, - taux de résolution de certains détecteurs, - effet de l'angle d'incidence sur la taille du pixel	- variation de l'altitude - variation de l'attitude - variation de la vitesse

Le choix d'une méthode de correction géométrique dépend des critères liés aux utilisations futures des images corrigées et des informations disponibles sur la région étudiée. Selon la source et l'origine de la distorsion, deux méthodologies peuvent être suivies pour corriger les distorsions géométriques dans une image radar :

### **3.7.2. Les principes de base de la méthode « Ortho »**

La méthode «Ortho» consiste à corriger directement les distorsions en tenant compte de leurs sources ou de leurs origines. Cette technique peut être utilisée seulement si les sources des distorsions sont identifiables comme celles causées par la rotation de la Terre ou l'effet des angles d'incidences. Dans ce cas, il suffit de développer un modèle qui engendre un effet inverse au type de distorsion à corriger. Dans ce cadre, le Centre canadien de télédétection (Toutin et Carbonneau, 1992a) a développé un modèle mathématique de correction géométrique qui tient compte de plusieurs paramètres reliés au satellite (mouvement et altitude), au vecteur d'illumination (orientation, angle et temps) et à la géométrie de la Terre (rotation, courbure et élévation).

Au début, la méthode photogrammétrique (ortho) a été employée spécialement pour la correction géométrique des images SPOT-HRV en tenant compte des paramètres relatifs au satellite et du modèle numérique d'altitude MNA (Toutin and Carbonneau, 1992b). Ensuite, en se basant sur le même principe, cette méthode a été adaptée pour la correction des images de sources multiples (visibles et micro-ondes ; spatiales et aéroportées).

Le modèle mathématique utilisé par cette méthode représente la réalité physique lors de la formation de l'image en intégrant plusieurs paramètres qui décrivent la géométrie totale de prise de vue (De Sève, *et al.*, 1996). Ces paramètres sont intégrés dans une série de transformations mathématiques pour donner à la fin deux équations qui représentent la loi de passage des coordonnées cartographiques terrain aux coordonnées de l'image. Les transformations mathématiques utilisées sont basées sur plusieurs principes liés à la photogrammétrie, à l'orbitographie, à la géodésie, et à la conformité de la projection. Les caractéristiques principales de cette méthode peuvent être résumées dans les sept points suivants (Toutin et Carbonneau, 1992a) :

Ce modèle est basé sur un développement analytique des équations de la colinéarité des points de contrôle et sur des équations de coplanarité des points homologues.

Chaque paramètre de ce modèle est identifié par une formule mathématique résultante des lois de la mécanique céleste (équations de Lagrange) et de la géométrie de la visée.

L'ordre de grandeur de chaque paramètre est connu à l'avance et les paramètres corrélés sont regroupés ce qui donne un minimum de huit inconnus non corrélés par image.

L'intégration de divers modèles relatifs à l'orbite, à l'attitude et à l'image et leurs ajustements simultanés doivent donner une détermination meilleure et une robustesse supérieure aux méthodes conventionnelles de modulation (modulation pas-à-pas ou une modulation indépendante).

L'addition des équations complémentaires reflète la précision des paramètres orbitaux et augmente leur importance surtout avec des points de contrôle imprécis.

La précision du modèle mathématique donne des résultats avec une erreur de positionnement inférieure à un pixel.

La correction géométrique obtenue peut être utilisée dans plusieurs projections cartographiques conformes (UTM ou Lambert) avec ou sans modèle numérique d'altitude.

### **3.7.3. Théorie de la méthode polynomiale**

Cette méthode consiste à établir empiriquement une relation mathématique polynomiale entre les coordonnées (en lignes et pixels) d'un ensemble des points dans l'image brute (points de

contrôle) et les coordonnées réelles de ces points (ex. en projection UTM). Ces dernières peuvent être obtenues soit en se référant à une carte topographique, soit par rapport à une autre image satellite corrigée couvrant la même région. Cette méthode permet de corriger les distorsions géométriques d'une image brute avec aucune connaissance a priori du type ou de la source de la distorsion et indépendamment des paramètres du satellite utilisé pour l'acquisition.

Cette méthode utilise un modèle de régression polynomiale obtenu à partir de points d'appui communs à l'image brute et au système de référence (Richards, 1993). Ce modèle crée une relation entre l'image brute et le système de référence en minimisant les erreurs résiduelles calculées pour chaque point de contrôle. Le principe de base de la méthode polynomiale consiste à établir deux fonctions empiriques ( $f$  et  $g$ ) qui assurent le lien entre deux systèmes de coordonnées cartésiens :

$$\begin{aligned} u &= f(x, y) \\ v &= g(x, y) \end{aligned} \quad (3-3)$$

Le premier système des coordonnées  $(u, v)$  définit la position du pixel dans l'image brute. Cette position correspond au numéro de ligne et au numéro de pixel (ou colonne) du point choisi. Le deuxième repère  $(x, y)$  localise le même point dans une carte de référence (ou dans une image corrigée). Ce repère représente donc la latitude et la longitude de ce point.

Généralement, on choisit une forme polynomiale pour les deux fonctions  $f$  et  $g$ . Par exemple, pour une équation polynomiale d'ordre 3,  $f$  et  $g$  s'écrivent sous la forme suivante :

$$u = f(x, y) = a_0 + a_1x + a_2y + a_3xy + a_4x^2 + a_5y^2 + a_6x^2y + a_7xy^2 + a_8x^3 + a_9y^3 \quad (3-4)$$

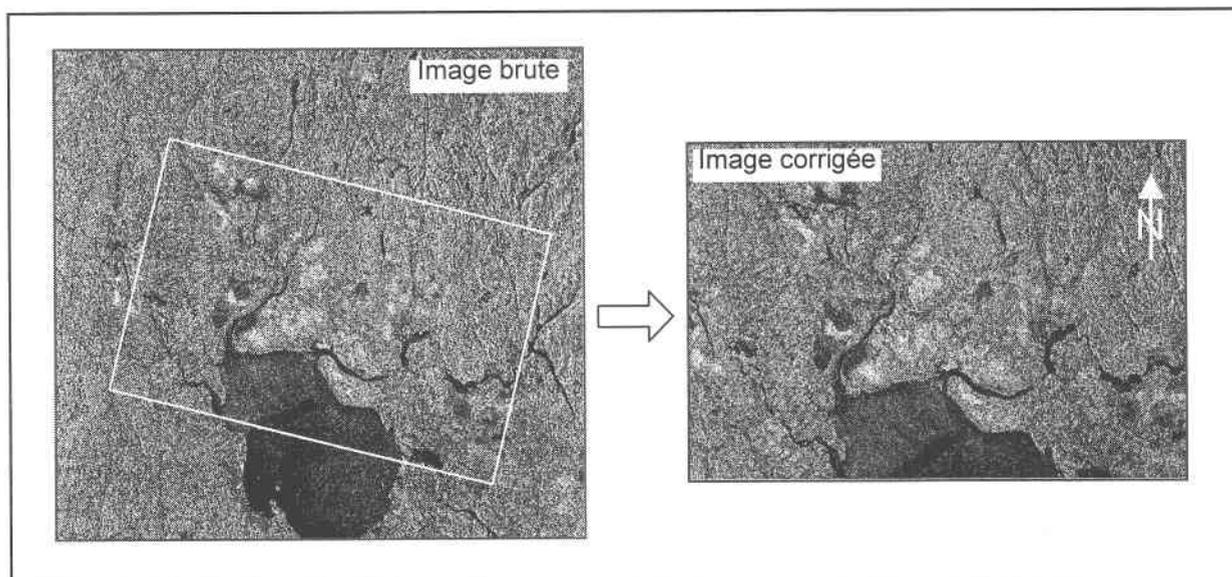
$$v = g(x, y) = b_0 + b_1x + b_2y + b_3xy + b_4x^2 + b_5y^2 + b_6x^2y + b_7xy^2 + b_8x^3 + b_9y^3 \quad (3-5)$$

Au début, les coefficients  $a_i$  et  $b_i$  de deux polynômes sont inconnus. Pour les estimer, on doit identifier un nombre minimal de points de contrôle qui dépend de l'ordre du polynôme choisi. Par exemple, on doit choisir au moins 6 points de contrôle pour évaluer les coefficients d'un polynôme de d'ordre 2 et 10 points de contrôle pour un polynôme d'ordre 3. Ces points doivent être facilement repérables à la fois sur la carte et sur l'image à corriger. Par exemple, on peut choisir des intersections de routes, des chemins de fer, des courbures de rivières, des bâtiments, des pistes d'aéroports, etc.

De Sève *et al.*, (1996) ont appliqué les deux méthodes sur deux types d'images LANDSAT-TM et ERS-1 et comparé leur efficacité et la précision du résultat obtenu. Dans cette application, la méthode photogrammétrique a montré sa supériorité et sa plus grande efficacité par rapport à la méthode polynomiale sur les deux types d'images.

### 3.7.4. Choix d'une méthode de correction géométrique

Dans ce projet, ces deux méthodes de correction géométrique ont été testées. La méthode polynomiale au deuxième degré a donné de meilleurs résultats que la méthode Ortho, probablement en raison de l'absence d'un modèle numérique d'altitude (MNA). Toutefois, à cause du faible relief des sites d'étude, nous avons introduit une altitude moyenne pour toute la région. Avec la méthode polynomiale de deuxième degré, les erreurs obtenues (RMS) variaient entre 0,57 et 1,12 pixels sur les deux axes. Ces erreurs sont calculées en mesurant le décalage entre les coordonnées réelles des points de contrôle et les coordonnées de ces points dans l'image corrigée.



**Figure 3-8.** Correction géométrique d'une image du lac Saint-Jean.

Afin de garder une correction géométrique uniforme et cohérente pour l'ensemble des images RADARSAT, un groupe de 20 points de contrôle pouvant être facilement repéré sur toutes les images a été choisi. Les coordonnées étaient exprimées selon la grille UTM 19 NAD27. Le choix de cette méthodologie de repérage des points de contrôle permet d'avoir une correction

géométrique cohérente tout en minimisant au maximum les erreurs introduites par cette étape de traitement. Cependant, le repérage de quelques points de contrôle était plus difficile pour quelques images influencées par le vent ou par la fonte de neige. La figure 3-8 montre le résultat de la correction géométrique d'une image du lac Saint-Jean.

### **3.8. Mesure de la texture**

#### **3.8.1. Définition de la texture**

La texture d'une image radar est constituée de deux sources d'informations. La première source dépend de la scène observée et représente la variation de tonalité due à la variation de plusieurs éléments de la scène. Des paramètres statistiques liés à cette source d'information peuvent être évalués par des méthodes analytiques (voir paragraphes ci-dessous). Le chatoiement (*speckle* en anglais) représente la deuxième source de texture dans une image radar. Cette source de texture est statistiquement indépendante de la scène observée et elle dépend uniquement du système d'acquisition et des étapes de production des données. Le chatoiement est ainsi considéré comme source de bruit qui affecte négativement la qualité de l'image (Raney, 1998).

La texture de la scène est une information très utile dans un processus d'analyse et d'extraction d'information des données de télédétection et particulièrement des données radar. L'utilité des informations sur la texture dans un processus de traitement des données radar repose essentiellement sur la capacité de ces informations de réduire l'effet du chatoiement tout en gardant une certaine sensibilité pour l'identification des objets ou des régions d'intérêt dans une image (Ulaby *et al.*, 1986). Contrairement aux paramètres spectraux qui représentent la moyenne de la variation de tonalité dans plusieurs bandes d'images, la texture d'une image représente la distribution spatiale de la variation de tonalité dans une seule bande de données. Elle est très utile pour identifier plusieurs zones d'intérêt dans l'image en se basant sur la fréquence de variation et la disposition des nuances de gris ou des teintes.

L'utilisation des méthodes de classifications basées sur la variation de tonalité des pixels a donné des bons résultats pour des données optiques comme celles de Landsat MSS. Toutefois, ces méthodes se sont avérées limitées pour les données radar à cause de la présence du chatoiement (Ulaby *et al.*, 1986). En effet, la présence du chatoiement est considérée comme la cause principale d'erreur dans ce genre de classification. Toutefois, la réduction du chatoiement

par l'application d'un algorithme de filtrage affecte considérablement la résolution de l'image. Dans une classification d'un milieu forestier par des images SIR-A, Ulaby *et al.* (1986) ont montré que l'utilisation de la texture peut augmenter la précision de la classification de 75 à 93 %.

Plusieurs mesures de texture peuvent être extraites à partir d'une seule image brute. Ces mesures sont dérivées à partir de la matrice de coexistence ou de dépendances des niveaux de gris dans une fenêtre centrée sur le pixel concerné et de dimension prédéfini. Les éléments de cette matrice représentent les mesures de la fréquence d'existence relative de la combinaison de paires de pixels ayant une relation spatiale spécifique. Le terme GLCM est largement utilisé en littérature pour désigner cette matrice; il est l'acronyme de l'expression anglaise : Grey Level Co-occurrence Matrix. L'utilisation de la GLCM pour l'extraction de l'information sur la texture suppose à priori que la texture d'un bloc d'image est continue dans le lien spatial qui existe entre les niveaux de gris de ce bloc d'image (Frost *et al.*, 1984).

### **3.8.2. Calcul de la matrice de dépendances des niveaux de gris (GLCM)**

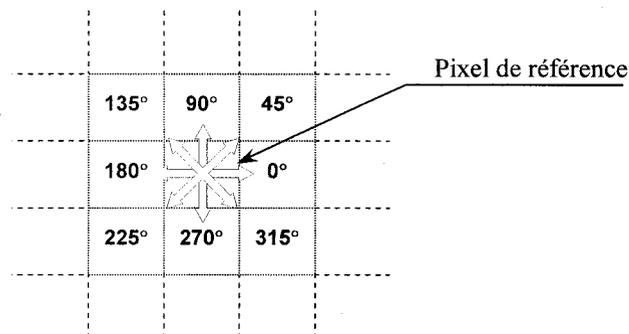
La base théorique utilisée dans le calcul des éléments de la GLCM d'une image a été définie par Haralick (1979) comme suit :

Soit  $f(x,y)$  une fenêtre rectangulaire choisie dans un bloc d'image (I) définie dans le domaine suivant :  $x \in [0, n_x)$  et  $y \in [0, n_y)$ . Soit  $n_g$  le nombre de niveaux de gris dans la fenêtre  $f(x,y)$ . Pour chaque fenêtre  $f(x,y)$ , on peut définir une matrice carrée  $P$  de dimension  $n_g$ . Cette matrice est définie comme étant la matrice de dépendances des niveaux de gris ou (GLCM).

Soit  $P_{ij}$  un élément de cette matrice qui se trouve à l'intersection de la ligne  $i$  et de la colonne  $j$  de cette matrice. La valeur de  $P_{ij}$  est une fonction des valeurs de tonalité des pixels et d'un vecteur de déplacement  $d$ . Les éléments  $P_{ij}$  de la GLCM sont calculées en additionnant le nombre de fois que deux pixels voisins spatialement séparés par  $d$  se présentent dans la fenêtre  $f(x,y)$  (l'un avec un niveau de gris égal à  $i$  et l'autre avec un niveau de gris égal à  $j$ ). Les éléments  $P_{ij}$  de la GLCM sont ensuite normalisés en divisant chaque élément par la somme de tous les éléments de la matrice.

Le vecteur de déplacement  $d$  peut être défini selon une ou plusieurs orientations ( $0^\circ$ ,  $45^\circ$ ,  $90^\circ$ , ...,  $315^\circ$ ). Les huit orientations possibles sont présentées sur la figure (3-9). Si on considère par

exemple une orientation de  $0^\circ$ , on prend en compte uniquement la valeur du pixel qui se trouve à droite du pixel de référence. La base théorique utilisée dans le calcul de ces éléments et les différentes mesures qui peuvent être extraites de la GLCM sont présentées avec plus de détail dans Haralick (1979).



**Figure 3-9 :** Orientations possibles pour le calcul de la GLCM.

L'exemple illustré dans la figure 3-10 montre une matrice de dépendances des niveaux de gris (GLCM) définie sur six niveaux de gris ( $n_g = 6$ ). Cette matrice a été produite à partir d'une fenêtre  $f(x,y)$  de  $5 \times 5$  pixels ( $n_x = 5$  et  $n_y = 5$ ) et avec une orientation de  $270^\circ$ . Avec cette orientation, on tient compte uniquement du pixel qui se trouve au-dessous du pixel de référence.

Fenêtre de l'image de dimension  $5 \times 5$

4	6	8	5	4
5	5	8	7	6
6	7	7	7	9
8	8	4	8	6
9	8	9	5	6

GLCM de cette fenêtre

		Valeurs numériques des pixels					
		4	5	6	7	8	9
Valeurs numériques des pixels	4	0	1	1	0	0	1
	5	0	0	1	2	0	0
	6	0	1	1	0	1	1
	7	1	0	0	1	2	0
	8	0	1	0	1	2	1
9	0	0	1	0	0	0	

**Figure 3-10 :** Exemple de calcul de la GLCM (PCI Geomatics, 1997)

### 3.8.3. Extraction des mesures de texture

Haralick (1979) a défini huit mesures de texture qui peuvent être dérivées de la GLCM. Ces mesures, dont plusieurs sont fortement corrélées, représentent des aspects différents de la GLCM.

$$\text{Homogénéité :} = \sum_{i,j=0}^{N-1} \frac{P(i,j)}{1+(i-j)^2} \quad (3-6)$$

$$\text{Contraste} = \sum_{i,j=0}^{N-1} P(i,j) \cdot (i-j)^2 \quad (3-7)$$

$$\text{Dissemblance} = \sum_{i,j=0}^{N-1} P(i,j) \cdot |i-j| \quad (3-8)$$

$$\text{Moyenne} = \sum_{i,j=0}^{N-1} i \cdot P(i,j) = \mu_i \quad (3-9)$$

$$\text{Écart type} = \sum_{i,j=0}^{N-1} P(i,j) \cdot (1-\mu_i)^2 = \sigma_i^2 \quad (3-10)$$

$$\text{Entropie} = \sum_{i,j=0}^{N-1} -P(i,j) \cdot \log P(i,j) \quad (3-11)$$

[en supposant que  $(0 \log (0) = 0)$ ]

$$\text{Second Moment Angulaire} = \sum_{i,j=0}^{N-1} P(i,j)^2 \quad (3-12)$$

$$\text{Corrélation} = \sum_{i,j=0}^{N-1} \frac{P(i,j) \cdot (i-\mu_i) \cdot (j-\mu_j)}{\sigma_i \cdot \sigma_j} \quad (3-13)$$

Dans ce projet, nous avons calculé huit mesures de texture pour les six images disponibles (3 en mode S1 et 3 en mode S7). Le module XPACE de Geomatica PCI Inc. a été utilisé pour calculer les 48 bandes de texture (huit mesures de texture pour chacune des six images). Le programme TEX de XPACE utilise la méthodologie développée par Haralick (1979) présentée dans les paragraphes précédents. Les images brutes ont été échelonnées *a priori* par ce module sur seize niveaux de gris par une méthode adaptative non linéaire. Cette étape permet de transformer les données de 32 bits à 4 bits afin de produire des GLCM qui reflètent bien les distributions des niveaux de gris et éviter des matrices avec des valeurs éparpillées. Les matrices obtenues après cette transformation ont une dimension de 16 x 16.

#### **3.8.4. Choix de la taille de fenêtre**

Le choix de la taille de la fenêtre pour extraire des informations sur la texture a un grand effet sur le résultat obtenu. Premièrement, la taille de la fenêtre doit être assez large pour avoir une

distribution significative des pixels. Deuxièmement, la taille de la fenêtre ne doit pas dépasser une certaine taille pour limiter les erreurs causées par la superposition des classes à l'intérieur d'une même fenêtre (Ulaby *et al.*, 1986). Ainsi, le choix de la taille de la fenêtre doit tenir compte du milieu d'étude et des informations recherchées dans l'image. Ulaby *et al.* (1986) ont utilisé des paramètres de texture extraits des images SAR de SEASAT avec 25 mètres de résolution pour classer des milieux forestiers dans l'état d'Oklahoma aux États Unis. Ils ont testé cinq tailles de fenêtres entre 4 x 4 et 8 x 8. Le meilleur résultat a été obtenu avec une fenêtre de 8 x 8. Le choix de cette limite supérieure de 8 x 8 a été basé sur des observations de la distribution des classes sur le terrain afin de limiter la superposition des classes à l'intérieur d'une seule fenêtre. Chan *et al.* (2000) ont utilisé cinq tailles de fenêtres entre 3 x 3 et 11 x 11 pixels pour détecter les changements sur le terrain avec des données optiques de 250 mètres de résolution. Les auteurs ont conclu qu'une taille de la fenêtre supérieure à 11 x 11 ne donne pas une information supplémentaire à la classification. Wikantika *et al.* (2000a) ont testé trois tailles de fenêtres 3 x 3, 5 x 5 et 7 x 7 pour discriminer entre neuf types de couvertures du sol avec des images RADARSAT et Landsat TM. Les meilleurs résultats ont été obtenus avec une fenêtre de 7 x 7.

Dans ce projet, trois tailles de fenêtres (3 x 3, 5 x 5 et 7 x 7) ont été testées. Le choix d'une limite supérieure de 7 x 7 a pour but de réduire le risque de superposition de plusieurs classes dans la même fenêtre. Les graphiques de la figure 3-12 montrent l'effet de la taille de la fenêtre sur trois mesures de textures : la Moyenne, l'Écart Type et la Corrélacion. Ces mesures de texture ont été extraites de l'image S7 du mois d'avril. Ces graphiques représentent, pour chaque mesure de texture, la variation de la texture moyenne et de l'écart type en fonction de la taille de fenêtre pour les quatre classes définies au deuxième chapitre. En observant la variation de l'écart type, on constate que ce dernier diminue quand la taille de la fenêtre augmente et ceci pour les trois mesures de texture. La diminution de l'écart type est expliquée par l'augmentation de nombre de pixels qui passe de 9 pixels pour la fenêtre 3 x 3 à 49 pixels pour la fenêtre 7 x 7. Toutefois, l'effet de la taille de fenêtre sur la texture moyenne varie d'une texture à une autre. Par exemple, pour la texture Moyenne (3-9), la taille de la fenêtre n'a aucun effet sur la valeur moyenne de la texture pour les quatre classes, tandis que pour les textures Corrélacion (3-13) et Écart type (3-10), l'augmentation de la taille de la fenêtre augmente la valeur de la texture tout en gardant les mêmes proportions entre les quatre classes. Les histogrammes détaillés utilisées dans la production de ces graphiques sont présentés en annexe A.

D'après ces observations, on peut conclure que l'augmentation de la taille de la fenêtre augmente le pouvoir discriminatoire de la texture. Toutefois, le choix de la taille de la fenêtre doit tenir compte de la superficie des classes sur le terrain afin d'éviter toute confusion ou superposition des classes. Comme suite à ces observations, nous avons choisi une taille de fenêtre de 7 x 7 puisque la superficie de certaines zones homogènes (surtout les milieux humides fortement arborés) ne dépasse pas 200 x 200 mètres soit une fenêtre de 8 x 8 pixels. Ce choix respecte la condition avancée par Ulaby *et al.* (1986) selon laquelle la taille de la fenêtre ne doit pas dépasser la superficie de la plus petite zone à classer.

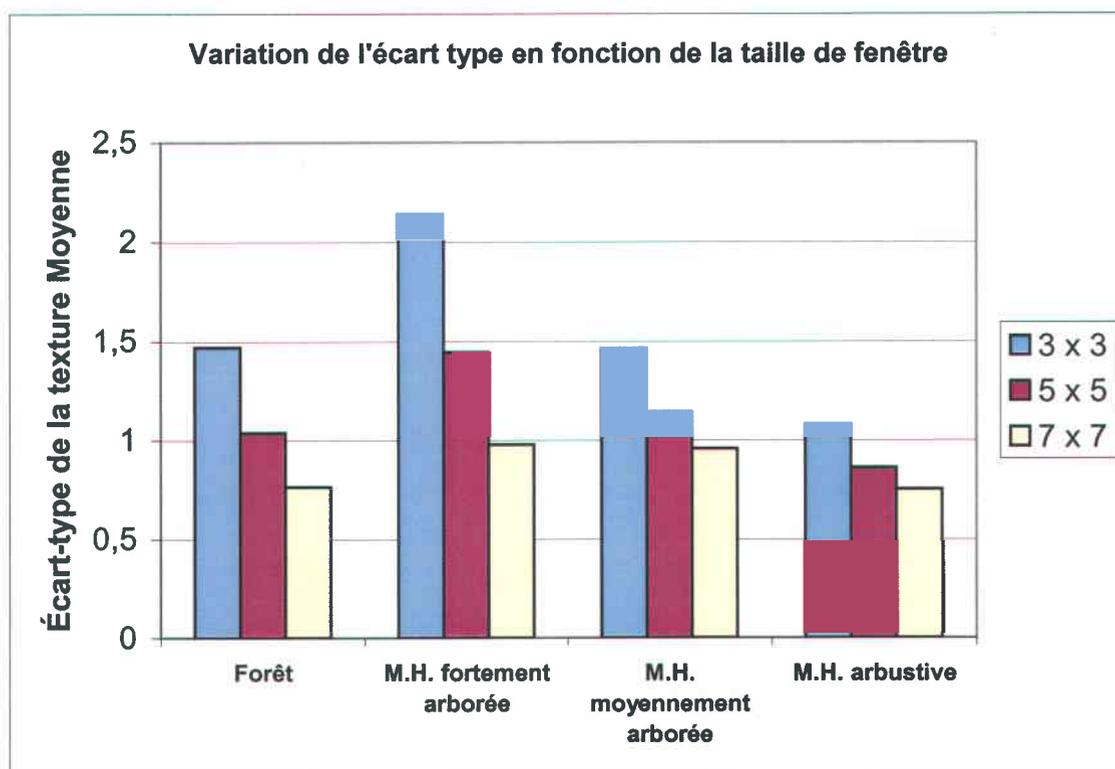
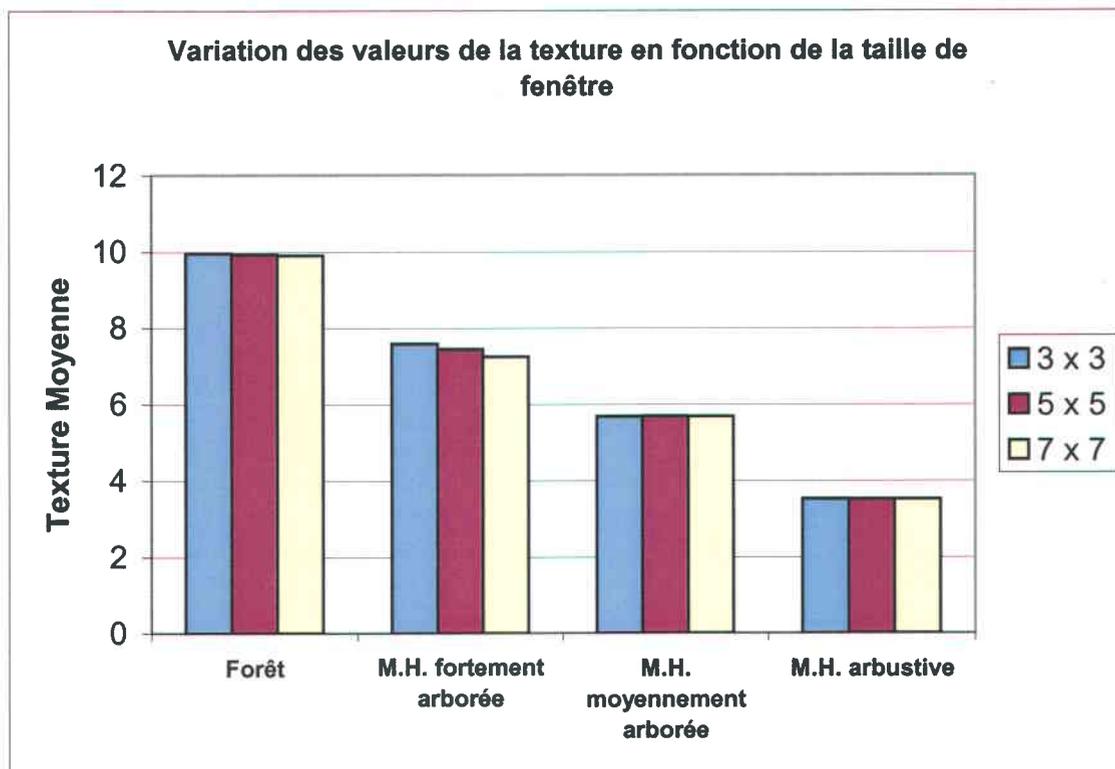
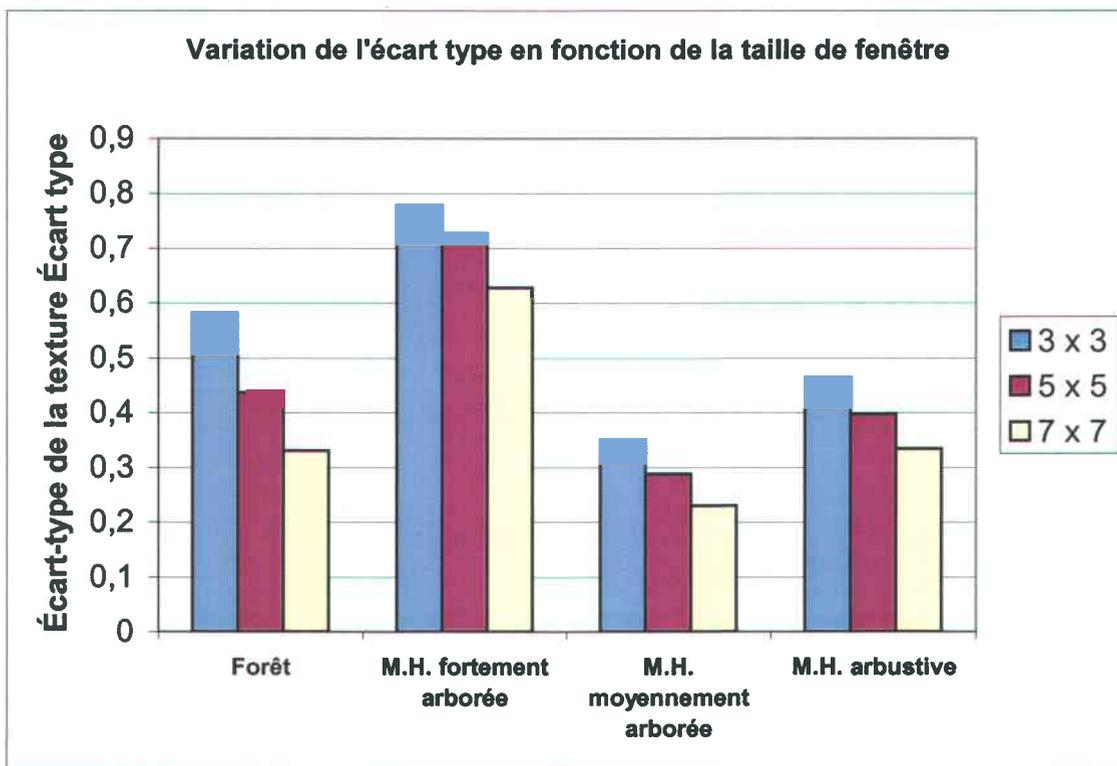
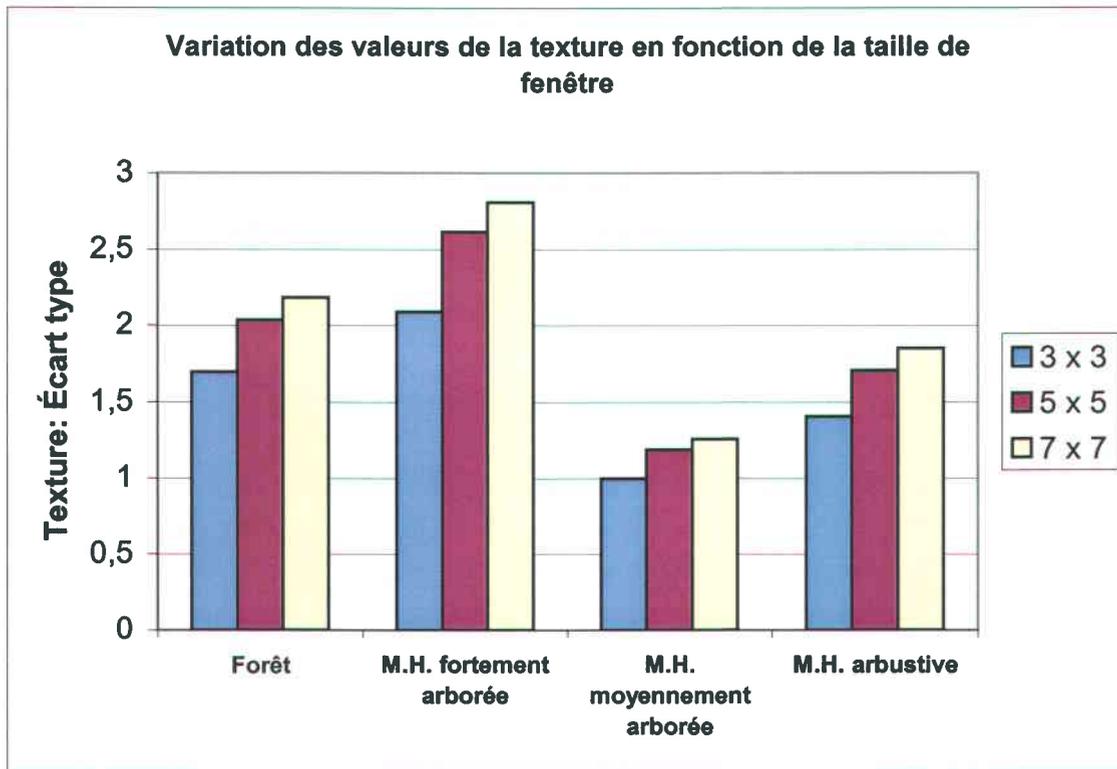
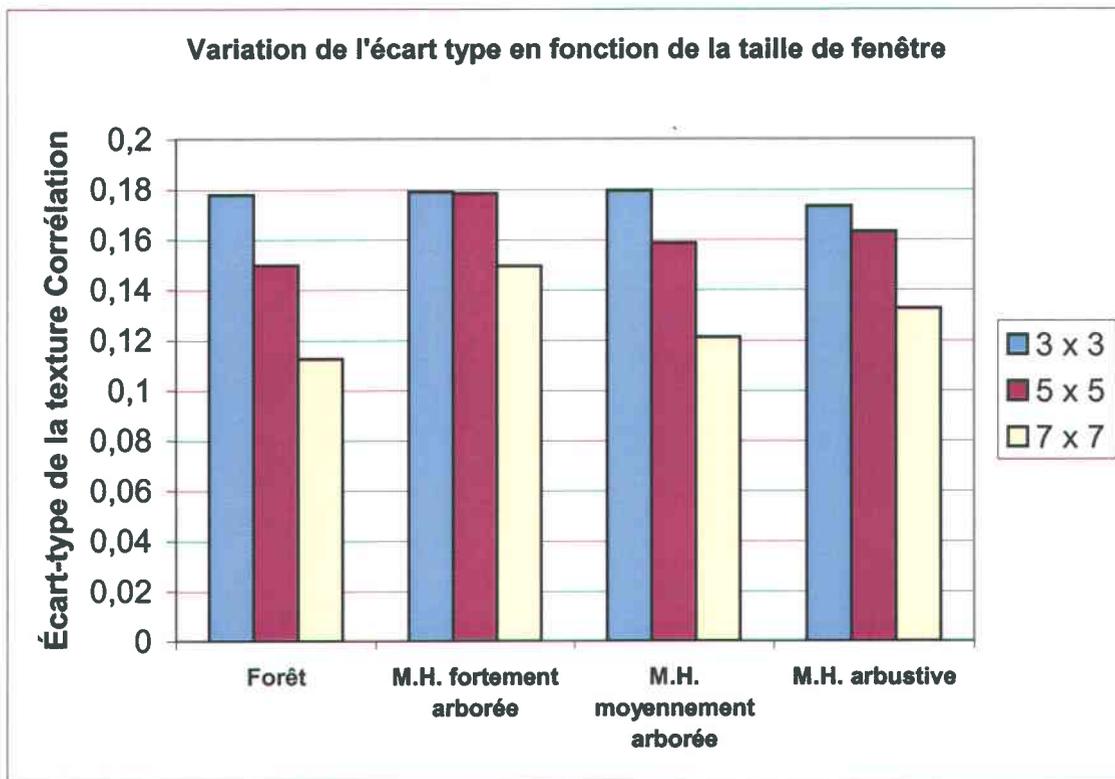
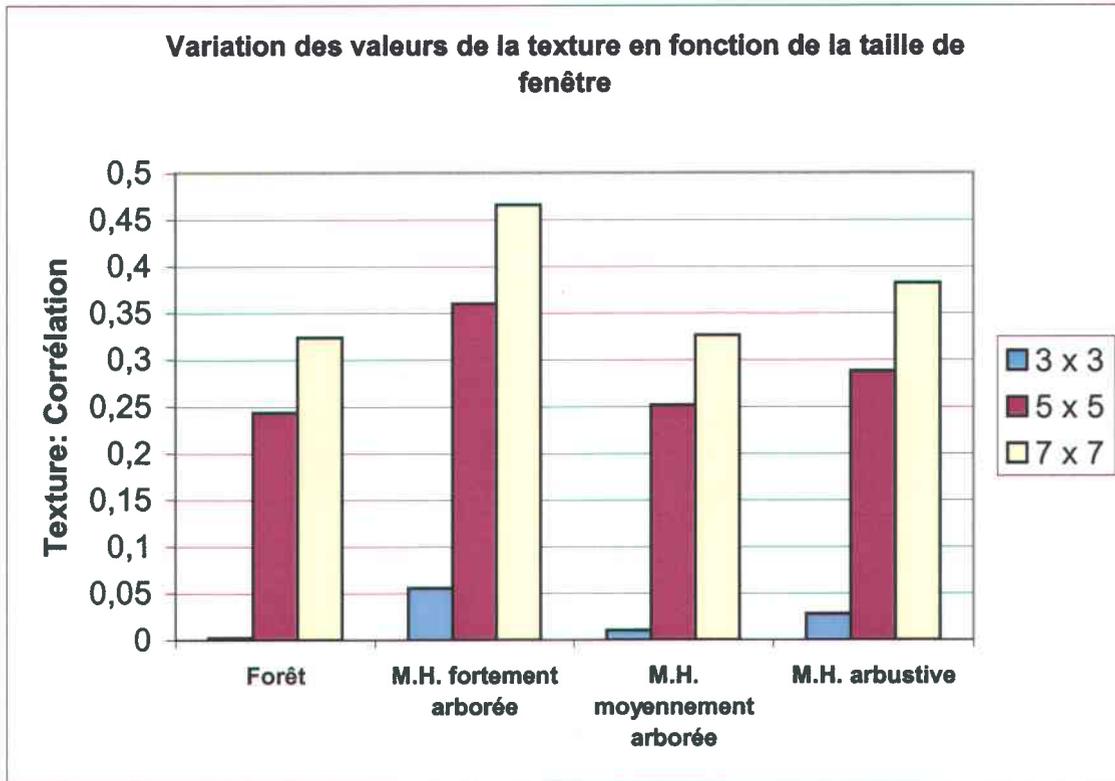


Figure 3-11a. Effet de la taille de fenêtre sur la texture Moyenne



**Figure 3-11b.** Effet de la taille de fenêtre sur la texture Écart Type



**Figure 3-11c. Effet de la taille de fenêtre sur la texture Corrélation**

### 3.8.5. Analyse de corrélation

Même si les mesures de texture qui peuvent être dérivées de la GLCM représentent des aspects différents, plusieurs d'entre elles sont fortement corrélées (Haralick, 1979). À cet effet, afin de réduire la quantité de données à fournir au réseau de neurones, nous avons effectué une analyse de corrélation pour choisir les textures les moins corrélées. Cette analyse permet d'éliminer les informations inutiles et réduire considérablement la taille du réseau de neurones et par conséquent le temps nécessaire pour la classification des données.

Le résultat de cette analyse est présenté dans le tableau 3-3. Les valeurs en gras sont celles qui présentent les corrélations les plus élevées. Chaque coefficient de corrélation représente la moyenne des coefficients obtenus pour chacune des six images utilisées dans ce projet.

**TABLEAU 3-3.** Corrélation moyenne entre les différentes mesures de la texture

	1	2	3	4	5	6	7	8
1	<b>1,00</b>							
2	<b>-0,79</b>	<b>1,00</b>						
3	<b>-0,90</b>	<b>0,97</b>	<b>1,00</b>					
4	-0,20	0,23	0,24	<b>1,00</b>				
5	-0,55	<b>0,73</b>	<b>0,70</b>	0,15	<b>1,00</b>			
6	<b>-0,79</b>	<b>0,77</b>	<b>0,81</b>	0,20	<b>0,79</b>	<b>1,00</b>		
7	<b>0,79</b>	-0,66	<b>-0,73</b>	-0,19	<b>-0,67</b>	<b>-0,94</b>	<b>1,00</b>	
8	0,11	-0,07	-0,09	-0,03	0,60	0,29	-0,24	<b>1,00</b>

1. Homogénéité, 2. Contraste, 3. Dissemblance, 4. Moyenne, 5. Écart type, 6. Entropie, 7. Second Moment Angulaire et 8. Corrélation.

Comme suite à cette analyse, les trois mesures les moins corrélées ont été retenues pour le reste du projet soit la Moyenne (3-9), l'Écart Type (3-10) et la Corrélation (3-13). Ces mesures sont calculées à partir de la GLCM normalisée d'une fenêtre 7 x 7 avec des données brutes échelonnées en 4 bits.

Le choix d'une mesure de texture varie d'une application à une autre. Pour la classification d'un milieu forestier avec des images SEASAT, Ulaby *et al.* (1986) ont effectué une analyse similaire de corrélation pour choisir les textures les moins corrélées. Après cette analyse, ils ont gardé quatre mesures de texture soit l'Homogénéité, le Contraste, le Moment angulaire secondaire et

la Corrélation. Chan *et al.* (2000) ont fait plusieurs tests statistiques pour choisir les meilleures mesures de texture. Ils ont trouvé que le Contraste, la Moyenne, la Dissemblance et l'Entropie offrent les meilleurs résultats pour détecter les changements de l'occupation du sol. Wikantika *et al.* (2000b) ont testé quatre mesures de textures : l'Écart type, l'Entropie, le Contraste et le Moment angulaire secondaire pour classifier des images RADARSAT. Les meilleurs résultats ont été obtenus avec trois mesures de texture en excluant le Moment angulaire secondaire.

Les trois graphiques de la figure 3-12 montrent le comportement des différentes classes avec les trois mesures de texture retenues dans ce projet. Les histogrammes détaillés utilisées dans la production de ces graphiques sont présentés en annexe A. Ces graphiques montrent la supériorité du mode S7 dans la discrimination des composantes internes des milieux humides. Si on compare ces graphiques avec celui obtenu avec les images brutes (figure 3-6), on voit que, pour chaque mode d'acquisition, les valeurs de la texture de quatre classes sont plus stables que les valeurs brutes de rétrodiffusion entre les différentes dates d'acquisition. Ceci est clairement remarquable avec la texture moyenne (figure 3-12a). La stabilité de la texture réduit l'impact des conditions environnementales sur la rétrodiffusion et donne plus de flexibilité pendant le choix des dates d'acquisition. Car, un modèle de classification basé sur des conditions météorologiques particulières (neige sèche, fonte de neige, sol inondé... etc.) reste vulnérable à des imprévus climatiques (fonte prématurée de la neige, sécheresse, gel du sol... etc.).

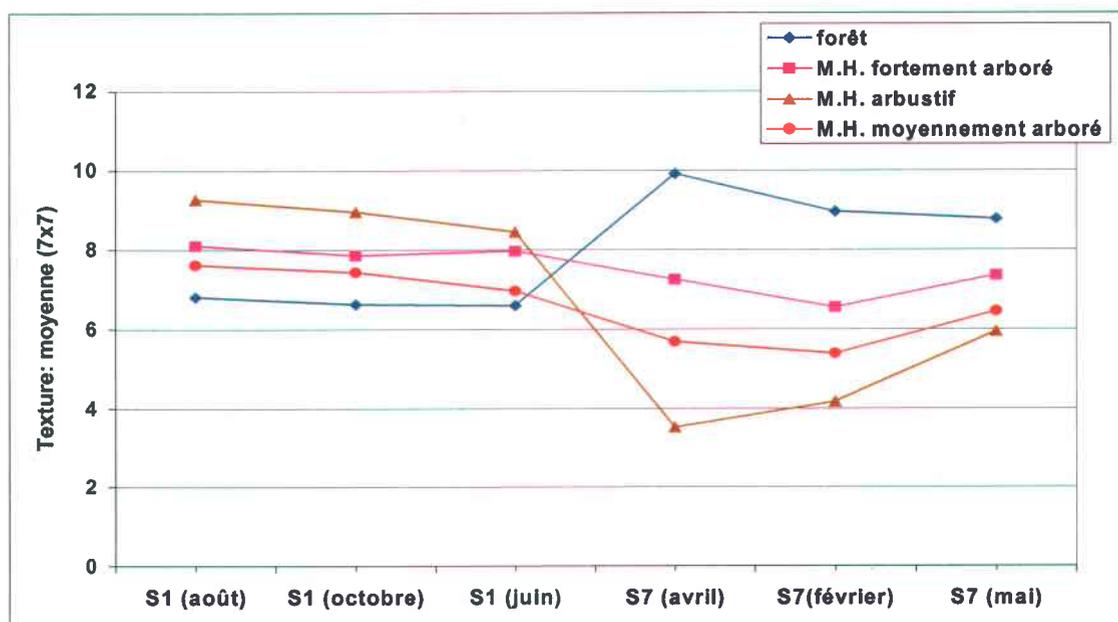


Figure 3-12a. Variation temporelle de la texture Moyenne en fonction de classes.

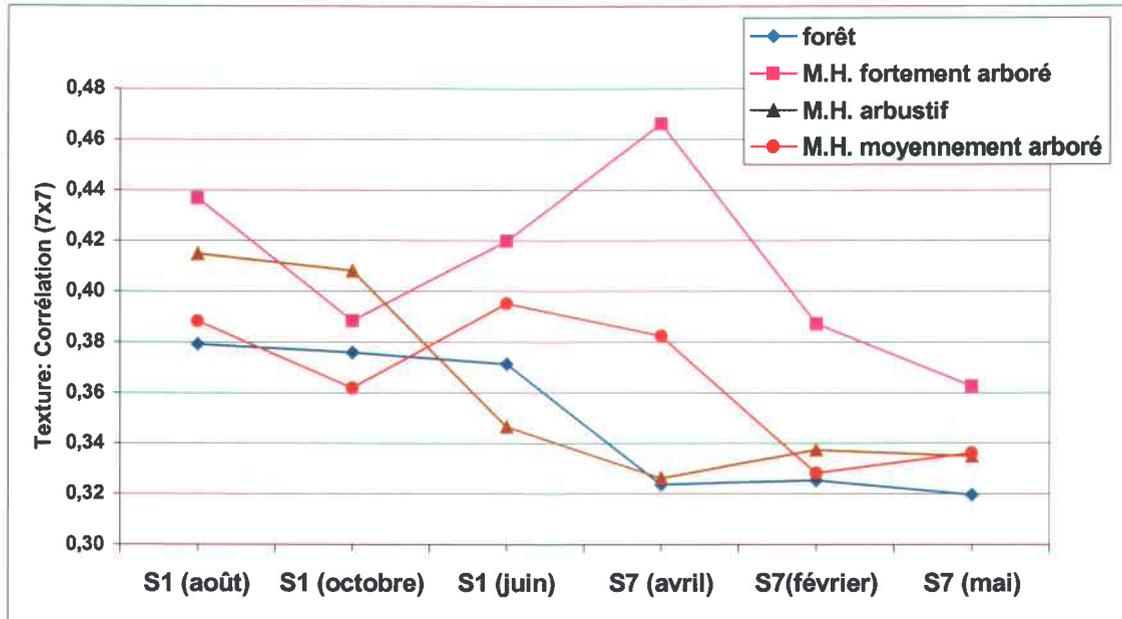


Figure 3-12b. Variation temporelle de la texture Corrélation en fonction de classes.

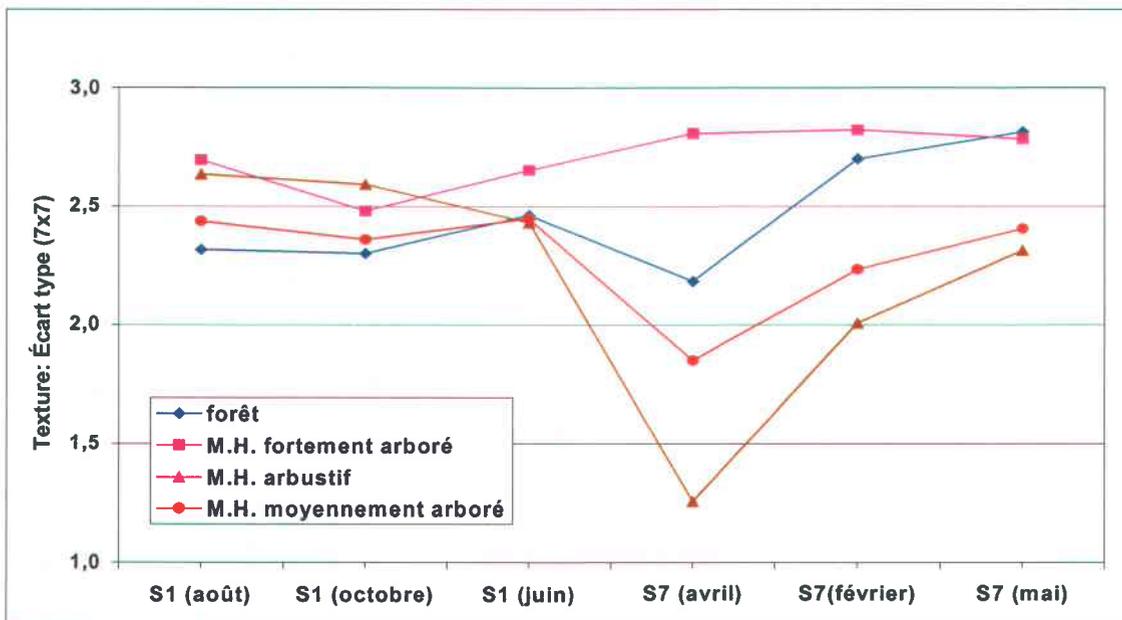


Figure 3-12c. Variation temporelle de la texture Écart Type en fonction de classes.

### 3.9. Analyse de séparabilité

L'analyse de séparabilité permet d'évaluer le potentiel informatif et discriminatoire d'une image quelconque. À l'aide de cette analyse, on peut savoir *a priori* si une image peut donner un

apport positif dans un processus de classification. L'indice de séparabilité (équation 3-14) entre deux classes est un paramètre statistique qui dépend de la moyenne et de l'écart type des deux échantillons en question. Deux classes sont définies comme statistiquement séparables si la différence entre leurs moyennes respectives est supérieure à la somme des deux écart types soit un indice de séparabilité supérieur à 1. L'indice de séparabilité, calculé par l'équation 3-14, permet d'évaluer la distance qui existe entre deux classes dans une bande d'image. Cette équation a été utilisée par plusieurs auteurs pour évaluer la séparabilité des classes (Cumming and Van Zyl, 1989, Shi *et al.*, 1994 et Baghdadi *et al.*, 2001).

$$I_{C1/C2} = \frac{|\mu_{C1} - \mu_{C2}|}{\sigma_{C1} + \sigma_{C2}} \quad (3-14)$$

où :

- $I_{C1/C2}$  L'indice de séparabilité entre les classes C1 et C2
- $\mu_i$  La valeur moyenne des pixels de la classe (i)
- $\sigma_i$  L'écart type des pixels de la classe (i)

Nous avons effectué une analyse de séparabilité entre les quatre classes pour les 18 mesures de texture (trois textures retenues pour chaque image) et pour les six images brutes. Chaque histogramme de la figure 3-13 présente les indices de séparabilité calculés pour chaque source d'information soit les images brutes, textures Moyennes (3-9), textures Écart Type (3-10) et textures Corrélations (3-13). Une première observation de ces histogrammes montre que pour toutes les mesures de texture, et pour toutes les combinaisons des classes, les images S7 offrent une séparabilité supérieure à celle obtenue avec les images S1. Cette supériorité est due principalement à la forte sensibilité des micro-ondes à angle d'incidence élevé à la composition structurale de la surface supérieure de la végétation.

En comparant l'apport de trois mesures de texture à la séparabilité des classes, on observe que la texture Moyenne offre les meilleurs résultats et surtout avec les trois images S7. Par contre, la texture Corrélation n'apporte aucune amélioration au pouvoir discriminatoire des images mais au contraire, elle est même inférieure aux séparabilités obtenues avec les images brutes. L'amélioration apportée par la texture Écart Type à la séparabilité reste faible. Elle est à peine supérieure aux séparabilités obtenues avec les images brutes.

D'autres mesures de texture peuvent donner une séparabilité supérieure à celle obtenue par la texture Corrélation ; mais, il est fort probable qu'elles seront corrélées avec l'une ou l'autre des textures gardées pour ce test de séparabilité. En effet, dans plusieurs études qui ont fait usage de la texture, les auteurs ont gardé entre deux et quatre mesures après plusieurs tests d'élimination soit par corrélation ou par d'autres tests statistiques (Ulaby *et al.*, 1986; Chan *et al.*, 2000; Wikantika *et al.* 2000b).

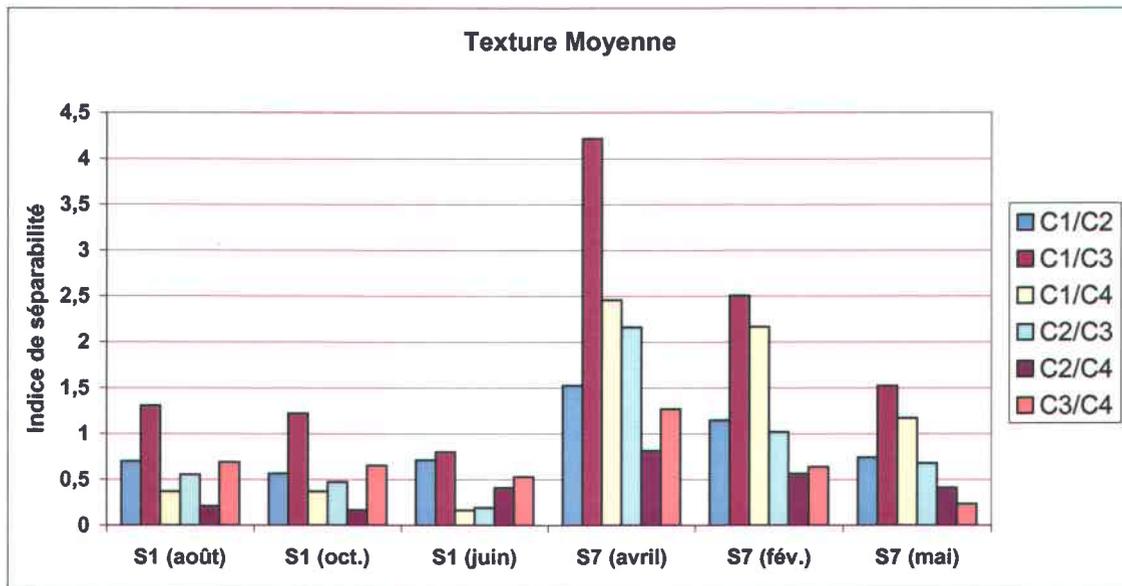


Figure 3-13a. Variation temporelle des indices de séparabilité pour la texture Moyenne

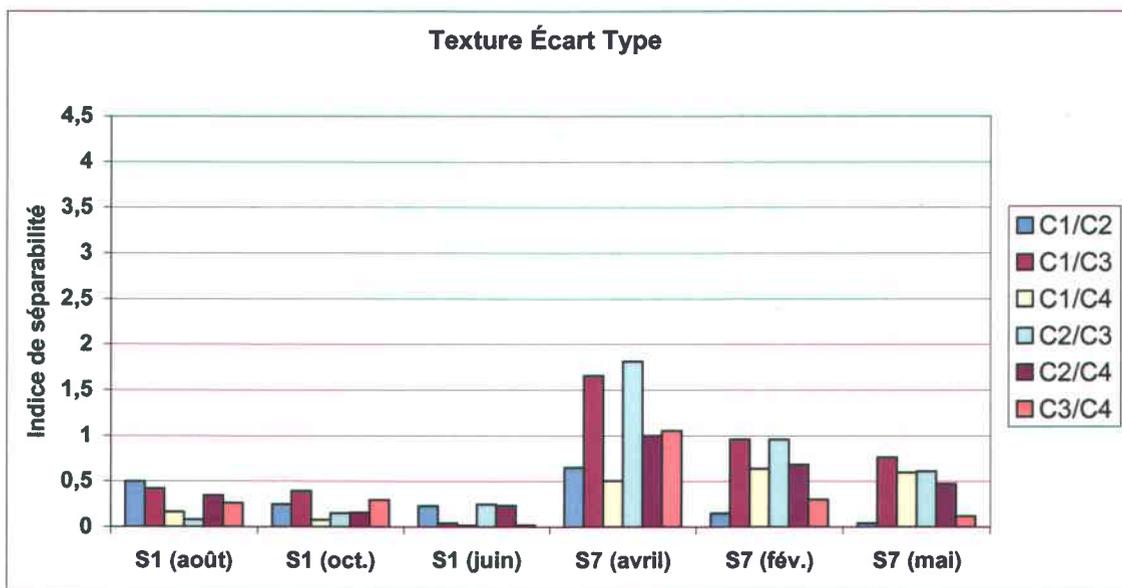


Figure 3-13b. Variation temporelle des indices de séparabilité pour la texture Écart Type

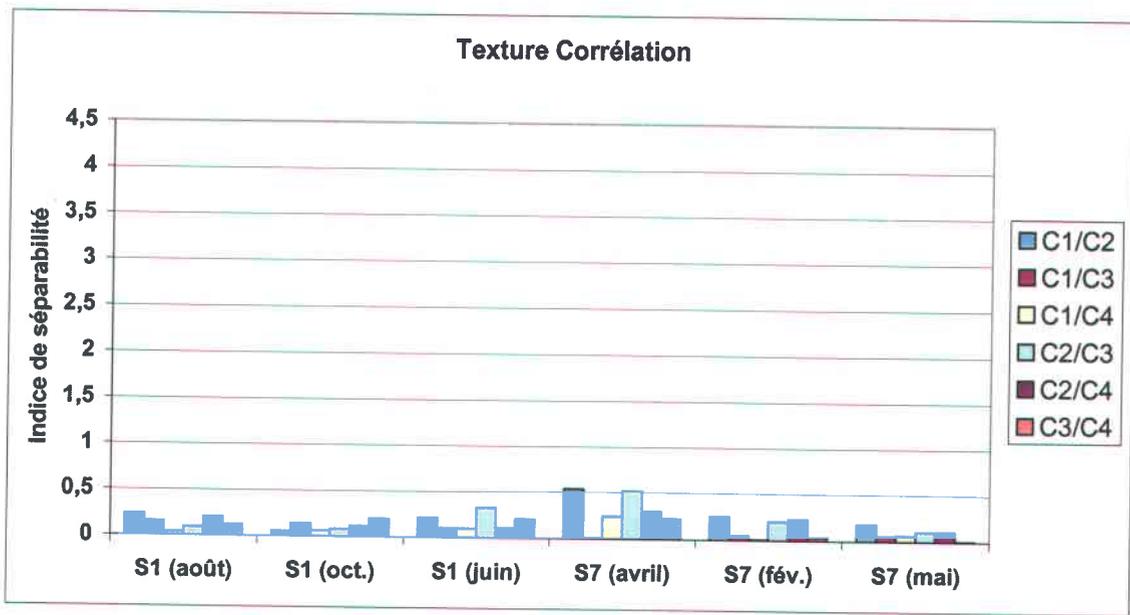


Figure 3-13c. Variation temporelle des indices de séparabilité pour la texture Corrélation

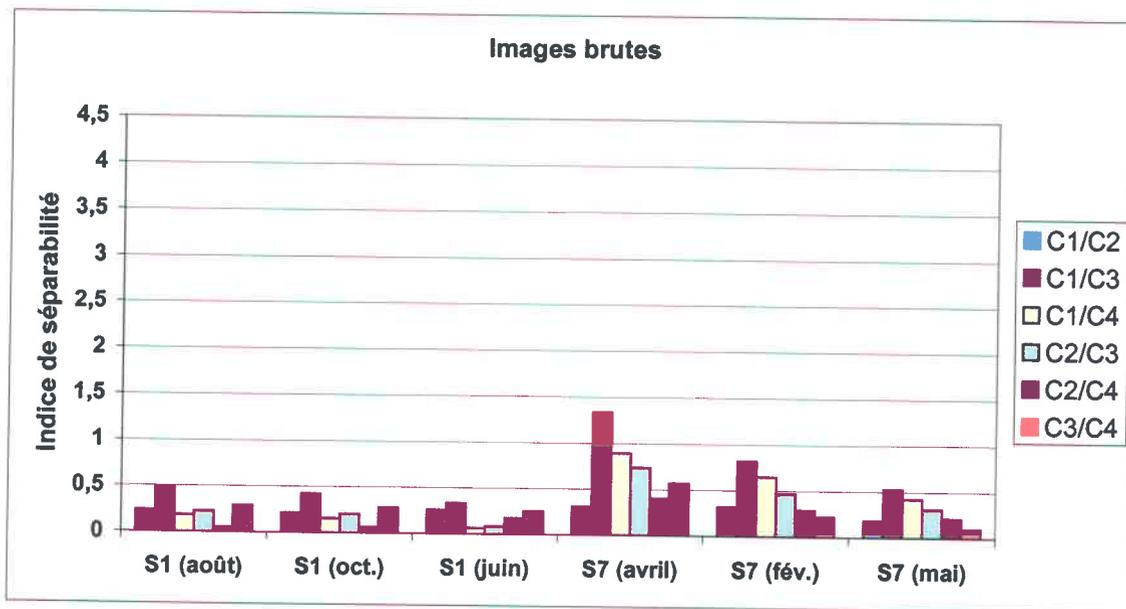
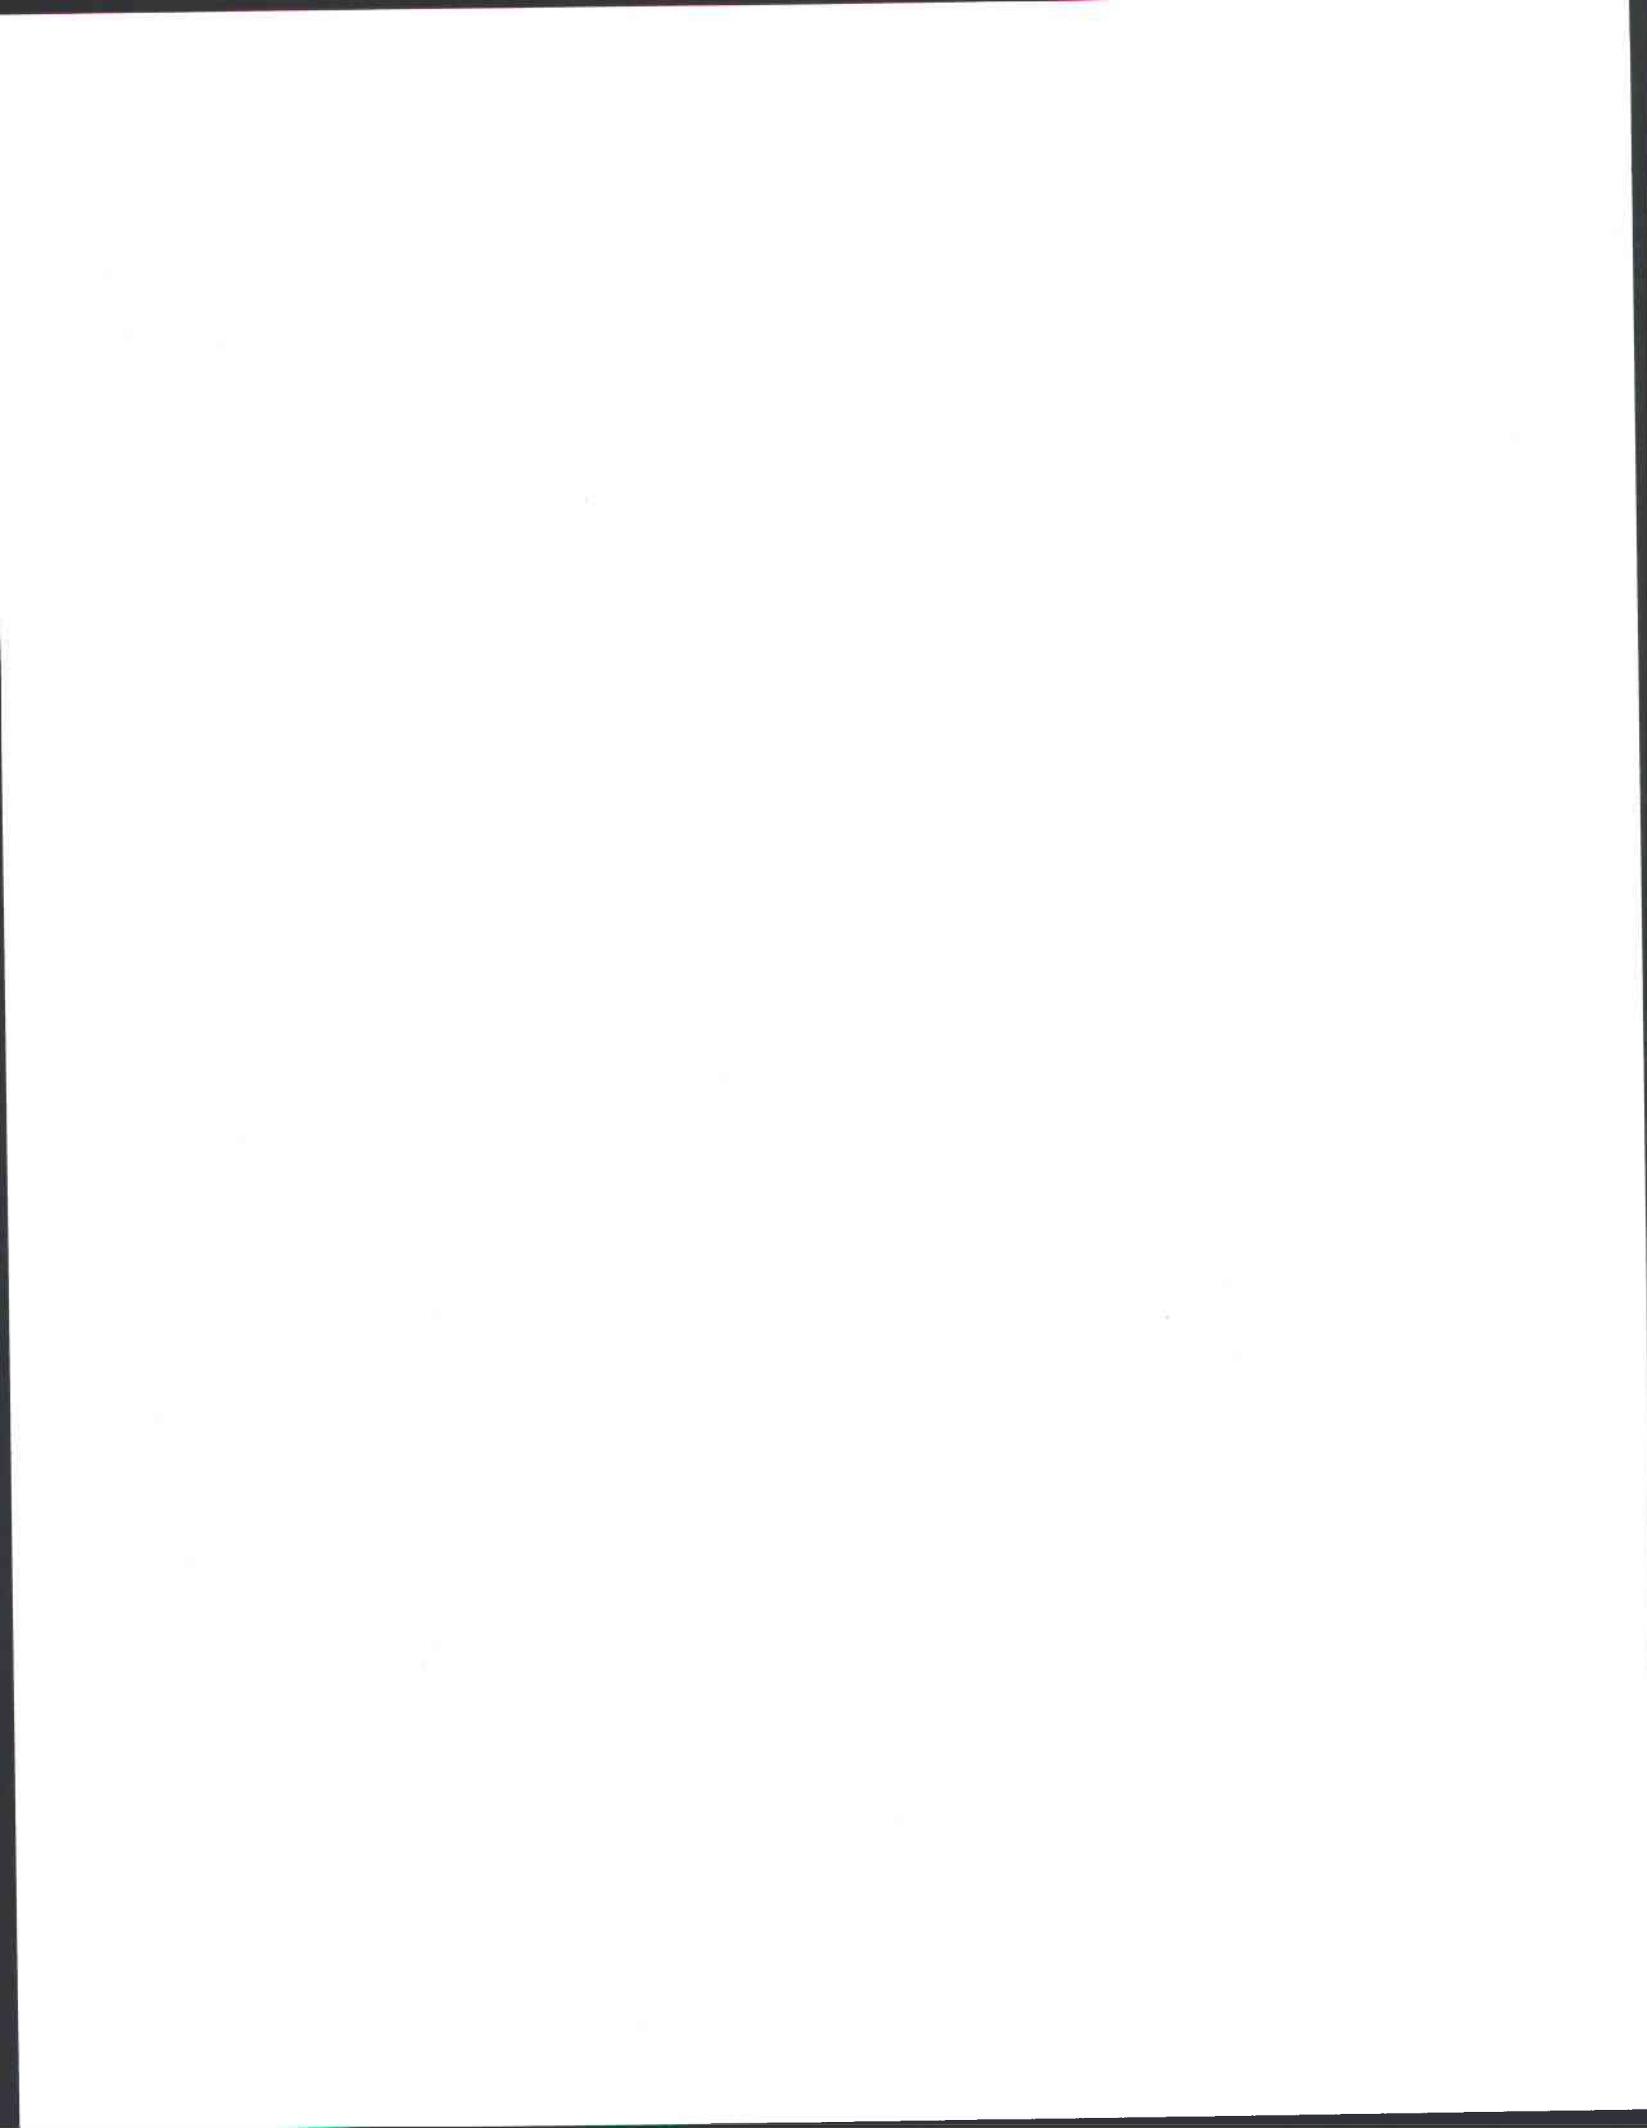


Figure 3-13d. Variation temporelle des indices de séparabilité pour les images brutes

C1 : Milieu forestier      C2 : Milieu humide fortement arboré  
 C3 : Milieu humide arbustif      C4 : Milieu humide moyennement arboré



# CHAPITRE 4

## Introduction aux réseaux de neurones

---

Ce chapitre présente une introduction à la théorie de réseaux de neurones. Nous présentons à la fin de ce chapitre (§ 4.8) un aperçu des autres algorithmes couramment utilisés pour la classification supervisée des images de télédétection. L'adaptation des réseaux de neurones à la classification des données Radarsat-1 sera présentée avec plus de détails au chapitre suivant.

### **4.1. Introduction**

Les réseaux de neurones sont constitués d'un ensemble de neurones artificiels ou nœuds qui sont analogues aux neurones biologiques. Ils sont issus d'une tentative de conception d'un modèle mathématique très simplifié du cerveau humain en se basant sur notre façon d'apprendre et de corriger nos erreurs. Les premiers travaux sur les réseaux de neurones ont été réalisés en 1943 par Mc Culloch et Pitts. Ces deux chercheurs sont les premiers à montrer théoriquement que des réseaux de neurones formels et simples peuvent réaliser des fonctions logiques, arithmétiques et symboliques. Ils ont ainsi présenté un modèle assez simple pour les neurones pour explorer différentes possibilités d'applications.

L'évolution phénoménale des outils informatiques a largement contribué au développement des réseaux de neurones. Il existe plusieurs types de réseaux de neurones tels que les "perceptrons", les réseaux à fonctions de base radiales et les réseaux récurrents. Parmi eux, les perceptrons à alimentation directe (*feed-forward*) et entraînés par rétropropagation (*backpropagation*) ont eu un succès important dans plusieurs applications (Chan *et al.*, 1996).

Leur intérêt provient de la simplicité de leur utilisation et de l'algorithme de rétropropagation proposé par Werbos *et al.*, (1974) et diffusé par Rumelhart *et al.* (1986).

Un réseau de neurones sera plus efficace si les utilisateurs comprennent bien son fonctionnement et sa structure interne (Gopal and Woodcock, 1996). Toutefois, les paramètres internes d'un réseau de neurones ont été à peine explorés dans des applications en télédétection radar malgré leur rôle important dans le fonctionnement et la convergence du réseau (Gopal and Woodcock, 1996). Ces paramètres sont liés à l'architecture du réseau et à l'algorithme d'apprentissage. L'optimisation de ces paramètres consiste à chercher la configuration qui donne la meilleure précision au résultat final du réseau.

#### **4.2. Utilisation des réseaux de neurones en télédétection**

Le développement et l'amélioration continus des réseaux de neurones (RNs) ont permis de bien cerner le potentiel et les limites de cette technique dans plusieurs domaines. Parmi celles-ci, la télédétection a bénéficié de l'évolution rapide des RNs et de leur efficacité marquée dans plusieurs applications de classification et de prédiction. Depuis la fin des années quatre-vingts, les applications faisant recours à cette technologie n'ont pas cessé de s'accroître (Kanellopoulos and Wilkinston, 1997). Ces applications concernent différents types de données spatiales et aéroportées, optiques et radar. Paola et Schowengerdt (1994) ont traité les différents aspects liés à l'utilisation des RNs en télédétection en étudiant la majorité des études publiées avant 1994. Kanellopoulos et Wilkinston, (1997) ont étudié l'usage des RNs en télédétection et ont donné les meilleures façons d'utiliser cette technique en classification d'images en se basant sur plusieurs recherches réalisées dans ce domaine.

La non linéarité entre les entrées et les sorties a contribué à la réussite des RNs par rapport aux autres méthodes (Gopal and Woodcock, 1996). Certains auteurs ont testé l'efficacité des RNs pour l'estimation de quelques paramètres à partir des données de télédétection. Parmi ces travaux on cite : Gopal and Woodcock (1996) qui ont comparé les RNs à d'autres approches analytiques pour détecter l'impact de la sécheresse sur les forêts à l'aide d'une série temporelle d'images TM; Kimes *et al.* (1997) ont testé le potentiel des RNs pour l'extraction des informations sur les propriétés des végétations (biomasse, âge, hauteur, LAI ...etc.); Bhattacharya et Parui (1997) ont appliqué les RNs pour la détection des routes à partir d'une image SPOT.

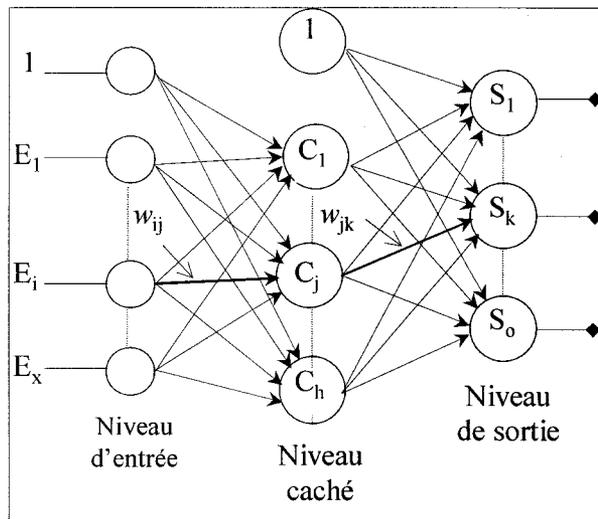
Un réseau de neurones permet d'optimiser la meilleure approximation non linéaire basée sur la structure complexe du réseau et ceci sans aucune contrainte sur la linéarité ou sur la non linéarité spécifiée a priori comme dans les méthodes usuelles de régression (Kimes *et al.*, 1997). Or, la comparaison entre les méthodes conventionnelles de classification et les réseaux de neurones traduit de façon évidente le potentiel de ces derniers à apporter de nouvelles approches et à améliorer la précision d'une classification (Bendiktsson et Sveinsson., 1997).

### **4.3. Architecture d'un réseau de neurones**

Dans un réseau de neurones multicouches, les neurones sont organisés en couches successives (Figure 4-1). Chaque neurone d'une couche reçoit des signaux de la couche antérieure et transmet le résultat aux neurones de la couche postérieure en suivant un seul sens de propagation de l'information (entrée – sortie). Avec cette configuration, la couche d'entrée reçoit les variables d'entrée et la couche de sortie fournit les résultats. Les autres couches qui se trouvent entre la couche d'entrée et la couche de sortie sont appelées couches cachées.

Le nombre de niveaux cachés et le nombre de neurones par niveau représentent les paramètres architecturaux du réseau. La plupart des réseaux de neurones contiennent sur leur niveau d'entrée et leurs niveaux cachés, un nœud particulier ayant un rang égal à zéro et une valeur indépendante des couches précédentes. Ce nœud, dit biais, a une valeur fixe égale à 1 indépendamment de la combinaison utilisée à l'entrée du réseau. Ce nœud possède son propre poids et il est traité comme les autres nœuds dans les différentes phases de calcul du réseau. L'ajout de ce nœud au niveau d'entrée du réseau permet de lui donner plus de flexibilité pendant la phase d'apprentissage (Tarassenko, 1998).

Un nombre élevé de neurones dans les niveaux intermédiaires augmente le temps de calcul et diminue la généralisation du réseau, d'où la nécessité de trouver le meilleur compromis pour le nombre de niveaux et de neurones cachés (Heermann and Khazenie, 1992). Toutefois, il est avantageux de commencer la phase d'optimisation avec plusieurs neurones cachés afin d'éviter une prolongation inutile de la phase d'apprentissage causée par l'oscillation du réseau autour de l'erreur minimale. Toutefois, une oscillation du réseau pendant la phase d'apprentissage ne signifie pas nécessairement que le niveau caché est petit. La source la plus probable de cette oscillation (instabilité) du réseau est le mauvais choix du taux d'apprentissage (Heermann and Khazenie, 1992).



**Figure 4-6.** Architecture d'un réseau multicouches

D'après des expériences menées par Kanellopoulos et Wilkinston (1997), pour un réseau multicouche, le premier niveau caché doit contenir idéalement un nombre de neurones compris entre le double et le triple des neurones du niveau d'entrée. En outre, les auteurs ont trouvé, pour une vingtaine de classes, qu'un seul niveau caché suffit généralement pour la plupart des classifications. Cette observation a été aussi confirmée par Kimes *et al.* (1997) qui ont trouvé qu'un réseau de neurones à trois niveaux est généralement suffisant pour résoudre n'importe quelle fonction entre les entrées et les sorties.

#### **4.4. Format des données**

Contrairement au nombre de neurones des niveaux cachés (qui doivent être déterminés expérimentalement), le nombre de neurones du niveau d'entrée et du niveau de sortie est directement lié aux informations disponibles et au nombre de classes.

##### **4.4.1. Niveau d'entrée**

Pour le niveau d'entrée, on affecte généralement un neurone pour chaque information fournie au réseau (bandes spectrales, images ou d'autres informations supplémentaires). L'ordre de présentation des données d'entrée n'est pas important. Par contre, le format de la valeur présentée au réseau a un effet primordial sur les phases d'entraînement et de classification.

La plupart des réseaux sont conçus pour travailler avec des données comprises entre 0 et 1 et pour utiliser un neurone pour chaque valeur (Paola and Schowengerdt, 1995). Toutefois, plusieurs auteurs suggèrent d'utiliser un neurone pour chaque bit. Avec un choix pareil, 8 neurones seraient requis pour chaque bande de 8 bits (image TM) ou 32 neurones pour chaque image radar. L'utilisation de cette méthodologie permet de rendre le réseau plus sensible aux petites variations des valeurs numériques des pixels surtout si les entrées doivent être normalisées entre 0 et 1. Par contre, l'utilisation du codage binaire des données a l'inconvénient d'augmenter considérablement le temps nécessaire pour l'entraînement du réseau (Paola and Schowengerdt, 1995). Comme exemple, Heermann et Khazenie (1992) ont présenté les données au réseau sous forme binaire ce qui donne 8 neurones pour chaque bande TM et un total de 24 neurones au niveau d'entrée pour la classification de trois bandes TM. Dans d'autres applications, une fenêtre de 9 pixels (3 x 3) est introduite pour chaque bande (neuf neurones / bande / pixel). Cette méthode a l'avantage d'introduire des informations sur la texture pendant la phase d'entraînement mais elle augmente considérablement le temps de calcul. D'autres auteurs utilisent un compromis pour réduire le temps de calcul tout en gardant une information sur la texture et ceci en introduisant une fenêtre de 3 x 3 juste pour une bande et les valeurs de pixels pour le reste des bandes (Paola and Schowengerdt, 1995).

L'ajout des informations supplémentaires au réseau (modèle numérique du terrain, informations sur la texture, etc.) aide souvent à augmenter la performance du réseau tant que ces informations sont utiles et complémentaires aux données utilisées (Kanellopoulos and Wilkinston, 1997). Par contre, des sources supplémentaires de données peuvent augmenter considérablement le temps de calcul sans aucun ajout significatif à la précision des résultats (Paola and Schowengerdt, 1995). Les informations présentées à l'entrée seront filtrées par le réseau en donnant des poids différents pour chaque information. Ainsi, seules les données utiles seront prises en considération pour calculer la sortie (Gopal and Woodcock, 1996). Il est aussi possible d'appliquer un filtre moyen avant de présenter les données à l'entrée du réseau. Cette opération peut être faite automatiquement par le RN pendant la phase d'apprentissage (Paola and Schowengerdt, 1995).

#### **4.4.2. Niveau de sortie**

Dans le niveau de sortie, il est préférable d'utiliser un neurone pour chaque classe pour que chaque neurone soit entraîné pour donner la valeur la plus proche pour la classe correspondante. Dans ce cas, la classe attribuée au pixel sera celle attribuée au neurone ayant

la sortie la plus élevée entre 0 et 1 (Paola and Schowengerdt, 1995). Si on veut augmenter encore plus la précision de la classification, on peut fixer un seuil entre 0 et 1 pour qu'aucune classe ne soit attribuée au pixel concerné (pixel nul ou pixel non classé). Paola et Schowengerdt (1995) ont fixé un seuil égal à 0.4; si tous les neurones du niveau de sortie donnent une valeur inférieure au seuil, le pixel concerné ne sera pas classé. Cette propriété peut être aussi utilisée pour définir les classes mixtes dans le cas où plusieurs neurones, qui correspondent à des classes différentes, donnent des valeurs supérieures au seuil.

Heermann et Khazenie (1992) ont testé deux méthodologies pour la configuration du réseau au niveau de sortie. La première méthodologie donne une réponse sous forme binaire. Le format binaire au niveau de sortie a pour but de forcer le réseau à classer tous les pixels et éviter les pixel nuls (ou non classés). La deuxième méthode consiste à affecter au niveau de sortie, un nombre de neurones égal au nombre des classes. La comparaison entre ces deux méthodes a montré que la deuxième est largement supérieure à la première pour toutes les architectures testées.

#### 4.5. Transfert des données entre les neurones

Les nœuds sont considérés comme éléments processeurs d'un réseau de neurones, chaque nœud permet la transformation de l'information contenue dans les entrées ( $E_j$ ) par une fonction non linéaire dite d'activation (figure 3-2). La valeur de la sortie d'un neurone quelconque ( $j$ ) est calculée à partir des entrées qu'il reçoit, ces entrées étant les sorties de la couche précédente.

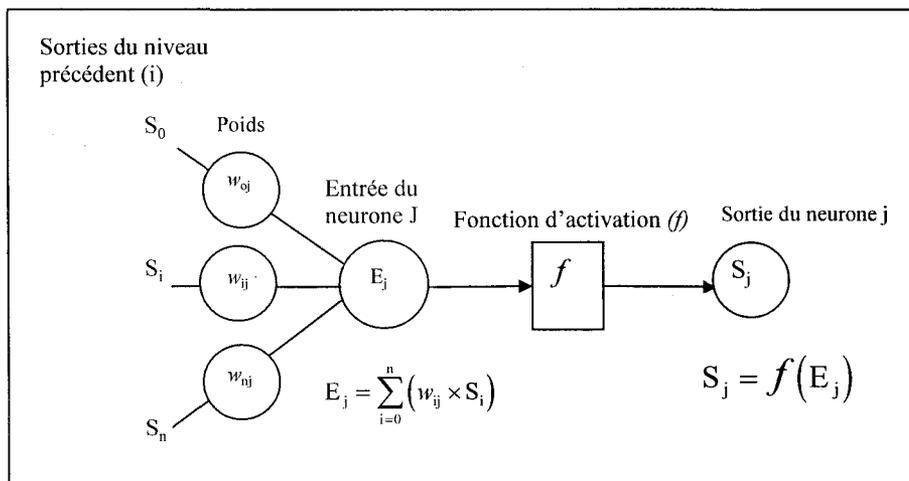


Figure 4-7. Connexions d'un élément processeur (nœud  $j$ ).

La réponse d'un neurone dépend des entrées qu'il reçoit, les entrées d'un neurone correspondent aux sorties des neurones des couches précédentes pondérées par un facteur de poids ( $w$ ) qui caractérise le lien entre deux neurones. La configuration et le fonctionnement de base pour chaque neurone intermédiaire sont présentés sur la figure 4-2. La méthode utilisée pour le transfert de l'information entre deux neurones  $i$  et  $j$  appartenants à deux couches successives est basée sur les trois équations (4-1), (4-2) et (4-3).

$$S_j = f(E_j) \quad (4-1)$$

$$E_j = \sum_{i=0}^n (w_{ij} \times S_i) \quad (4-2)$$

$$f(x) = \tanh(x) \approx \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (4-3)$$

(d'autres fonctions seront aussi testées dans ce projet)

où :

- $S_i$  : La valeur à la sortie du neurone  $i$
- $S_j$  : La valeur à la sortie du neurone  $j$
- $f$  : La fonction d'activation
- $w_{ij}$  : Le coefficient de pondération (poids) entre les neurones  $i$  et  $j$
- $E_j$  : La valeur à l'entrée du neurone  $j$

Dans la plupart des applications, les fonctions d'activation utilisées sont soit la sigmoïde soit la tangente hyperbolique (Kanellopoulos and Wilkinston, 1997). Toutefois, pour accélérer la phase d'entraînement, Kimes *et al.* (1998) ont suggéré d'utiliser une fonction d'activation linéaire au niveau de sortie du réseau.

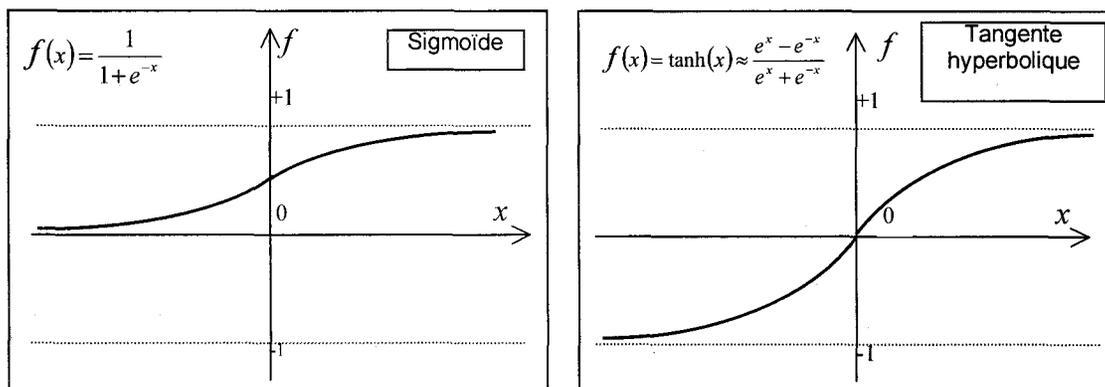


Figure 4-8. Fonctions d'activation.

Ces fonctions sont non linéaires et ont une forme asymptotique (figure 4-3). Elles travaillent comme des amplificateurs non linéaires du signal (Kanellopoulos and Wilkinston, 1997). Les fonctions d'activation permettent de compresser la sortie de neurone dans un intervalle  $[0,1]$  pour la fonction sigmoïde et dans un intervalle  $[-1,1]$  pour la tangente hyperbolique afin d'éviter que des valeurs très grandes se propagent dans le réseau. L'utilisation d'une fonction d'activation non linéaire est nécessaire si on veut obtenir un modèle statistique non linéaire.

#### 4.6. Apprentissage du réseau

Les réseaux de neurones sont des outils de modélisation numérique qui tentent de prédire les sorties d'un système à partir de la connaissance des entrées. Cette prédiction est réalisée en construisant au cours d'une phase d'apprentissage (ou d'entraînement) un modèle non linéaire entre des couples entrées-sorties. Les poids ( $w$ ) précisent le lien entre deux neurones appartenant à deux niveaux successifs (figure 4-4). Leurs valeurs sont ajustées et affinées continuellement tout au long de la phase d'apprentissage. Pendant cette phase, un certain nombre de couples entrées-sorties sont fournis au réseau. Ces données représentent le groupe d'apprentissage et elles sont constituées des informations disponibles pour chaque pixel et sa classe correspondante. Par exemple, la figure 4-4 représente l'étape d'apprentissage d'un réseau de neurones avec trois images radar. Dans ce cas, le couple d'apprentissage est composé pour chaque pixel, des trois valeurs de rétrodiffusion pour l'entrée du réseau et de la classe correspondante à la sortie du réseau. Ces informations seront donc fournies au réseau pour tous les couples entrées-sorties du groupe d'apprentissage.

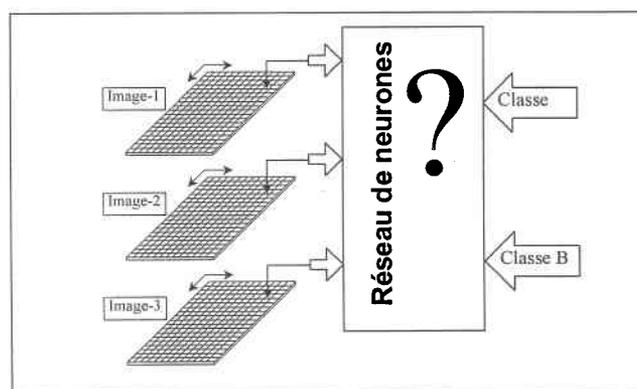


Figure 4-4. Apprentissage du réseau

Dans un premier temps, les poids sont fixés aléatoirement (valeurs proches de zéro) pour permettre au réseau de calculer ses propres sorties à partir des entrées déjà fournies (Tarassenko, 1998). Les poids sont alors corrigés de manière à minimiser la différence entre les sorties ainsi calculées et les sorties réelles. Cette phase de minimisation correspond à l'apprentissage; elle est primordiale à l'efficacité du réseau. L'ensemble des données utilisées pour cette étape doit donc être représentatif des situations qui seront rencontrées ultérieurement, lors de l'utilisation réelle. En effet, le réseau ne peut fournir de réponses correctes si les valeurs présentées du pixel lui paraissent inconnues (Tarassenko, 1998).

Lorsque la phase d'apprentissage est terminée, il est recommandé de procéder à une phase de vérification, qui consiste à tester le réseau sur un ensemble des pixels qui n'ont pas servi à l'apprentissage, ce qui permet de vérifier le pouvoir de généralisation du réseau. Si l'étape de vérification est satisfaisante, c'est-à-dire si le réseau arrive à prédire correctement les classes à partir des entrées pour des couples entrées-sortie n'ayant pas servi à l'apprentissage, le réseau est opérationnel (Bishop, 1995; Tarassenko, 1998). Dans le cas contraire, il faut recommencer l'apprentissage avec de nouveaux paramètres (architecture, fonctions d'activations, algorithmes d'entraînement, etc.).

Une fois entraîné, un réseau de neurones est capable d'offrir une classification efficace et surtout plus rapide que les méthodes conventionnelles de classification (Heermann and Khazenie, 1992). Le temps nécessaire pour une classification est proportionnel à la taille de l'image car chaque pixel est classifié indépendamment de ces voisins. Par conséquent, la nouvelle génération des ordinateurs à processeurs multiples peut diminuer considérablement le temps de calcul tout en subdivisant l'image en plusieurs sous-images.

#### **4.7. La théorie de la méthode de rétropropagation**

L'algorithme de rétropropagation est le plus utilisé en télédétection. Toutefois, les RNs à rétropropagation sont lents à entraîner surtout si le problème présente plusieurs classes (Kanellopoulos and Wilkinston, 1997).

La rétropropagation de gradient d'erreur est un algorithme d'apprentissage adapté aux réseaux de neurones multicouches. Cet algorithme associé aux réseaux multicouches permet de réaliser une fonction non linéaire d'entrée/sortie sur un réseau en décomposant cette fonction en une suite d'étapes linéairement séparables. De nos jours, un réseau multicouche munie d'un

algorithme de rétropropagation du gradient reste le modèle le plus étudié et le plus productif au niveau des applications. La méthode d'apprentissage par rétropropagation a été développée vers le milieu des années quatre-vingts par plusieurs chercheurs dont Rumelhart *et al.* (1986).

#### 4.7.1. Minimisation de l'erreur par rétropropagation

Cette phase de minimisation correspond à l'apprentissage (ou l'entraînement); elle est fondamentale pour l'efficacité du réseau. Elle est réalisée à partir d'un algorithme de rétropropagation à alimentation directe développé et publié par Rumelhart *et al.* (1986)

L'algorithme de rétropropagation a été retenu et adapté pour une classification pixel par pixel d'une série temporelle d'images radar. Cet algorithme permet d'estimer la correction à faire pour un poids ( $w_{ij}$ ) défini entre les deux neurones  $i$  et  $j$ . Cette correction permet de minimiser l'erreur au carré  $E_p$  (équation 4-4) entre la sortie calculée par le réseau ( $S_{c,j}$ ) et la sortie désirée ( $S_{d,j}$ ) du neurone  $j$ . L'erreur  $E_p$  est calculée pour chaque pixel ( $p$ ) appartenant au groupe d'apprentissage.

$$E_p = \frac{1}{2} \sum_j (S_{d,j} - S_{c,j})^2 \quad (4-4)$$

Avec :

- $E_p$  : L'erreur au carré pour un pixel ( $p$ )
- $S_{d,j}$  : La valeur désirée de la sortie du neurone  $J$
- $S_{c,j}$  : La valeur de la sortie du neurone  $J$  (calculée par réseau)

Pour minimiser l'erreur au cours de la phase d'apprentissage, la correction du poids doit être proportionnelle à la dérivée de l'erreur par rapport au poids avec un signe négatif pour avoir une erreur décroissante (4-5).

$$\Delta w_{ij} \approx - \frac{\partial E_p}{\partial w_{ij}} \quad (4-5)$$

D'après les équations (4-1), (4-2) et (4-4), on voit bien que l'erreur au carré ne dépende pas directement des poids ( $w_{ij}$ ). En effet, pour dériver l'équation (4-5), il vaut mieux passer par la règle d'enchaînement (4-6).

$$\frac{\partial E_p}{\partial w_{ij}} = \frac{\partial E_p}{\partial E_j} \cdot \frac{\partial E_j}{\partial w_{ij}} \quad (4-6)$$

D'après l'équation (4-2), la dérivée de la deuxième partie de (4-6) est donnée par:

$$\frac{\partial E_j}{\partial w_{ij}} = \frac{\partial}{\partial w_{ij}} \sum_k (w_{kj} \cdot S_k) = S_i \quad (4-7)$$

Pour calculer la première partie de (4-6), on doit passer par une autre règle d'enchaînement car il n'y a pas une liaison directe entre  $E_p$  et  $E_j$  (4-8) :

$$\frac{\partial E_p}{\partial E_j} = \frac{\partial E_p}{\partial S_j} \cdot \frac{\partial S_j}{\partial E_j} \quad (4-8)$$

D'après l'équation (4-1), la dérivée de la deuxième partie de (4-8) est donnée par:

$$\frac{\partial S_j}{\partial E_j} = \frac{\partial}{\partial E_j} [f(E_j)] = \frac{\partial E_j}{\partial E_j} \cdot f'(E_j) = f'(E_j) \quad (4-9)$$

Où  $f'(E_j)$  est la dérivée de la fonction d'activation  $f$  par rapport à l'entrée  $E_j$  du neurone  $j$  (équation 4-2).

Le calcul de la première partie de (4-6),  $(\frac{\partial E_p}{\partial S_j})$ , dépend de la disposition du niveau contenant le neurone ( $j$ ) car l'erreur au carré ( $E_p$ ) dépend de la sortie de la couche finale du réseau  $S_{c,j}$ . Donc, on ne peut pas calculer directement  $(\frac{\partial E_p}{\partial S_j})$  pour n'importe quel neurone sans tenir compte de l'emplacement de la couche considérée.

#### 4.7.2. Signal d'erreur

Supposons d'abord :

$$\delta_j = -\frac{\partial E_p}{\partial E_j} \quad (4-10)$$

$\delta_j$  est définie comme étant un signal d'erreur ou un indicateur d'erreur pour le neurone  $j$  d'un pixel ( $p$ ), sa valeur dépend de l'emplacement de ( $j$ ) dans le réseau. En effet, deux cas se présentent pour l'évaluation de  $\delta_j$  :

- Si ( $j$ ) appartient au niveau de sortie du réseau, la sortie  $S_j$  va être la réponse finale calculée par le réseau, dans ce cas, on peut écrire:  $S_j = S_{c,j}$  et  $(\frac{\partial E_p}{\partial S_j})$  peut être calculée à partir de (4-4):

$$\frac{\partial E_p}{\partial S_j} = \frac{\partial E_p}{\partial S_{c,j}} = \frac{\partial}{\partial S_{c,j}} \left( \frac{1}{2} \sum_j (S_{d,j} - S_{c,j})^2 \right) = -(S_{d,j} - S_{c,j}) \quad (4-11)$$

Donc, l'équation (4-8) devient:

$$\frac{\partial E_p}{\partial E_j} = \frac{\partial E_p}{\partial S_j} \cdot \frac{\partial S_j}{\partial E_j} = -(S_{d,j} - S_{c,j}) \cdot f'(E_j) = -\delta_j \quad (4-12)$$

$$\Rightarrow \delta_j = (S_{d,j} - S_{c,j}) \cdot f'(E_j)$$

- Si ( $j$ ) appartient à un niveau caché du réseau, la sortie ( $S_j$ ) va être utilisée comme entrée de neurones de la couche suivante ( $k$ ). En effet, on ne peut pas utiliser l'équation (4-4) pour calculer  $(\frac{\partial E_p}{\partial S_j})$  car  $E_p$  ne dépend pas directement de  $S_j$ , on doit donc introduire les entrées de

la couche suivante ( $E_k$ ) par une autre règle d'enchaînement (4-13).

$$\frac{\partial E_p}{\partial S_j} = \sum_k \frac{\partial E_p}{\partial E_k} \cdot \frac{\partial E_k}{\partial S_j} = \sum_k \frac{\partial E_p}{\partial E_k} \cdot \frac{\partial}{\partial S_j} \sum_i w_{ik} \cdot S_i = \sum_k \frac{\partial E_p}{\partial E_k} \cdot w_{jk} \quad (4-13)$$

D'après (4-10), on peut écrire:  $\frac{\partial E_p}{\partial E_k} = -\delta_k$ ; donc, l'équation (4-13) devient :

$$\frac{\partial E_p}{\partial S_j} = -\sum_k \delta_k \cdot w_{jk} \quad (4-14)$$

Donc, l'équation (4-8) devient:

$$\begin{aligned}\frac{\partial E_p}{\partial E_j} &= \frac{\partial E_p}{\partial S_j} \cdot \frac{\partial S_j}{\partial E_j} = -\delta_j = -f'(E_j) \cdot \sum_k \delta_k \cdot w_{jk} \\ \Rightarrow \delta_j &= f'(E_j) \cdot \sum_k \delta_k \cdot w_{jk}\end{aligned}\quad (4-15)$$

### 4.7.3. La règle généralisée du delta

Pour résumer les étapes précédentes, les équations (4-5), (4-6), (4-7) et (4-10) donnent:

$$\Delta w_{ij} = -\delta_j \cdot S_i = \eta \cdot \delta_j \cdot S_i \quad (4-16)$$

Où:

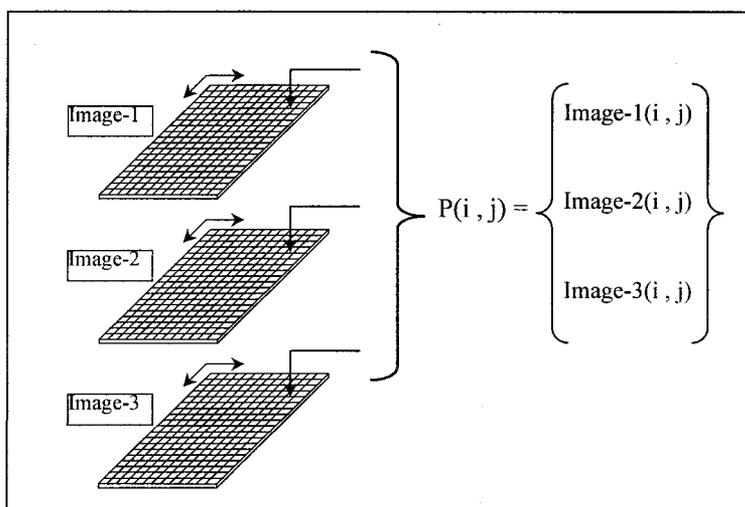
$$\delta_j = (S_{d,j} - S_{c,j}) \cdot f'(E_j) \quad \text{si } (j) \text{ appartient au niveau de sortie du réseau (4-12)}$$

$$\delta_j = f'(E_j) \cdot \sum_k \delta_k \cdot w_{jk} \quad \text{si } (j) \text{ appartient à un niveau caché du réseau (4-15)}$$

( $\eta$  est un coefficient de proportionnalité qui représente le taux d'apprentissage)

L'équation (4-16) représente la règle généralisée du delta (*generalized delta rule*) introduite par Rumelhart *et al.* (1986). Cette règle permet de calculer pour chaque vecteur de pixels la correction ( $\Delta w_{ij}$ ) à apporter au poids ( $w_{ij}$ ) entre deux neurones  $i$  et  $j$ . Cette règle s'applique en deux phases.

Durant la première phase, un vecteur de données sera présenté à l'entrée du réseau pour chaque pixel. Par exemple, pour une série temporelle d'images radar, ce vecteur peut contenir les valeurs des rétrodiffusions correspondantes à ce pixel pour trois dates différentes (figure 4-5). Dans ce cas, on aura un réseau avec trois neurones à son niveau d'entrée. Par la suite, les éléments du vecteur présenté au réseau seront propagés à travers les niveaux afin de calculer les valeurs de sortie pour chaque neurone par les équations (4-1), (4-2) et (4-3); ces valeurs sont calculées niveau par niveau, de gauche à droite (figure 4-5), jusqu'au niveau de sortie. Les dernières valeurs seront ensuite comparées avec celles attendues à la sortie du réseau (valeurs attribuées à la classe concernée) pour calculer le signal d'erreur ( $\delta_j$ ) par l'équation (4-12).



**Figure 4-5.** Préparation des données pour une analyse multi-temporelle.

D'après l'équation (4-15), les indicateurs d'erreur du niveau caché dépendent directement de  $(\delta_j)$  du niveau de sortie. En effet, la deuxième phase consiste à faire une rétropropagation dans un sens opposé à celui la circulation de l'information (de droite à gauche) pour calculer les signaux d'erreur de chaque nœud du niveau caché (en utilisant l'équation (4-15)) à partir du signal déjà calculé dans la phase précédente. Après la deuxième phase, on peut calculer la correction appropriée de chaque poids entre le niveau d'entrée et le niveau de sortie par la règle généralisée du delta (4-16).

Le principe de base de la procédure utilisée pour l'apprentissage (gradient décroissant), nécessite des corrections proportionnelles à  $\frac{\partial E_p}{\partial w_{ij}}$  ; ces corrections doivent être faites par de petites valeurs afin de garder une bonne décroissance de la fonction de minimisation. En effet, la rapidité d'apprentissage est directement proportionnelle à la valeur choisie pour le taux d'apprentissage ( $\eta$ ). Mais, de grandes corrections du poids peuvent engendrer des oscillations autour du résultat recherché et provoquent un ralentissement de l'apprentissage.

#### 4.7.4. Taux d'apprentissage

Pour éviter tous risque de divergence de la procédure d'apprentissage, Rumelhart *et al.* (1986) ont proposé un autre modèle (équation 4-17) inspiré de l'équation (4-16) qui permet de choisir

un taux d'apprentissage le plus élevé que possible et qui donne un apprentissage rapide sans risque d'oscillations.

$$\Delta w_{ij}(n+1) = \left[ \eta \cdot \delta_j \cdot S_i \right] + \left[ \alpha \cdot \Delta w_{ij}(n) \right] \quad (4-17)$$

Où:

- n : L'indicateur du nombre d'itérations de la phase d'apprentissage
- $\alpha$  : Une constante (dite *momentum*) qui reflète l'effet du changement de poids dans l'itération précédente

Les valeurs du taux d'apprentissage ( $\eta$ ) et de la constante ( $\alpha$ ) sont spécifiques pour chaque application. Ils sont généralement optimisés au début de l'expérimentation par des méthodes d'essais-erreurs.

Cependant, pour utiliser les réseaux, il faut préciser un certain nombre de paramètres reliés à l'architecture (nombre de niveaux, nombre de neurones par niveau, fonction de transfert) et à la phase d'apprentissage (algorithme d'apprentissage, fonction erreur, vitesse et momentum, test d'arrêt, ensemble test et ensemble de validation). De nombreuses études ont permis de mieux comprendre l'influence de ces paramètres et d'en améliorer le choix. D'autres techniques ont aussi été proposées pour construire dynamiquement l'architecture d'un réseau, comme l'ajout de nœuds cachés par une technique de Quasi-Newton (Setiono and Hui., 1995) ou l'élimination des nœuds cachés par des techniques d'élagages (Karras, 1995).

#### **4.8. Autres méthodes de classification supervisée**

La classification supervisée est la procédure la plus utilisée dans l'analyse quantitative des images de télédétection (Richards, 1993). Nous présentons dans cette section un aperçu des algorithmes couramment utilisés dans la classification supervisée (ou dirigée) des données de télédétection.

En littérature, plusieurs méthodes de classification des données de télédétection ont été proposées mais seulement quelques approches peuvent être trouvées dans les logiciels

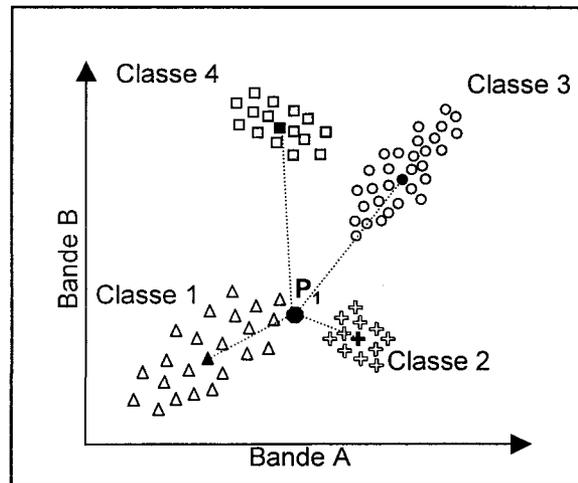
commerciaux de traitement d'images (Smits *et al.*, 1999). On trouve dans le tableau 4-1 un aperçu des avantages et des inconvénients de ces approches de classification.

**Tableau 4-1.** Méthodes de classification les plus utilisées dans les logiciels commerciaux de traitement (Smits *et al.*, 1999).

<b>Classificateur</b>	<b>Avantages</b>	<b>Inconvénients</b>
Distance minimale	Pas de pixels non classifiés, classification rapide.	Aucune considération à la covariance des classes.
Parallélépipèdes	Simple et rapide, aucun préalable sur la distribution statistique des pixels.	Les pixels sont classifiés à partir de la moyenne spectrale.
Mahalanobis	Tient compte de la covariance des classes.	Sur-classification des signatures ayants des valeurs élevées dans la matrice de covariance. Suppose <i>a priori</i> que la distribution des classes est normale
Maximum de vraisemblance / Bayésienne	Relativement précise, tient compte de la variabilité des classes	Beaucoup de calcul, suppose <i>a priori</i> que la distribution est normale, sur-classification des signatures ayants des valeurs élevées dans la matrice de covariance.
Réseau de neurones	Aucune contrainte sur la distribution statistique des pixels, rapide après l'apprentissage.	Apprentissage lent. Aucune base théorique, convergence stochastique

#### **4.8.1. Méthode de la distance minimale**

La méthode de la distance minimale calcule pour chaque classe et pour chaque bande de données la moyenne des valeurs numériques des pixels d'entraînement. Ainsi, chaque nouveau pixel sera affecté à la classe ayant la moyenne la plus proche. La figure 4-6 présente une illustration simplifiée d'un espace spectral à deux dimensions. La classe du pixel  $P_1$  serait tout simplement déduite en comparant les distances (dans l'espace spectral) entre ce pixel et la moyenne de chaque classe. L'inconvénient majeur de cette méthode réside dans le fait qu'elle ne tient pas compte de la variabilité ou de la dispersion des pixels appartenant à la même classe. En effet, dans l'illustration de la figure 4-6, le pixel  $P_1$  sera affecté à la classe 2 bien qu'il apparaisse plus proche à la classe 1.



**Figure 4-6.** Critères de classification par la méthode de la distance minimale.

L'algorithme de discrimination de la méthode de la distance minimale fonctionne comme suit (Richards, 1993) :

Soit  $(m_i)$  la moyenne des pixels d'entraînement de la classe  $(w_i)$  et  $(x)$  la position du pixel à classifier. Le calcul de la distance Euclidienne au carrée entre le pixel en question et la moyenne  $(m_i)$  de la classe  $(w_i)$  se fait par l'équation suivante :

$$d(x, m_i)^2 = (x - m_i)^2 = x^2 - 2m_i \cdot x + m_i^2 \quad (4-18)$$

Ainsi, l'attribution d'une classe  $(w_i)$  au pixel  $(x)$  se fait comme suit :

$$x \in w_i \text{ si } d(x, m_i)^2 < d(x, m_j)^2 \text{ (pour toutes les classes } j \neq i) \quad (4-19)$$

En remplaçant  $d(x, m_i)^2$  par sa valeur dans l'équation (4-18), l'inégalité (4-19) devient :

$$x \in w_i \text{ si } x^2 - 2m_i \cdot x + m_i^2 < x^2 - 2m_j \cdot x + m_j^2 \quad (4-20)$$

Puisque la valeur de  $x^2$  est constante quelque soit la classe concernée, l'inégalité (4-20) peut s'écrire comme suit :

$$x \in w_i \text{ si } 2m_i \cdot x + m_i^2 < 2m_j \cdot x + m_j^2 \quad (4-21)$$

L'inégalité (4-21) est la fonction discriminatoire de la méthode de la distance minimale.

La méthode de classification par la distance minimale est reconnue pour sa rapidité. Toutefois, étant donné qu'elle n'utilise aucune information sur les caractéristiques statistiques des données, son utilisation est conseillée uniquement lorsqu'on ne dispose pas d'un grand nombre de données d'entraînement (Richards, 1993).

L'utilisation d'une méthode paramétrique de classification nécessite, pour chaque classe, un nombre suffisant des données d'entraînement afin d'établir adéquatement des paramètres statistiques des données (comme la matrice de covariance pour la méthode de maximum de vraisemblance). En effet, la disponibilité d'un petit échantillon d'entraînement produit des paramètres statistiques erronés et affecte considérablement la précision d'une classification. Dans ce cas, la méthode de la distance minimale peut offrir des précisions supérieures à celles obtenus par d'autres algorithmes plus puissants comme celui de la méthode du maximum de vraisemblance étant donné que les pixels d'entraînement sont utilisés uniquement pour calculer la moyenne de la classe (Richards, 1993).

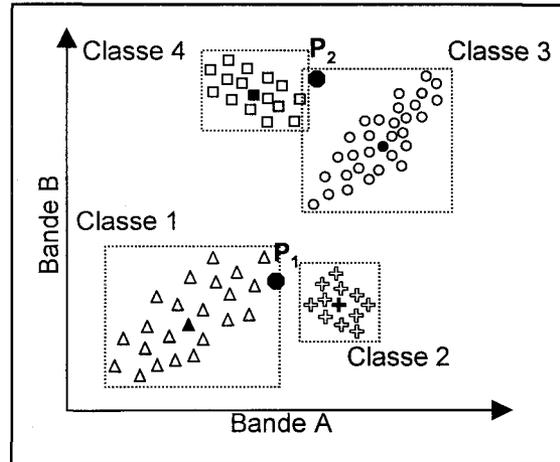
#### **4.8.2. Méthode des parallélépipèdes**

La méthode des parallélépipèdes est considérée comme la plus simple méthode de classification non paramétrique (Schowengerdt, 1997). Avec cette méthode, chacune des signatures de classes est formée par un hyperparallélépipède dans l'espace spectral (Bonn et Rochon, 1992). Le domaine de décision de chaque classe est défini par les limites supérieures et inférieures des niveaux de gris de chaque bande. Ces limites peuvent aussi être fixées en utilisant l'écart type des données pour chaque classe (la moyenne  $\pm$  l'écart type). Pour un espace spectral de deux dimensions, le domaine de décision se ramène à un rectangle pour chacune des classes (Figure 4-7). La classe attribuée à un pixel inconnu sera celle du parallélépipède dans lequel il s'y retrouve. Cependant, un pixel qui se trouve à l'extérieur de tous les parallélépipèdes sera classifié comme pixel nul.

La plus grande faiblesse de la méthode des parallélépipèdes est le risque élevé de chevauchement entre les domaines spectraux (Bonn et Rochon, 1992). Dans ce cas, la précision de la classification sera moins bonne et plusieurs étiquettes seront attribuées à un seul pixel.

Par exemple, dans l'illustration de la figure 4-7, le pixel  $P_2$  sera incorrectement affecté à la classe 4 bien qu'il apparaisse plus proche à la classe 3. Ce pixel sera correctement classifié si

on utilise la méthode de la distance minimale. Toutefois, le pixel  $P_1$  qui a été mal classifié par la méthode de la distance minimale sera correctement affecté à la classe 1. Les deux exemples illustrés dans les figures 4-6 et 4-7 montrent la faiblesse et la manque de flexibilité de ces deux méthodes de classification.



**Figure 4-7.** Critères de classification par la méthode des parallélépipèdes.

#### 4.8.3. Méthode du maximum de vraisemblance.

La méthode de classification par maximum de vraisemblance est la méthode la plus utilisée dans la classification des données de télédétection (Richards, 1993). Cette méthode utilise une approche qui permet d'effectuer une segmentation de l'espace spectral suivant des règles de décision où les risques d'erreur sont minimisés à partir des lois probabilistes (Bonn et Rochon, 1992).

$$G_i(X) = \ln\{P(X|C_i)P(C_i)\} = \ln P(X|C_i) + \ln P(C_i) \quad (4-22)$$

Où  $P(X|C_i)$  et  $P(C_i)$  représentent respectivement la probabilité conditionnelle du vecteur  $X$  compte tenu du fait que la classe  $i$  était retenue *a priori* et la probabilité *a priori* de la classe  $i$ .

La probabilité  $P(X|C_i)$  peut être calculée pour chacune des classes par l'expression suivante (Schowengerdt, 1997) :

$$P(X|C_i) = \frac{\exp\left[-\frac{1}{2}(X - \mu_i)^T \cdot \Sigma_i^{-1}(X - \mu_i)\right]}{(2\pi)^{\frac{K}{2}} \cdot |\Sigma_i|^{\frac{1}{2}}} \quad (4-23)$$

En appliquant le logarithme à l'équation (4-23), l'équation (4-22) devient :

$$G_i(X) = \ln[P(C_i)] - \frac{1}{2} \left\{ K \ln[2\pi] + \ln|\Sigma_i| + (X - \mu_i)^T \Sigma_i^{-1} (X - \mu_i) \right\} \quad (4-24)$$

avec :

$K$  : Est le nombre de bandes utilisées

$X$  :  $X = (x_1, x_2, \dots, x_K)$  est un vecteur de pixels de taille  $K$

$\mu_i$  : Est un vecteur des moyennes pour la classe  $i$

$\Sigma_i$  : Est la matrice de covariance de la classe  $i$  de taille  $K \times K$

$\Sigma_i^{-1}$  : Est la transposée de la matrice de covariance  $C_i$

$|\Sigma_i|$  : Est le déterminant de la matrice de covariance  $C_i$

L'équation (4-24) a été présentée par Richards (1993) comme étant la règle de décision dans une classification par maximum de vraisemblance. Cette équation a été aussi présentée par Schowengerdt (1997) comme étant la fonction discriminante par maximum de vraisemblance pour une classe  $i$ .

L'utilisation de la matrice de covariance ( $\Sigma_i$ ) dans le calcul de la probabilité  $P(X|C_i)$  permet de tenir compte de l'aspect multidimensionnel de l'espace spectral et de l'effet de corrélation entre les différentes bandes. Dans le cas où une seule bande est utilisée pour la classification, la matrice de covariance ( $\Sigma_i$ ) sera tout simplement remplacée par la variance ( $\sigma_i^2$ ) des pixels d'entraînement de la classe  $i$  (Richards, 1993). Les matrices de covariance utilisées dans les équations précédentes ont la forme suivante :

$$\Sigma_i = \begin{bmatrix} c_{11} & \cdots & c_{1K} \\ \vdots & & \vdots \\ c_{K1} & \cdots & c_{KK} \end{bmatrix} \quad (4-25)$$

Chaque élément de cette matrice représente la covariance entre les deux bandes correspondantes. Une covariance entre les bandes  $m$  et  $n$  est calculée par l'équation 4-26.

$$c_{mn} = \frac{1}{N-1} \sum_{p=1}^N (DN_{pm} - \mu_m)(DN_{pn} - \mu_n) \quad (4-26)$$

Où  $DN$  est la valeur numérique du pixel et  $N$  le nombre total de pixels.

La moyenne est calculée pour chaque bande par l'équation (4-27)

$$\mu_k = \frac{1}{N} \sum_{p=1}^N DN_{pk} \quad (4-27)$$

L'équation 4-24 a été utilisée par le logiciel PCI Geomatica Inc dans son module de classification par maximum de vraisemblance. Le processus de classification est effectué pour chaque pixel  $X = (x_1, x_2, \dots, x_N)$  en deux étapes :

#### Étape 1

Pour chaque classe  $i$ , on détermine si le pixel  $X$  se trouve dans le l'hyper-ellipsoïde de la classe concernée en vérifiant l'inégalité suivante :

$$(X - \mu_i)^T \Sigma_i^{-1} (X - \mu_i) \leq \theta_i \quad (4-28)$$

Où  $\theta_i$  représente le seuil de probabilité minimal pour la classe  $i$ . La valeur de  $\theta_i$  est calculée en fonction de la probabilité *a priori* et de la matrice de covariance de la classe  $i$  et en utilisant les tables de la distribution  $\chi^2$  (Richards, 1993).

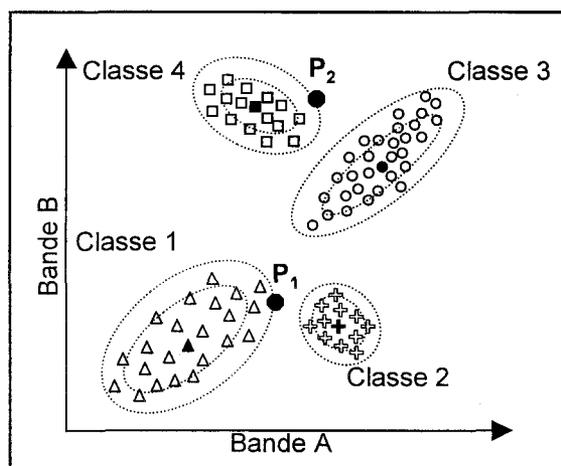
Si cette inégalité ne peut pas être vérifiée pour toutes les classes, le pixel en question sera classifié comme pixel nul. Sinon, on passe à l'étape suivante.

### Étape 2

Si le pixel franchi l'étape 1, on calcule la fonction discriminante  $G(X)$  (4-24) pour toutes les classes qui ont pu satisfaire l'inégalité (4-28) et le pixel en question sera affecté à la classe qui a donné la valeur la plus élevée de  $G(X)$ . Ainsi :

$$X \in C_i \text{ si } G_i(X) > G_j(X) \text{ pour toute classe } j \neq i \quad (4-29)$$

L'illustration de la figure 4-8 montre une segmentation d'un espace spectral à deux dimensions par maximum de vraisemblance. Comparativement aux segmentations illustrées dans les figures 4-6 et 4-7, la segmentation par maximum de vraisemblance donne plus de sensibilité dans la délimitation des classes et les pixels P1 et P2 sont correctement affectés à leurs classes respectives.



**Figure 4-8.** Critères de classification par la méthode de maximum de vraisemblance.

### **4.9. Comparaison entre les méthodes de classification**

Plusieurs comparaisons ont été effectuées entre la classification par réseau de neurones et d'autres méthodes plus conventionnelles de classification. Les résultats de ces comparaisons divergent d'une étude à une autre. Dans la plupart de ces travaux, la comparaison a été effectuée entre les réseaux de neurones et la méthode du maximum de vraisemblance.

En général, les auteurs ont montré que les réseaux de neurones offrent une précision semblable ou supérieure à la méthode de maximum de vraisemblance (Benediktsson *et al.*, 1990; Heermann and Khazenie, 1992; Bischof *et al.*, 1992; Paola et Schowengerdt, 1994; Yoshida and Omatu, 1994; Augusteijn, *et al.* 1995 et Foody and Arora, 1997).

Une étude comparative intéressante entre ces deux méthodes a été effectuée par Benediktsson *et al.* (1990). Dans cette étude, les auteurs ont trouvé que le réseau de neurones donne une classification plus précise quand la distribution des classes est non Gaussienne. En outre, les réseaux de neurones sont plus exigeants quand il s'agit de la représentativité des données d'entraînement. Ainsi, l'algorithme du maximum de vraisemblance offre un meilleur résultat quand on ne dispose pas d'un échantillon assez représentatif des classes en question (Benediktsson *et al.*, 1990).

Pour surmonter l'infériorité de la méthode du maximum de vraisemblance face à des données non Gaussiennes, Benediktsson *et al.* (1990) ont suggéré d'apporter, si c'est possible, des modifications à l'algorithme de classification afin de l'adapter à la distribution réelle des données. Cette opération n'est pas toujours garantie. Elle exige, entre autres, une connaissance approfondie de la scène à classer et des données disponibles.

Une étude menée par Hepner *et al.*, (1990) a montré que les réseaux de neurones nécessitent moins de données d'entraînement que la méthode du maximum de vraisemblance. Un nombre suffisant de données est nécessaire pour cette méthode paramétrique pour bien présenter les paramètres statistiques de chaque classe. Paola et Schowengerdt (1995) ont attribué cette supériorité au fait que les réseaux de neurones utilisent tous les pixels d'entraînement pour définir les paramètres discriminatoires de chaque classe; tandis que, l'algorithme du maximum de vraisemblance tient compte uniquement des pixels d'une seule classe pour définir les paramètres liés à cette classe en question. Cette caractéristique est très importante car elle permet de réduire les coûts liés à la collecte des données sur le terrain.

Les réseaux de neurones ont montré leur efficacité dans plusieurs applications. Dans notre cas, étant donnée que nous travaillons avec des classes naturelles dont la normalité de la distribution n'est pas toujours garantie (voir histogrammes des figures 6-12 et 6-13), les réseaux de neurones peuvent jouer un rôle important dans la discrimination de ces classes.

#### **4.10. Évaluation de précision d'une classification**

Quand les classes sont bien séparées dans l'espace spectral avec aucune superposition entre leurs distributions, la majorité des classificateurs sont capable de fournir les même résultats dont la précision dépend essentiellement du choix des échantillons d'entraînement (Smits, *et al.*, 1999). Toutefois, quand une confusion existe entre les différentes classes, ce qui est souvent le cas avec des données réelles de télédétection, les résultats fournis par les classificateurs ne se concordent pas. La différence entre ces différents résultats dépend essentiellement des informations incorporées a priori dans le modèle du classificateur (Smits, *et al.*, 1999). En plus, pour le même classificateur, les résultats peuvent être différents si on entraîne le modèle avec des différents groupes de données.

L'évaluation de la précision d'une carte thématique doit être considérée comme une étape intégrale d'un processus de classification des données de télédétection et non pas comme une tâche supplémentaire à faire après la production du produit final (Congalton, 1991). En effet, l'utilisateur d'une carte thématique dérivée à partir des données de télédétection a besoin de savoir le degré d'exactitude de ce produit pour une utilisation rationnelle et efficace (Smits, *et al.*, 1999). L'évaluation de cette exactitude doit être faite à partir des données sûres et indépendantes du processus de classification. Toutefois, dans la majorité des cas, les données utilisées dans l'évaluation de la précision d'une classification sont les mêmes que celles utilisées dans l'entraînement du classificateur. L'utilisation du même groupe de données dans la classification et l'évaluation provoque une surestimation de la précision (Congalton, 1991).

En plus, un problème d'incohérence d'étiquetage des classes peut mettre en cause la représentativité des données d'entraînement. Plusieurs causes peuvent être à l'origine de cette incohérence dont le chevauchement entre les classes (classes mixtes), zones de transition, variabilité à l'intérieur d'une même classe (covariance), quantité limitée des données d'entraînement... etc. (Smits, *et al.*, 1999). L'erreur engendrée par ces types de problèmes est difficile à quantifier.

Une carte thématique qui résulte d'une classification est considérée comme précise si elle réussisse de fournir une représentation non biaisée de la couverture réelle du sol (Foody, 2002). L'erreur provoquée par la classification elle-même peut être réduite en définissant adéquatement : les classes, le nombre des classes, le système de classification, et les informations à fournir au classificateur (Smits *et al.*, 1999).

#### 4.10.1. Matrice de confusion

La matrice de confusion (ou matrice des erreurs) est la méthode la plus utilisée pour évaluer l'exactitude d'une classification des données de télédétection. Cette méthode a l'avantage de fournir à la fois une estimation de l'exactitude de la classification et une caractérisation des sources de l'erreur. Les résultats affichés dans une matrice de confusion peuvent révéler la confusion qui pourrait exister entre différentes classes qui peut être résolue en ajoutant des informations additionnelles sur les classes concernées (Foody, 2002). En télédétection, le degré d'exactitude d'une classification est traditionnellement évalué par la précision totale (*overall accuracy*) calculée à partir de la somme des éléments du diagonal de la matrice de confusion (Fitzgerald and Lees, 1994).

Généralement, les colonnes de la matrice affichent les données de référence préalablement identifiées (sur le terrain ou à partir d'un autre support thématique) et les lignes affichent la classification générée à partir des données de télédétection. Avec cette disposition, les valeurs de la diagonale indiqueront le nombre de pixels correctement classifiés. En d'autres termes, une matrice de confusion représente une comparaison, pour un groupe de pixel (groupe test), entre les étiquettes attribuées par le classificateur et leurs étiquettes réelles. Les valeurs affichées dans cette matrice peuvent être analysées d'une façon descriptive ou analytique.

Le nombre de lignes de cette matrice est égal au nombre de classes (une ligne par classe). Tandis que le nombre de colonnes dépend de l'approche adoptée pour la classification :

- Si on force le réseau à classifier tous les pixels (classification forcée), le nombre de colonnes sera égal au nombre de classes. On obtient dans ce cas une matrice de confusion carrée.
- Si on adopte une classification non forcée, le nombre de colonnes sera égal au nombre de classes plus un. La dernière colonne sera consacrée aux pixels non classifiés (ou pixels nuls).

Pour ces deux approches, la somme des éléments de chaque ligne doit être égale au nombre total de pixels de la classe concernée (ou à 100 % si les éléments de la matrice sont présentés en pourcentage). Toutefois, si on ajoute une classe nulle au processus de classification (c'est à dire, on utilise des pixels prédéfinis comme pixels nuls), ces pixels seront considérés comme

une classe à part entière et on peut choisir l'une des deux approches présentées précédemment.

#### 4.10.2. Analyse descriptive d'une matrice de confusion

La méthode d'analyse descriptive d'une matrice de confusion est relativement simple (Smits, *et al.*, 1999). Elle consiste à calculer, pour chaque classe, le rapport entre le nombre de pixels correctement classés et le nombre total de pixels. La précision totale de la classification (*overall accuracy*) est ainsi obtenue en moyennant les précisions calculées pour chaque classe en tenant compte du nombre de pixels de chaque échantillon.

La précision de classification d'une classe donnée peut être exprimée de deux façons différentes : La précision de producteur calculée à partir des données de référence et la précision d'utilisateur calculée à partir du nombre total des pixels correctement classifiés (Smits, *et al.*, 1999). Les erreurs générées par ces deux modes d'interprétations sont appelées : erreurs d'inclusion (ou de commission) pour la précision d'utilisateur et les erreurs d'exclusion (ou d'omission) pour la précision de producteur (Congalton, 1991).

**TABLEAU 4-2.** Calcul des précisions à partir d'une matrice de confusion (Congalton, 1991)

	C1	C2	C3	C4	Total de lignes	
<b>C1</b>	<b>65</b>	4	22	24	115	<b>Précision de producteur :</b> C1 : 65/75 = 87 %   C2 : 81/103 = 79 % C3 : 85/115 = 74 %   C4 : 90/141 = 64 %
<b>C2</b>	6	<b>81</b>	5	8	100	
<b>C3</b>	0	11	<b>85</b>	19	115	<b>Précision de l'utilisateur :</b> C1 : 65/115 = 57 %   C2 : 81/100 = 81 % C3 : 85/115 = 74 %   C4 : 90/104 = 87 %
<b>C4</b>	4	7	3	<b>90</b>	104	
Total de colonnes	75	103	115	141	434	Précision totale = (65 + 81 + 85 + 90)/434 = <b>74 %</b>

La précision de producteur indique la probabilité qu'un pixel de référence soit correctement classifié. Par contre, la précision d'utilisateur mesure la probabilité qu'une étiquette donnée au pixel par le classificateur représente bien son étiquette réelle au sol (Congalton, 1991).

Congalton (1991) a présenté un exemple (tableau 4-2) qui illustre bien l'importance de considérer les trois types de précisions qui peuvent être dérivées de la matrice de confusion (précision de producteur, précision d'utilisateur et précision totale). Par exemple, si la classe C1 est une classe forêt, la lecture de la matrice de confusion illustrée au tableau 4-2 montre que

87 % des forêts ont été correctement identifiées comme forêts, mais uniquement 57 % des pixels classifiés comme forêts le sont réellement. Ainsi, le producteur de cette classification va mettre l'accent sur le fait que les zones forestières ont 87 % de chance de s'identifier comme telle, tandis que, un utilisateur de ce produit va trouver, qu'uniquement dans 57 % des cas, une zone identifiée sur la carte thématique comme forêt le sera réellement sur le terrain.

#### **4.10.3. Analyse analytique d'une matrice de confusion**

Les techniques d'analyse analytique sont très utiles quand il s'agit d'avoir un jugement objectif de la précision d'une classification ou de comparer les performances des différentes méthodes de classification (Congalton, 1991, Smits, *et al.*, 1999). En plus des analyses descriptives présentées dans les paragraphes précédentes, une matrice de confusion est un outil approprié pour toute analyse analytique dont les méthodes discrètes multivariées (Congalton., 1991).

Les méthodes discrètes multivariées sont très utiles pour l'analyse des données de télédétection puisque ces données sont dans la plupart des cas discrètes et rarement continues. En plus, la distribution statistique de ces données est plus souvent bi-modales ou multi-modales que normale ce qui met en cause l'utilisation des méthodes conventionnelles d'analyse. Nous présentons dans les paragraphes suivants un aperçu de deux méthodes analytiques d'analyse : La méthode de normalisation et les statistiques de KHAT (estimateur Kappa).

##### **A. Méthode de normalisation**

Cette méthode, présentée par Bishop *et al.*, (1975), permet de «normaliser» ou standardiser plusieurs matrices de confusion pour pouvoir les comparer plus tard. Pour ce faire, toutes les valeurs de la matrice seront normalisées entre 0 et 1 par une procédure itérative d'ajustement proportionnelle (*iterative proportional fitting procedure*). Cette méthode force chaque ligne et chaque colonne de la matrice d'avoir une somme égale à 1. Ainsi, l'effet des différences de tailles d'échantillons utilisés pour le calcul de la matrice sera éliminé et toutes les cellules de la matrice deviennent comparables avec celles obtenues par d'autres tests de classification.

Le processus itératif utilisé par cette méthode permet de balancer les valeurs des lignes et de colonnes pour avoir une somme égale à 1. Ainsi, chaque cellule de la matrice contiendra, indirectement, des informations sur les cellules de la ligne et de la colonne correspondantes.

Dans ce cas, les précisions obtenues à partir d'une matrice de confusion normalisée sont, en effet, une combinaison des précisions d'utilisateur et de producteur.

Congalton (1991) considère que la précision calculée à partir d'une matrice normalisée donne une représentation plus réelle de la performance du classificateur que celle obtenue par les valeurs originales de la matrice de confusion puisqu'elle contient des informations sur les valeurs au-dessus et au-dessous du diagonal.

## B. Statistiques de KHAT

Les statistiques de KHAT sont largement utilisés en télédétection pour évaluer la performance d'une classification (Ulaby *et al.*, 1986a; Chen *et al.*, 1997 et Foody and Arora, 1997). Fitzgerald et Lees, (1994) ont recommandé l'utilisation de la statistique KHAT (coefficient Kappa) à la place de la précision totale pour estimer la précision d'une classification.

Contrairement à la précision totale calculée en moyennant les valeurs diagonales de la matrice de confusion, le coefficient Kappa donne une estimation de la qualité de la classification en tenant compte de toutes les valeurs de la matrice de confusion (équation 4-27). L'estimation du coefficient Kappa permet d'évaluer si la matrice de confusion ne représente pas un résultat aléatoire (Smits, *et al.*, 1999). Il permet aussi de comparer entre deux ou plusieurs matrices de confusions obtenues avec différents classificateurs et d'évaluer d'une manière significative si une classification est meilleure qu'une autre (Smits, *et al.*, 1999). En d'autres termes, le coefficient Kappa exprime la réduction proportionnelle de l'erreur obtenue par une classification, comparée à l'erreur par une classification complètement au hasard. La valeur du coefficient Kappa varie entre 0 et 1. Ainsi, un coefficient Kappa de 0.75 signifie que 75 % de la classification n'est pas due au hasard (Girard et Girard, 1999).

Les statistiques Kappa ont été développées par Cohen (1960) et présentés sous leur format actuel (équation 4-30) par Bishop *et al.*, (1975). Le coefficient Kappa est calculé à partir de la matrice de confusion (exprimée en nombre de pixel) par l'équation suivante:

$$K = \frac{\left| N \times \sum_{i=1}^l x_{ii} - \sum_{i=1}^l (x_{i+} \times x_{+i}) \right|}{N^2 - \sum_{i=1}^l (x_{i+} \times x_{+i})} \quad (4-30)$$

avec :

- $K$  : Coefficient Kappa
- $N$  : Nombre total des pixels (du groupe test).
- $l$  : Nombre de lignes de la matrice de confusion.
- $x_{ii}$  : Valeurs de la diagonale.
- $x_{i+}$  : La somme marginale de la ligne  $i$
- $x_{+i}$  : La somme marginale de la colonne  $i$

L'équation 4-30 montre bien que l'estimateur Kappa introduit indirectement des informations sur les précisions qui se trouvent à l'extérieur du diagonal. Ainsi, comme il a été le cas pour la méthode de normalisation de la matrice de confusion, la précision estimée par le coefficient Kappa représente une combinaison des précisions d'utilisateur et de producteur.

La statistique de KHAT utilise un modèle d'échantillonnage multi-nominal et la variance du coefficient Kappa. Cette variance est calculée en utilisant la méthode Delta (Congalton, 1991). Plusieurs méthodes de calcul de la variance de Kappa ont été présentées dans beaucoup de publications mais la plupart d'entre elles sont incorrectes (Hudson and Ramm, 1987). Nous avons retenu dans ce projet la formule (4-31) présentée par Bishop et al., (1975) et confirmée par (Hudson and Ramm, 1987).

$$\hat{\sigma}^2[K] = \frac{1}{N} \left[ \frac{\theta_1(1-\theta_1)}{(1-\theta_2)^2} + \frac{2(1-\theta_1)(2\theta_1\theta_2 - \theta_3)}{(1-\theta_2)^3} + \frac{(1-\theta_1)^2(\theta_4 - 4\theta_2^2)}{(1-\theta_2)^4} \right] \quad (4-31)$$

où :

$$\theta_1 = \sum_{i=1} \frac{x_{ii}}{N},$$

$$\theta_2 = \sum_{i=1} \frac{(x_{i+}) \cdot (x_{+i})}{N^2},$$

$$\theta_3 = \sum_{i=1} \frac{x_{ii}(x_{i+} + x_{+i})}{N^2} \text{ et}$$

$$\theta_4 = \sum_{i=1, j=1} x_{ij} \frac{(x_{j+} + x_{+i})^2}{N^3}$$

Pour comparer deux résultats de classification, Smits *et al.*, 1999 ont suggéré l'utilisation d'un test Z (*Z-Statistic*) pour évaluer s'il existe une différence significative entre les précisions obtenues par ces deux classifications. La formule utilisée pour calculer la valeur de Z a été présentée par Cohen (1960) comme suit :

$$Z \approx \frac{K_1 - K_2}{\sqrt{\hat{\sigma}_1^2 + \hat{\sigma}_2^2}} \quad (4-32)$$

Pour vérifier si deux coefficients Kappa ont une différence significative, la statistique Z est comparée à la valeur Z = 1,96. Cette valeur représente un niveau de confiance de 95 % pour une distribution normale (Congalton, 1991). Dans ce cas, si la statistique Z calculée pour deux coefficients Kappa dépasse le seuil de 1,96, on peut dire que les deux résultats de classification sont significativement différents.

# CHAPITRE 5

## Mise au point du réseau de neurones

---

### *5.1. Introduction*

Ce chapitre constitue la principale partie de la thèse. Il présente la méthodologie suivie pour le développement, l'adaptation et l'étalonnage du réseau de neurones pour la classification de plusieurs classes végétales de milieux humides. Ce chapitre aborde essentiellement les étapes suivies pour l'ajustement des paramètres internes du réseau tel que l'architecture, la fonction d'activation, le format des données, l'algorithme d'apprentissage, le taux d'apprentissage et les critères d'arrêt d'apprentissage.

Les réseaux de neurones utilisés dans ce projet ont été programmés sur Matlab (version 6). Ce logiciel de calcul dispose déjà de plusieurs modules qui facilitent plusieurs tâches liées à la création, l'entraînement, et la simulation des réseaux de neurones. Plusieurs modifications ont été apportées au programme source de ces modules afin de les adapter aux caractéristiques spécifiques de ce projet. Ces modifications ont touché essentiellement les critères d'arrêt de la phase d'apprentissage et l'adaptation du réseau au format des données spatiales.

### *5.2. Préparation des paramètres externes du réseau*

Les données utilisées en entraînement doivent contenir une description représentative de chaque classe. Toutefois, il n'existe pas une règle générale pour définir le nombre de pixels d'entraînement. Plusieurs auteurs ont étudié l'effet de la taille du groupe d'apprentissage sur la performance de la classification. Parmi eux, Foody et Arora, (1997) ont testé quatre tailles différentes du groupe d'apprentissage soit 10, 30, 50 et 100 pixels par classe. Ils ont trouvé que

la précision augmente considérablement en variant ce nombre de 10 à 30 pixels. Par contre, l'augmentation de la taille du groupe d'apprentissage de 50 à 100 pixels n'a pas apporté une grande amélioration à la précision de la classification. Les auteurs ont conclu que l'augmentation de la taille du groupe d'apprentissage au-delà de 100 pixels par classe augmente le temps nécessaire pour l'entraînement sans aucun apport significatif à la précision de la classification. Cette observation a été aussi rapportée par Zhuang *et al.* (1994).

D'autres auteurs ont lié le nombre de pixels d'entraînement à la taille de l'image à classifier. Benediktsson et Sveinsson, (1997) ont suggéré l'utilisation de 10 % de l'image pour l'entraînement de leur réseau soit un total de 4189 pixels. Fardanesh et Ersoy (1998), ont utilisé 11,4% de l'image pour l'entraînement et la validation du réseau (1181 pixels pour l'entraînement et 831 pixels pour la validation). Ces pixels ont été utilisés pour classifier 10 classes naturelles à partir d'une image Landsat MSS. D'autre part, Piper (1992) a lié le nombre de pixels d'entraînement au nombre d'informations présentées au réseau. Il a suggéré que le nombre de pixels d'entraînement pour chaque classe doit être au moins égal à 10 fois le nombre de bandes utilisées pour la classification.

### **5.2.1. Préparation des groupes d'apprentissage**

Dans ce projet, quatre classes ont été définies pour tester le réseau : milieux humides fortement arborés, milieux humides moyennement arborés, milieux humides arbustifs et milieux forestiers. Au total, 6000 pixels (1500 pixels par classe) ont été utilisés pour l'entraînement et la validation du réseau de neurones. Ces pixels ont été répartis aléatoirement en trois groupes : apprentissage (60 %), validation (20 %) et test (20%). Chaque groupe contient un nombre égal de pixels pour chaque classe. Les rôles de chacun de ces groupes dans le processus d'entraînement seront présentés dans les sections suivantes de ce chapitre.

Les sites d'entraînement ont été localisés sur le terrain à l'aide d'un système GPS à 12 canaux (appareil Lo-K-tor de la firme VIASAT). Ce système permet de fournir des fichiers numériques contenant le contour de ces sites avec leurs coordonnées géographiques (UTM). Ces fichiers ont été incorporés aux 26 bandes disponibles pour extraire les valeurs de pixels correspondantes. Cette opération a été réalisée par le module ImageWorks du logiciel EASI PACE (PCI Inc.). Les données extraites de sites d'entraînement ont été sauvegardées en quatre matrices (une matrice par classe). Chaque matrice est composée de 29 colonnes et d'un

nombre de lignes égal au nombre total de pixels appartenants à la classe concernée. Les 29 colonnes sont réparties comme suit :

Colonnes 1→2 : coordonnées géographiques du pixel (UTM-X et UTM-Y).

Colonnes 3→8 : les six images brutes (S1 août, S1 octobre, S1 juin, S7 avril, S7 février et S7 mai).

Colonne 9 : la composante principale de trois images S1.

Colonne 10 : la composante principale de trois images S7.

Colonnes 11→13 : la texture Moyenne, la texture Écart Type et la texture Corrélacion de l'image S1 du mois d'août.

Colonnes 14→16 : les trois mesures de texture de l'image S1 du mois d'octobre.

Colonnes 17→19 : les trois mesures de texture de l'image S1 du mois de juin.

Colonnes 20→22 : les trois mesures de texture de l'image S7 du mois d'avril.

Colonnes 23→25 : les trois mesures de texture de l'image S7 du mois de février.

Colonnes 26→28 : les trois mesures de texture de l'image S7 du mois de mai.

Colonne 29 : indice (c) qui correspond à la classe du pixel (c = 0 pour les pixels nuls, c = 1 pour le milieu forestier, c = 2 pour le milieu humide fortement arboré, c = 3 pour le milieu humide arbustif et c = 4 pour le milieu humide moyennement arboré).

Afin de fournir au réseau un nombre égal de pixels pour chaque classe, 1500 lignes ont été choisies aléatoirement de chaque matrice. Cette étape permet d'avoir quatre matrices de dimensions égales (1500 lignes par 29 colonnes). Ensuite, nous avons divisé les lignes de chaque matrice en trois parties :

- La première partie contient 900 lignes (60 % de pixels) : groupe d'apprentissage.

- La deuxième partie contient 300 lignes (20 % de pixels) : groupe de validation.

- La troisième partie contient 300 lignes (20 % de pixels) : groupe test.

Les 12 matrices obtenues sont par la suite rassemblées en trois grandes matrices : une première matrice de 3600 lignes (900 x 4) pour le groupe d'apprentissage, une deuxième matrice de 1200 lignes (300 x 4) pour le groupe de validation et une troisième matrice de 1200 lignes (300 x 4) pour le groupe test. Chacune de ces trois matrices est composée d'un nombre égal de pixels de chaque classe.

Les pixels nuls n'ont pas été considérés comme une classe à part entière. Ils ont été utilisés uniquement pour tester leur effet sur la précision des résultats. Ces pixels ont été répartis en trois matrices : une matrice de 300 lignes pour l'apprentissage, une deuxième matrice de 100 lignes pour la validation et une dernière matrice de 100 lignes pour le groupe test. Ces matrices sont constituées de 29 colonnes similaires aux matrices précédentes. Pendant le test de l'effet des pixels nuls, chacune de ces matrices sera incorporée à la matrice correspondante.

Afin d'homogénéiser la composition des matrices, l'ordre des lignes dans chaque matrice a été mélangé d'une façon aléatoire. L'appartenance d'une ligne à une classe donnée sera identifiée par la valeur de sa 29<sup>ème</sup> colonne (c). Cette étape permet d'éviter la présentation successive au réseau des pixels de la même classe. Toutes ces opérations ont été effectuées par un sous programme Matlab. Ce programme permet de convertir les données produites par le logiciel PCI (en format texte) en fichiers matriciels compatibles avec les modules de Matlab. Les matrices obtenues seront par la suite présentées pour l'entraînement du réseau de neurones.

Les valeurs du paramètre (c) qui se trouvent à la dernière colonne de chaque matrice (colonne 29) ont été utilisées pour créer les matrices qui doivent être présentées à la sortie du réseau. Ainsi, un vecteur de 4 chiffres sera créé pour chaque ligne :

- Si  $c = 0$ , le vecteur correspondant est :  $[0 \ 0 \ 0 \ 0]$ .
- Si  $c = 1$ , le vecteur correspondant est :  $[1 \ 0 \ 0 \ 0]$ .
- Si  $c = 2$ , le vecteur correspondant est :  $[0 \ 1 \ 0 \ 0]$ .
- Si  $c = 3$ , le vecteur correspondant est :  $[0 \ 0 \ 1 \ 0]$ .
- Si  $c = 4$ , le vecteur correspondant est :  $[0 \ 0 \ 0 \ 1]$ .

Ses vecteurs sont par la suite rassemblés en trois matrices de quatre lignes et de nombre de colonnes égal au nombre des lignes des matrices d'entrée (3600 pour la matrice

d'apprentissage, 1200 pour la matrice de validation et 1200 pour la matrice test). Ainsi, chaque ligne des matrices d'entrée (composé des informations liées à un seul pixel) aura une colonne correspondante dans la matrice de sortie.

### **5.3. Configuration du réseau**

#### **5.3.1. Choix d'architecture**

Le nombre de neurones au niveau d'entrée et au niveau de sortie est généralement préétabli par la nature du problème. Ainsi, le nombre de neurones au niveau d'entrée correspond généralement au nombre de bandes disponibles (images, textures, composantes principales... etc.). Dans d'autres cas, les données peuvent être fournies au réseau en format binaire, soit huit neurones pour chaque bande de 8 bits (Heermann and Khazenie, 1992). D'autre part, le nombre de neurones au niveau de sortie est généralement égal au nombre de classes. Les seuls paramètres à varier restent le nombre de niveaux cachés et le nombre de neurones par niveau.

Pour une application donnée, le nombre de niveaux cachés ainsi que le nombre de neurones par niveau n'est pas facile à déduire. Ils dépendent principalement de la quantité et de la complexité des données. Cependant, une architecture qui donne de bons résultats pour une application donnée ne peut être déterminée que d'une façon expérimentale. En outre, une architecture optimale trouvée pour une application spécifique ne peut pas garantir la même performance dans d'autres applications (Kanellopoulos and Wilkinston, 1997).

Bendiktsson *et al.* (1990) ont montré, par comparaison avec des méthodes statistiques de classification, qu'un réseau de neurones de trois niveaux entraînés par un algorithme de rétropropagation offre des potentiels assez intéressants dans la classification des données de télédétection de différentes sources.

Les architectures utilisées dans des applications de télédétection se diffèrent d'une application à une autre. En général, quand on augmente le nombre de neurones cachés, on gagne de la précision sur les pixels utilisés en apprentissage mais le réseau perd sur son pouvoir de généralisation pour d'autres données. Toutefois, une petite architecture risque de provoquer de l'oscillation du réseau au cours de l'apprentissage en affectant sa convergence (Foody and Arora, 1997).

Heermann et Khazenie, (1992) ont testé plusieurs architectures en variant le nombre de neurones au niveau caché de 24 à 37 neurones avec 24 neurones au niveau d'entrée (trois bandes de Landsat TM en format binaire) et trois neurones au niveau de sortie (un neurone par classe). Les auteurs ont conclu que le nombre de neurones au niveau caché a un effet négligeable sur la précision des résultats.

Le tableau 5-1 donne quelques exemples d'architectures utilisées pour la classification des données de télédétection.

**TABLEAU 5-1.** Exemples d'architectures extraites de la littérature.

Auteurs	Source des données	Architectures
Benediktsson and Sveinsson (1997)	RSO aéroportées	22-35-6
Fardanesh and Ersoy (1998)	Landsat MSS	7-14-10
Chen <i>et al.</i> (1997)	SPOT	6-50-50-7 et 6-50-50-9
Yoshida and Omatu (1994)	Landsat TM	3-14-9
Bruzzone <i>et al.</i> (1997)	Landsat TM	20-30-11

Dans ce projet, nous avons testé plusieurs architectures pour évaluer l'effet de ce paramètre sur le comportement du réseau. Le but de cette étape est de chercher la meilleure précision avec une architecture la plus légère possible. La recherche de la plus petite architecture permet de diminuer le temps d'entraînement et de la classification. En fait, l'augmentation de la taille de l'architecture augmente considérablement le temps nécessaire pour l'entraînement et la classification puisque le temps d'entraînement est directement proportionnel au nombre de neurones du réseau.

Vu le comportement aléatoire du réseau au cours de la recherche de l'erreur minimale, nous avons effectué dix tests d'apprentissage pour chaque architecture. L'apprentissage retenu sera celui qui offre, parmi les 10 essais, la meilleure précision pour le groupe test. Généralement, à part un ou deux tests d'apprentissage par architecture, les résultats obtenus sont similaires pour la plupart des tests ( $\pm 2\%$ ). Les quelques exceptions sont dues au fait que le processus d'apprentissage s'arrête parfois à une erreur minimale locale.

Toutes les architectures testées contiennent six neurones au niveau d'entrée et quatre neurones au niveau de sortie. Pour le niveau d'entrée, les trois premiers neurones correspondent aux trois mesures de texture (Moyenne, Écart Type et Corrélacion) extraites de l'image S1 du mois d'août, les trois derniers neurones correspondent aux même mesures de

texture extraites de l'image S7 du mois d'avril. Pour le niveau de sortie, chaque neurone correspond à une classe.

Au total, dix architectures ont été testées; cinq avec un seul niveau caché et cinq autres avec deux niveaux cachés. Afin de ressortir l'effet de l'architecture sur la performance du réseau, nous avons gardé la même configuration pour le reste des paramètres (taux d'apprentissage, fonction d'activation, algorithme d'apprentissage, sites d'entraînement, arrêt d'apprentissage et seuil de décision). Ainsi, seuls le nombre de niveaux cachés et le nombre de neurones par niveau ont été variés. Les résultats présentés au tableau 5-2 présentent les meilleures précisions obtenues pour les dix architectures. La meilleure précision enregistrée sur le groupe test (85,3 %) a été obtenue avec l'architecture 6-12-4 après la 268ème itération.

**TABLEAU 5-2.** Effet de l'architecture du réseau de neurones sur la précision de la classification

Architecture	Nombre des poids (connexions)	Précision totale : du groupe d'apprentissage	Précision totale : du groupe test	Nombre d'itérations
6-6-4	60	89 %	83 %	415
6-8-4	80	89 %	83 %	395
6-10-4	100	88 %	84 %	300
6-12-4	120	89 %	85 %	268
6-14-4	140	89 %	84 %	241
6-6-6-4	96	89 %	85 %	554
6-8-8-4	144	89 %	84 %	268
6-10-10-4	200	89 %	83 %	237
6-12-12-4	264	89 %	84 %	401
6-14-14-4	336	89 %	84 %	310

Ces résultats montrent que l'architecture a un effet minime sur la performance du réseau. La variation de l'architecture fait varier la performance du réseau à l'intérieur d'un intervalle de 2 % pour le groupe test et de 1 % pour le groupe apprentissage. Toutefois, pour atteindre la même performance, un réseau avec un nombre élevé de neurones cachés nécessite moins d'itérations qu'un réseau avec des neurones cachés moins nombreux (415 itérations pour 6 neurones cachés contre 241 itérations pour 14 neurones cachés). Ce phénomène a été aussi observé par Heermann et Khazenie, (1992) en comparant entre deux réseaux avec 24 et 37 neurones cachés. Ces résultats ont montré qu'avec un réseau de neurones de trois niveaux (un seul niveau caché), le nombre d'itérations nécessaires pour la convergence du réseau diminue

en augmentant le nombre de neurones du niveau caché. Cette relation est plus aléatoire avec un réseau de deux niveaux cachés.

Cependant, la diminution du nombre d'itérations avec un réseau plus volumineux ne permet pas d'accélérer le processus d'entraînement étant donné que le temps nécessaire pour une itération est proportionnel au nombre de neurones du réseau. Ainsi, le temps nécessaire pour 415 itérations avec un réseau de 60 neurones est presque équivalent au temps nécessaire pour 241 itérations avec un réseau de 140 neurones. En effet, si on arrive à la même précision avec deux réseaux de tailles différentes, il sera plus avantageux d'utiliser le plus léger afin de réduire le temps nécessaire pour la classification des images.

Pour le reste du projet, nous avons retenu une architecture avec un seul niveau caché ayant un nombre de neurones égal au double de neurones du niveau d'entrée. Ce choix nous donne, par exemple, un réseau de 120 neurones avec six neurones au niveau d'entrée et quatre neurones au niveau de sortie. L'utilisation d'un nombre de neurones cachés égal au double de neurones au niveau d'entrée a été aussi suggérée par Fardanesh et Ersoy (1998). Ce choix nous permet aussi de réduire le temps nécessaire pour la classification complète des images.

### **5.3.2. Configuration du niveau d'entrée**

Dans la plupart des applications de réseaux de neurones en télédétection, le niveau d'entrée du réseau est composé d'un nombre de neurones égal au nombre de bandes fournies au réseau (images brutes, textures, composantes principales... etc.) (Pierce *et al.*, 1994; Foody and Arora, 1997; Fardanesh and Ersoy, 1998). Deux autres configurations ont été aussi utilisées dans quelques applications. La première consiste à fournir au réseau, pour chaque bande, un ensemble de pixels qui se trouvent dans une fenêtre centrée sur le pixel concerné. Cette approche a été utilisée par Bhattacharya et Parui (1997) avec une fenêtre de 3 x 3. Ainsi, 9 neurones sont affectés pour chaque valeur de pixel soit neuf neurones pour chaque bande de données. Cette méthode a donné de bons résultats pour détecter la présence des routes à partir d'une image SPOT. La deuxième configuration consiste à affecter un neurone pour chaque bit d'information. Ainsi, pour une bande TM de Landsat en 8 bits, la valeur numérique d'un pixel (valeur entière entre 0 et 256) sera exprimée en format binaire (combinaison de huit chiffres composé par 0 et 1). Ainsi, chaque pixel sera présenté au niveau d'entrée du réseau par huit neurones (Heermann and Khazenie, 1992).

Dans ce projet, nous avons opté pour la configuration la plus usuelle soit un neurone pour chaque source d'information. Le choix de cette configuration repose essentiellement sur les deux points suivants :

- Il ne sera pas nécessaire d'utiliser des fenêtres autour du pixel puisque les mesures de la texture tiennent déjà compte du voisinage du pixel concerné.
- Les données radar (images brutes et textures) sont en 32 bits. L'utilisation d'un format binaire au niveau d'entrée alourdit considérablement le réseau en affectant 32 neurones pour chaque bande d'information.

En plus, l'utilisation d'un seul neurone pour chaque source d'information réduit la taille du réseau et accélère le processus d'apprentissage et de classification.

Afin d'assurer un bon fonctionnement du réseau, les données présentées à l'entrée doivent être normalisées. Cette opération garantit une réponse significative de la fonction d'activation. C'est-à-dire, pendant l'ajustement des poids, la sortie ajustée de chaque neurone doit refléter les ajustements initiaux. Ceci nous permet d'éviter que de petits changements dans l'entrée du réseau génèrent de grands changements à la sortie, en entraînant la saturation du réseau (Kanellopoulos and Wilkinston, 1997). En effet, il a été démontré que les réseaux de neurones sont plus performants si leurs valeurs d'entrée sont comprises entre 0 et 1 (Fardanesh and Ersoy, 1998). La normalisation des valeurs d'entrée entre 0 et 1 permet aussi d'éviter des valeurs négatives au cours de l'optimisation des poids du réseau.

Dans ce projet, nous avons normalisé les valeurs de pixels entre 0 et 1 par une équation linéaire (équation 5-1).

$$P_n = \frac{P - P_{\min}}{P_{\max} - P_{\min}} \quad (5-1)$$

avec :

$P$  : Valeur initiale du pixel.

$P_n$  : Valeur normalisée du pixel.

$P_{\min}$  : Valeur maximale observée sur tous les pixels de la bande.

$P_{\max}$  : Valeur minimale observée sur tous les pixels de la bande.

#### **5.4. Ajustement des paramètres d'apprentissage**

L'algorithme d'apprentissage par rétropropagation a été utilisé avec succès dans plusieurs applications. Toutefois, l'inconvénient majeur des réseaux de neurones réside dans la lenteur de la phase d'apprentissage (Augusteijn, *et al.* 1995).

Avec l'algorithme de rétropropagation, les valeurs des poids sont ajustées et affinées continuellement tout au long de la phase d'apprentissage. La correction des poids au cours de l'entraînement ne tient compte que des pixels appartenant au groupe d'apprentissage. Au cours de cette phase, les poids du réseau sont corrigés de manière à minimiser l'erreur au carré entre la réponse calculée par le réseau et la réponse attendue. Généralement, l'erreur calculée sur le groupe d'apprentissage diminue continuellement au cours de l'entraînement. Toutefois, une longue phase d'entraînement diminue la capacité de généralisation du réseau en l'adaptant uniquement aux données de l'apprentissage. Ce phénomène est appelé le surentraînement ou «*overfitting*» en anglais.

Plusieurs paramètres interviennent au cours de la phase d'apprentissage. Ces paramètres sont liés au fonctionnement interne de l'algorithme de rétropropagation. Ils sont entre autres : le taux d'apprentissage, le momentum, la fonction d'activation et les critères d'arrêt d'apprentissage. De nombreuses études ont permis de mieux comprendre l'influence de ces paramètres et d'en améliorer le choix. Nous présentons dans les paragraphes suivants les tests effectués pour l'optimisation de ces paramètres. Cette étape a permis de choisir la configuration idéale du réseau avant d'étudier l'apport de chaque intrant à la performance de la classification par réseau de neurones.

Normalement, les valeurs des poids doivent être initiées avant chaque test d'apprentissage. L'initialisation des poids permet d'offrir les mêmes conditions d'apprentissage pour chaque test (Paola and Schowengerdt, 1995). Toutefois, dans ce projet, le nombre de connexions (ou des poids) entre les neurones varie d'un test à un autre étant donnée que le nombre de neurones au niveau d'entrée varie selon la combinaison d'intrants choisie. Cela nous empêche de choisir les mêmes valeurs de connexions pour tous les tests. Pour remédier à ce problème, nous avons opté pour un choix aléatoire des poids initiaux avec des valeurs proches de zéro. Afin d'éviter l'effet d'un mauvais choix des poids initiaux, une dizaine de tests a été effectuée pour chaque configuration. Cette méthodologie a été suggérée par (Tarassenko, 1998) dans le cas de plusieurs tests d'apprentissage avec différentes architectures.

### 5.4.1. Taux d'apprentissage

Le taux d'apprentissage permet de calculer le changement à apporter aux valeurs des poids après chacune des itérations. La valeur de ce taux affecte considérablement la performance de l'algorithme d'apprentissage. Ainsi, un taux d'apprentissage très grand (proche de 1) provoque une instabilité du réseau et entraîne une oscillation de l'erreur pendant l'apprentissage. Par contre, si on choisit un taux assez petit (proche de 0), l'algorithme d'apprentissage prendra beaucoup de temps pour converger (Paola and Schowengerdt, 1995).

L'optimisation du taux d'apprentissage consiste à chercher un taux le plus élevé que possible pour avoir un apprentissage rapide tout en gardant un réseau stable sans risque d'oscillation au cours de l'entraînement. La valeur du taux d'apprentissage ( $\eta$ ) est spécifique pour chaque application. Il est généralement optimisé au début de la phase d'entraînement par des méthodes d'essais-erreurs. Plusieurs valeurs de ( $\eta$ ) ont été utilisés dans des applications des réseaux de neurones en télédétection. Parmi celles-ci, Gopal et Woodcock (1996) ont trouvé le meilleur compromis avec un taux égal à 0,3. Pierce *et al.* (1994) ont choisit un taux d'apprentissage égal à 0,1 afin de garder un apprentissage lent sans risque d'oscillation. Ce taux a été aussi utilisé par Foody et Arora, (1997). Dans une autre étude, Bruzzone *et al.* (1997) ont testé plusieurs taux d'apprentissage pour classifier des images Landsat-TM. Ils ont obtenu la meilleure précision avec un taux d'apprentissage égal à 0,01.

D'autres auteurs ont établi des formules empiriques inspirées du fonctionnement interne du réseau. Pour éviter l'instabilité du réseau de neurones, McClelland et Rumelhart (1986) ont suggéré que le taux d'apprentissage ( $\eta$ ) soit égal à l'inverse du nombre total de neurones dans le réseau ( $n$ ) soit :

$$\eta = \frac{1}{n} \quad (5-2)$$

D'autre part, Heermann et Khazenie, (1992) ont suggéré que le choix du taux d'apprentissage doive tenir compte du nombre des pixels utilisés en entraînement. Ils ont ainsi modifié l'équation (5-2) proposée par McClelland et Rumelhart (1986) en introduisant un paramètre qui dépend du nombre de pixels (équation 5-3).

$$\eta = C_0 \times \frac{1}{p} \times \frac{1}{n} \quad (5-3)$$

Le coefficient  $C_0$  varie d'une application à une autre et doit être déterminé expérimentalement. Après plusieurs tests, Heermann et Khazenie, (1992) ont trouvé la meilleure précision avec  $C_0 = 10$ .

La méthode proposée par Heermann et Khazenie, (1992) ne résout pas le problème du choix approprié d'un taux d'apprentissage, mais elle fait juste le déplacer. Ainsi, au lieu de faire varier directement le taux d'apprentissage ( $\eta$ ), on fait varier un coefficient ( $C_0$ ) qui est directement proportionnel à ( $\eta$ ) puisque le nombre de neurones et le nombre de pixels d'entraînement restent constants pendant le choix du taux d'apprentissage.

Dans ce projet, nous avons adopté une méthode d'entraînement avec un taux d'apprentissage variable. Cette méthode a été développée par Vogl *et al.* (1988). Nous avons utilisé dans ce projet une version de cette méthode améliorée par Hagan *et al.* (1996). Heermann et Khazenie (1992) ont utilisé la version proposée par Vogl *et al.* (1988) pour la classification de trois bandes de Landsat TM. En utilisant un taux d'apprentissage variable, les auteurs ont réussi d'accélérer la phase d'entraînement du réseau en passant de trois semaines à trois jours avec un ordinateur HP 9000-385. D'après une revue de littérature sur les utilisations des réseaux de neurones en télédétection dans les quinze dernières années (depuis le développement de l'algorithme d'apprentissage par rétropropagation par Rumelhart *et al.*, 1986), nous n'avons pas trouvé d'autres utilisations de cette méthode adaptative dans des applications en télédétection.

L'utilisation d'un taux d'apprentissage variable permet d'accélérer l'entraînement du réseau quand il est sur le bon chemin et de le freiner s'il prend une piste indésirable. Ainsi, le taux d'apprentissage varie pendant l'entraînement selon la variation de l'erreur entre deux itérations successives. Cette méthode permet de tenir compte uniquement des changements des poids qui font diminuer l'erreur. Le fonctionnement de cette méthode se fait comme suit :

Si, après une itération ( $i$ ), la nouvelle erreur ( $E_i$ ) dépasse l'ancienne erreur ( $E_{i-1}$ ) de  $x$  %, on ignore les modifications apportées aux poids et on reprend l'itération en multipliant l'ancien taux par un coefficient inférieur à 1 pour freiner l'évolution négative de l'erreur. Ce coefficient est appelé taux de freinage. Par contre, si l'erreur ( $E_{i-1}$ ) est inférieure à l'erreur précédente, on augmente légèrement le taux d'apprentissage en le multipliant par un coefficient supérieur à 1 afin d'accélérer l'apprentissage du réseau. Ce coefficient est appelé taux d'accélération.

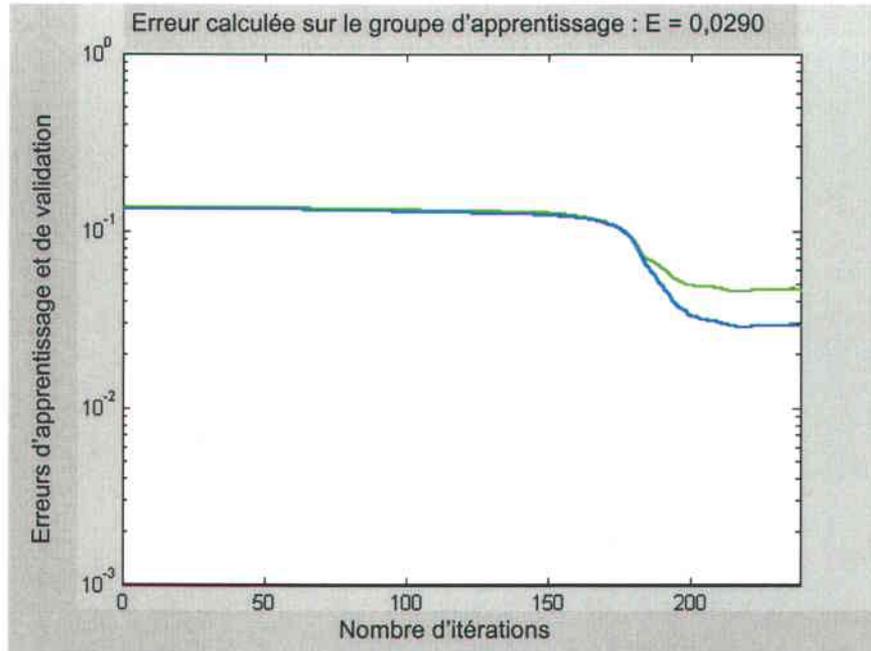
Par exemple, si on fixe la valeur du seuil à 5 % ( $x = 5$ ), trois cas se présentent :

- Si  $\frac{E_i}{E_{i-1}} > 1,05$ , on fait décroître l'ancien taux d'apprentissage en le multipliant par un coefficient de freinage inférieur à 1.
- Si  $1 < \frac{E_i}{E_{i-1}} < 1,05$ , on garde le même taux d'apprentissage pour la prochaine itération.
- Si  $\frac{E_i}{E_{i-1}} < 1$ , on augmente l'ancien taux d'apprentissage en le multipliant par un coefficient d'accélération supérieur à 1.

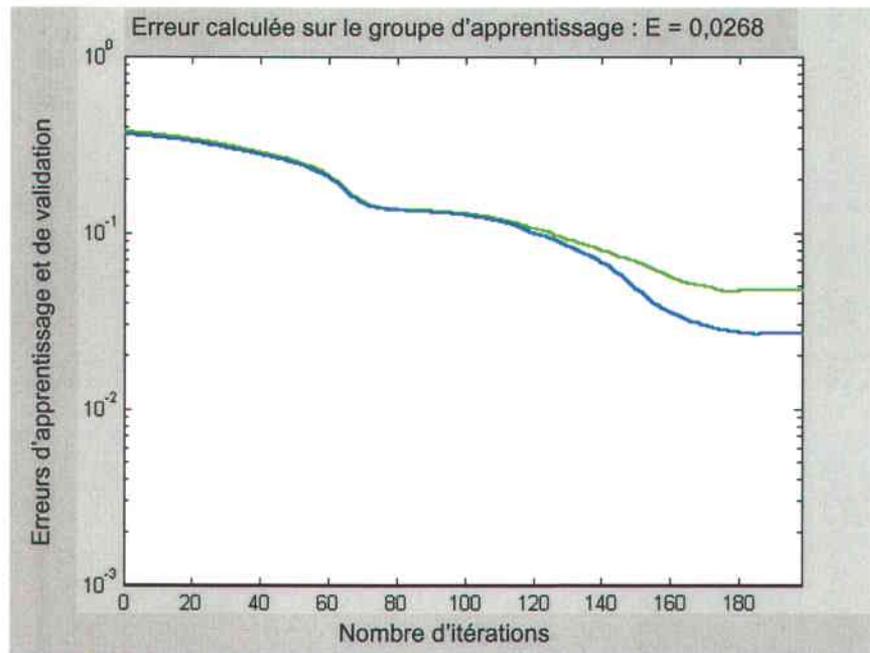
Afin d'optimiser les paramètres liés au taux d'apprentissage, nous avons varié les valeurs de chaque paramètre dans plusieurs tests d'apprentissage. Le choix des valeurs optimales est basé essentiellement sur la rapidité d'apprentissage et la convergence du réseau.

#### ***A. Effet du taux d'apprentissage initial :***

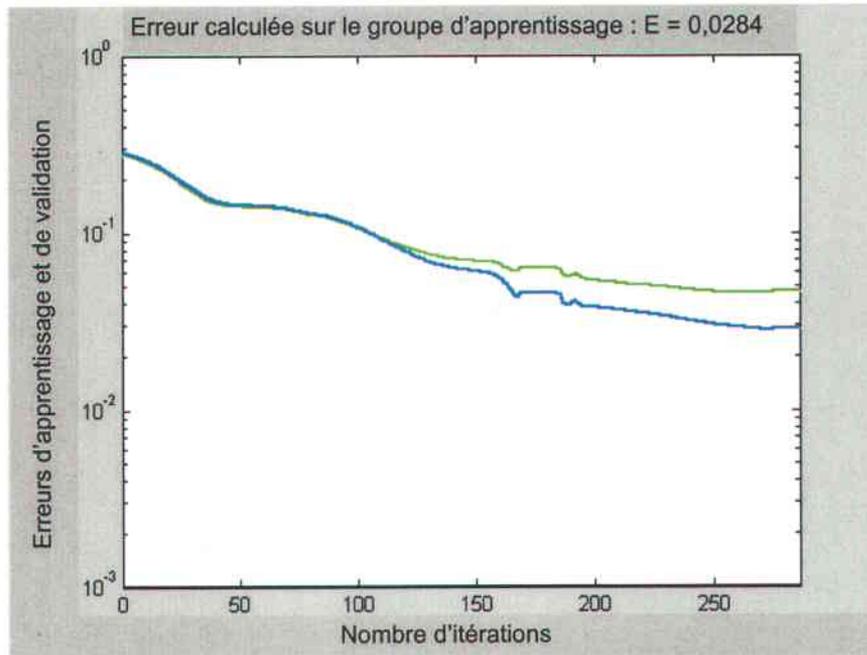
Nous avons testé dix taux d'apprentissage initiaux compris entre 0,01 et 0,1. Afin d'étudier uniquement l'effet du taux d'apprentissage, nous avons fixé les valeurs des autres paramètres comme suit : un seuil ( $x$ ) = 4 %, un coefficient de freinage = 0,9 et un coefficient d'accélération = 1,05. Les graphiques de la figure 5-1 montrent le comportement du réseau pour trois taux d'apprentissages initiaux : 0,01, 0,05 et 0,1. En analysant l'évolution de l'erreur dans ces trois cas, on a observé qu'un taux d'apprentissage faible (proche de 0,01) provoque un ralentissement du processus d'entraînement et une convergence lente (mais sûre) vers l'erreur optimale (figure 5-1a). Par contre, en adoptant un taux d'apprentissage élevé (proche de 0,1), le réseau devient plus exposé aux risques d'oscillation ce qui implique une augmentation du nombre d'itérations nécessaires pour la convergence du réseau (figure 5-1b).



**Figure 5-1a.** Effet du taux initial sur l'entraînement du réseau (taux = 0,01)



**Figure 5-1b.** Effet du taux initial sur l'entraînement du réseau (taux = 0,05)



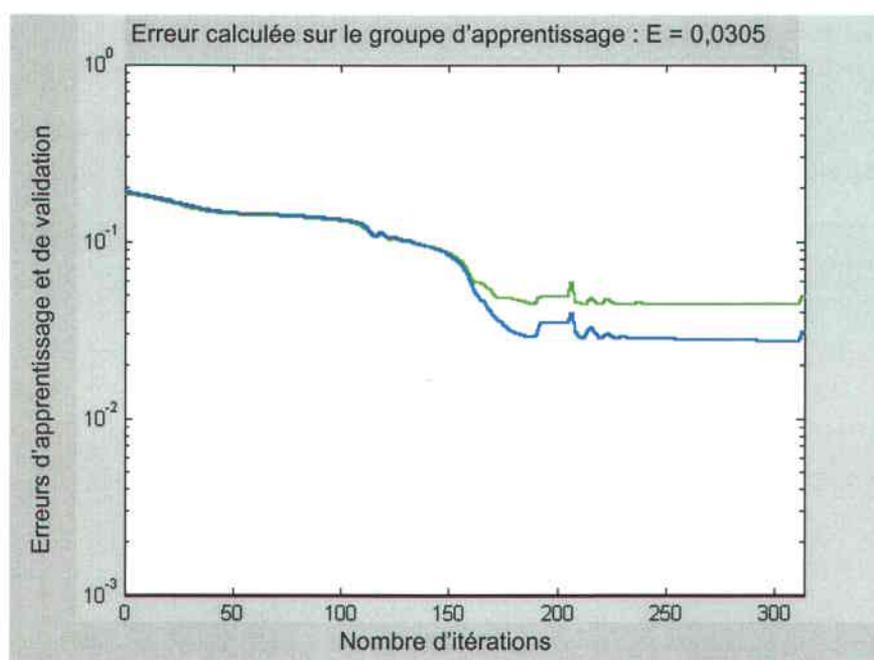
**Figure 5-1c.** Effet du taux initial sur l'entraînement du réseau (taux = 0,1)

Les différents tests effectués sur le taux d'apprentissage initial ont montré que le nombre d'itérations nécessaires à la convergence du réseau est proportionnel au taux d'apprentissage jusqu'à un certain seuil (égal à 0,07). Au-delà de ce seuil, le comportement du réseau devient aléatoire à cause de l'oscillation de l'erreur. Suite à ces tests nous avons choisi un taux d'apprentissage initial égal à 0,05 pour le reste du projet. Ce taux représente un bon compromis entre une convergence rapide du réseau et un risque presque nul d'oscillation.

### ***B. Effet du seuil ( $x$ ) :***

Le seuil ( $x$ ) représente une limite de tolérance au-delà de laquelle on n'accepte aucune évolution négative de l'erreur au cours d'apprentissage. C'est avec ce seuil qu'on décide si on doit freiner ou conserver le processus d'apprentissage. Dans leurs travaux sur le taux d'apprentissage adaptatif, Hagan *et al.* (1996) ont suggéré l'utilisation d'un seuil égal à 4 %. Dans notre cas, nous avons évalué l'effet de ce seuil sur le comportement du réseau pendant l'apprentissage en effectuant cinq tests d'apprentissage avec des valeurs de ( $x$ ) comprises entre 2 % et 10 %. Dans ces tests, nous avons utilisé un taux d'apprentissage initial égal à 0,05, un coefficient de freinage = 0,9 et un coefficient d'accélération = 1,05.

Les graphiques de la figure 5-2 montrent quelques exemples d'apprentissage avec différentes valeurs de  $(x)$ . Suite à ces tests, nous avons trouvé que le seuil de tolérance ( $x = 4 \%$ ) proposé par Hagan *et al.* (1996) présente un bon compromis (figure 5-2c). En effet, un grand seuil signifie qu'on tolère des baisses importantes de l'erreur au cours de l'entraînement du réseau ce qui risque de provoquer des oscillations de l'erreur et des ralentissements de la phase d'apprentissage (figure 5-2a). Toutefois, si on choisit un seuil faible (proche de 1), le réseau devient moins tolérant aux faibles accroissements de l'erreur. Cette situation peut provoquer une immobilité de l'apprentissage dans le cas où le réseau se retrouve dans un *minima* local (figure 5-2b). Dans ce cas, aucune modification significative ne sera apportée aux poids du réseau pendant plusieurs itérations.



**Figure 5-2a.** Effet du seuil de tolérance ( $x$ ) sur l'apprentissage ( $x = 10 \%$ )

Toutefois, cette diminution spectaculaire provoque, dans la plupart des cas, une immobilisation de l'erreur avec une légère variation aléatoire. Ce phénomène est principalement dû au fait que le réseau apporte une grande modification au taux d'apprentissage dès que l'erreur enregistre une légère évolution positive tout en ignorant les autres cheminements possibles. Dans le cas contraire, des tests effectués avec un faible taux d'accélération (proches de 1) ont montré qu'un faible taux d'accélération n'apporte pas une grande amélioration au processus d'apprentissage (figure 5-3b). Ainsi, les résultats obtenus sont similaires à ceux obtenus avec une méthode de rétropropagation standard avec un taux d'apprentissage fixe. Suite à ces tests, nous avons opté pour un taux d'accélération moyen égal à 1,05 (figure 5-3c). Ce taux offre un apprentissage stable et rapide.

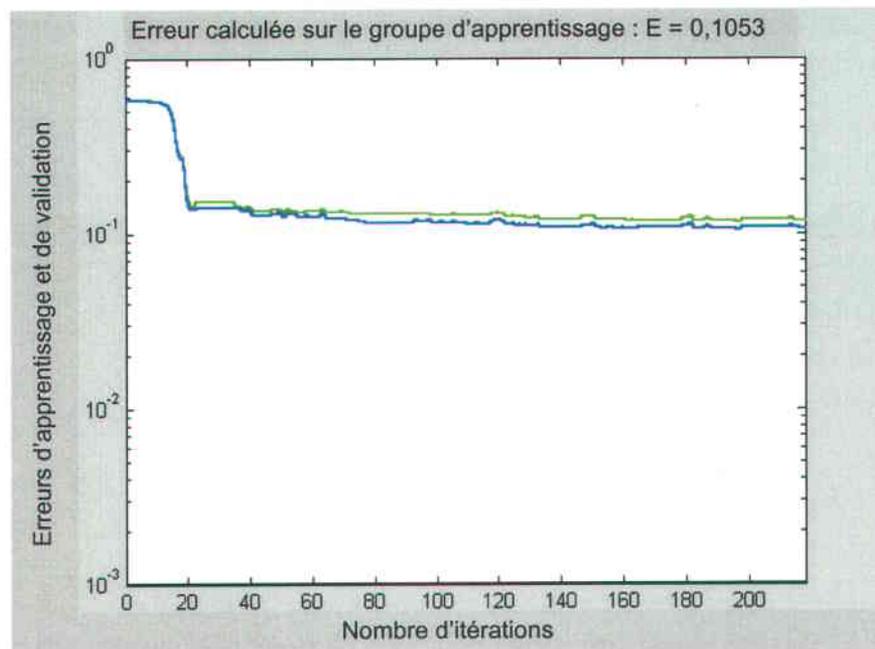
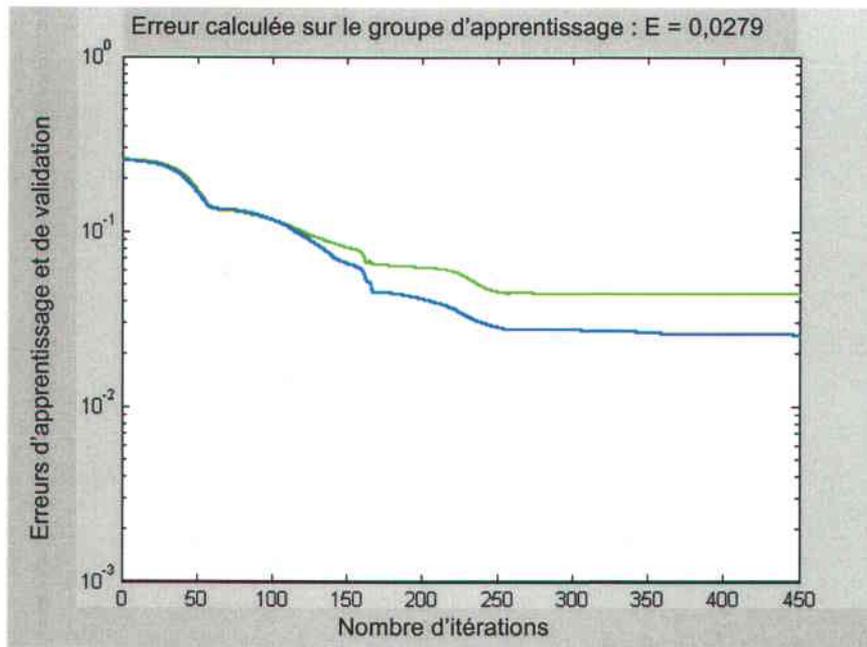
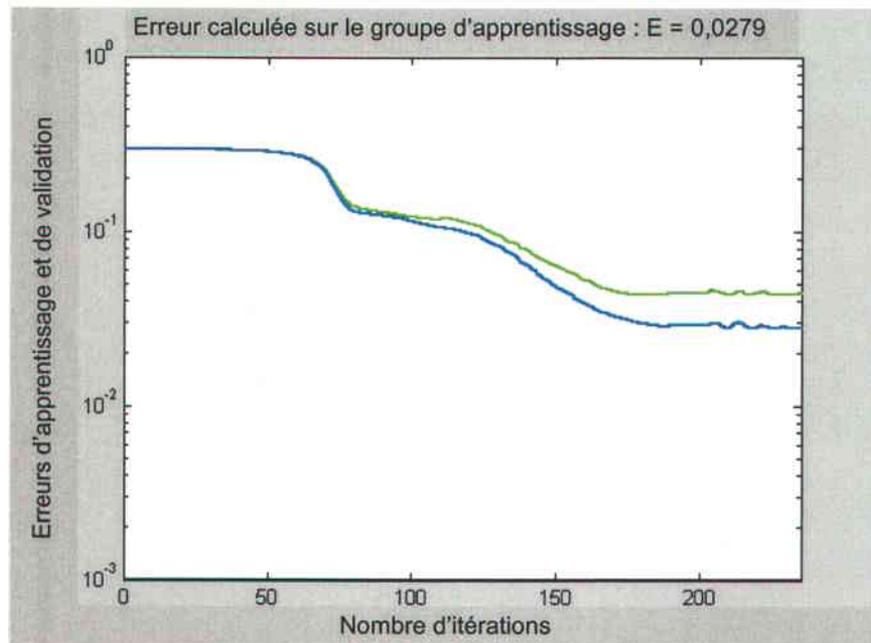


Figure 5-3a. Comportement de l'apprentissage avec un taux d'accélération élevée (taux = 1,10)



**Figure 5-2b.** Effet du seuil de tolérance ( $x$ ) sur l'apprentissage ( $x = 2\%$ ).



**Figure 5-2c.** Effet du seuil de tolérance ( $x$ ) sur l'apprentissage ( $x = 4\%$ )

### **C. Effet du coefficient d'accélération :**

Ce coefficient joue un rôle primordial dans l'accélération de l'apprentissage. En faisant varier ce coefficient dans plusieurs tests d'apprentissage, on a observé qu'un coefficient d'accélération élevée (supérieur à 1,2) peut donner une diminution rapide mais limitée de l'erreur (figure 5-3a).

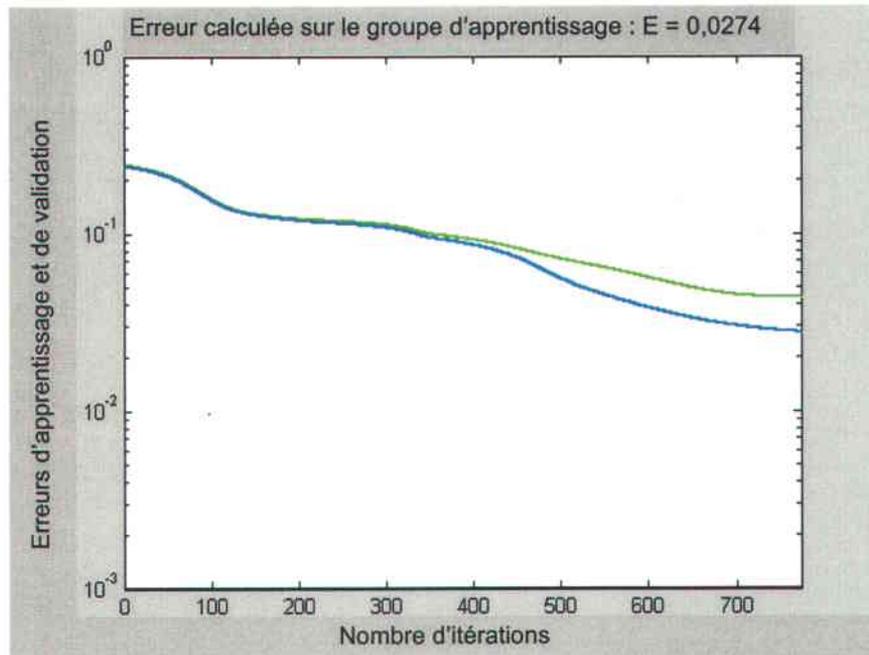


Figure 5-3b. Comportement de l'apprentissage avec un faible taux d'accélération (taux = 1,01)

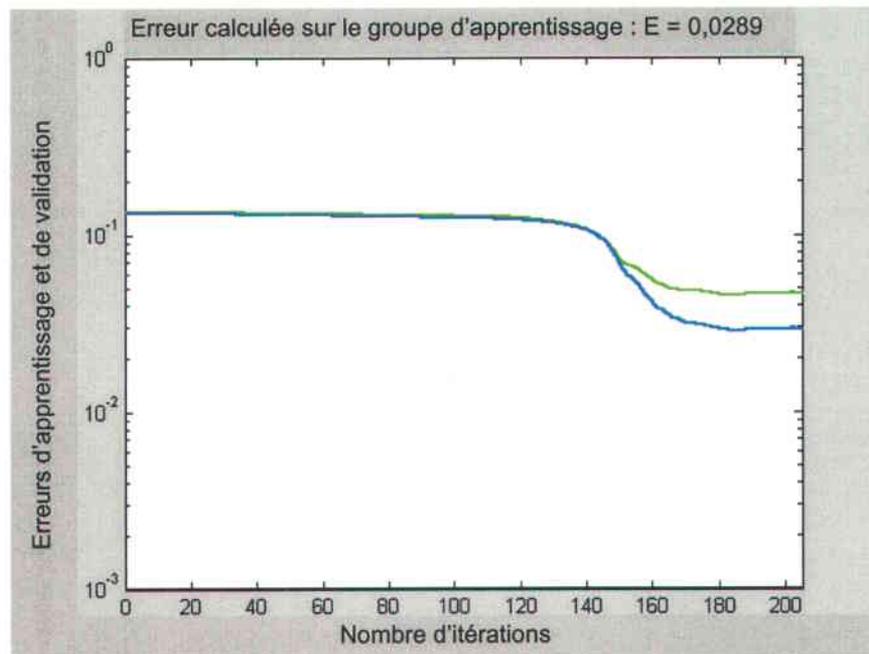
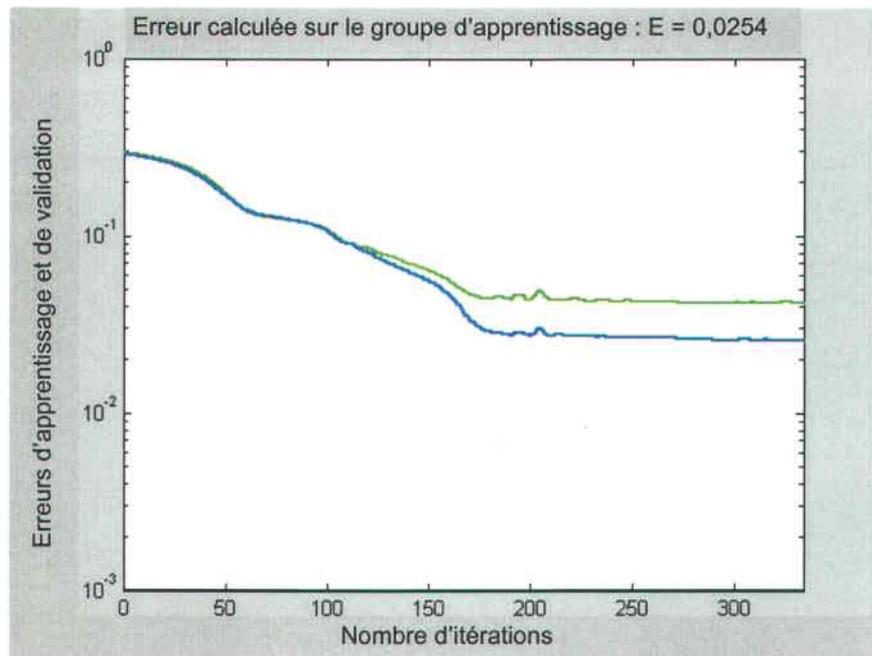


Figure 5-3c. Comportement de l'apprentissage avec un taux d'accélération égal à 1,05

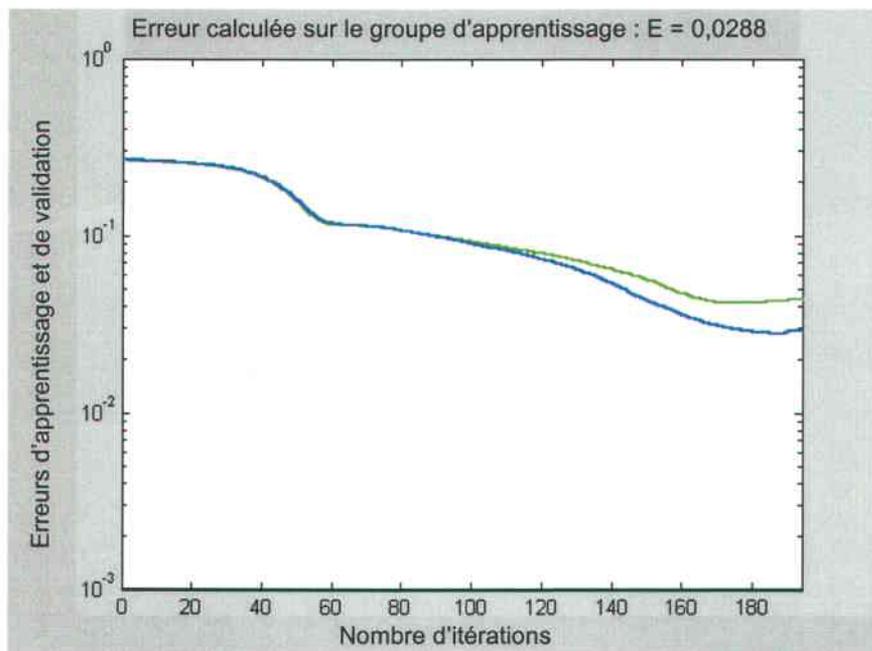
#### ***D. Effet du coefficient de freinage :***

Plusieurs tests ont été effectués avec des valeurs de ce coefficient qui varient entre 0,5 et 0,9. Les résultats observés ont montré que l'effet de ce coefficient sur le déroulement de l'apprentissage est moins important que le coefficient d'accélération. Toutefois, un faible taux de

freinage (proche de 0,5) apporte des changements brusques au taux d'apprentissage ce qui provoque quelques oscillations de l'erreur au cours de l'entraînement *et allonge* le temps nécessaire pour la convergence du réseau (figure 5-4a). Nous avons donc gardé un taux de freinage égal à 0,9 (figure 5-4b) pour éviter les changements brusques au taux d'apprentissage.



**Figure 5-4a.** Comportement de l'apprentissage avec taux de freinage égal à 0,5



**Figure 5-4b.** Comportement de l'apprentissage avec taux de freinage égal à 0,9

Ces étapes d'ajustement nous ont permis de fixer les paramètres liés au taux d'apprentissage. Le tableau 5-3 présente une récapitulation de ces paramètres retenus pour le reste du projet.

**TABLEAU 5-3.** Optimisation des paramètres liés au taux d'apprentissage

	Intervalles testés	Coefficients gardés
Taux d'apprentissage initial	[0,01 → 0,1], pas = 0,02	0,05
Seuil d'apprentissage ( $x$ )	[1% → 10%], pas = 1%	4 %
Coefficient de freinage	[0,5 → 0,9], pas = 0,1	0,9
Coefficient d'accélération	[1,01 → 1,1], pas = 0,01	1,05

#### 5.4.2. le momentum

Le paramètre momentum ( $\alpha$ ) a été ajouté à la règle généralisée de delta (voir équation 4-16) par Rumelhart *et al.* (1986) pour éviter tous risques de divergence ou d'oscillation pendant l'apprentissage. Ce paramètre, qui varie entre 0 et 1, mesure l'effet de l'itération précédente sur l'itération en cours. Un momentum proche de zéro signifie que les itérations précédentes ont un faible effet sur l'itération en cours. Cet effet est plus grand quand la valeur du momentum est proche de 1. La valeur de momentum varie d'une application à une autre mais elle est rarement inférieure à 0,6. Par exemple, Pierce *et al.* (1994) ont utilisé un momentum égal à 0,9 pour augmenter le lien entre les itérations pendant l'apprentissage. Cette valeur a été aussi utilisée par Foody et Arora, (1997). Gopal et Woodcock (1996) ont optimisé leur réseau de neurones avec un momentum égal à 0,6.

Dans ce projet, nous avons évalué l'effet du momentum sur la performance du réseau. En variant ce paramètre entre 0,5 et 0,95, on a observé que le momentum n'a pas un effet significatif ni sur la performance du réseau ni sur le nombre d'itérations. En effet, en utilisant un taux d'apprentissage variable au cours de la phase d'apprentissage, il est difficile d'évaluer l'effet réel du momentum sur l'évolution de l'apprentissage. Avec cette méthode adaptative du taux d'apprentissage, l'effet négatif d'un mauvais choix du momentum sera compensé par un ajustement du taux d'apprentissage au cours de l'entraînement du réseau.

### 5.4.3. La fonction d'activation

La fonction d'activation permet de normaliser les sorties de neurones dans un intervalle prédéfini grâce à sa forme asymptotique (figure 4-3). Les sorties de neurones sont échelonnées sur un intervalle  $[0,1]$  par la fonction sigmoïde (équation 5-4) ou sur un intervalle  $[-1,1]$  si on utilise la fonction tangente hyperbolique (équation 5-5).

$$\text{Fonction sigmoïde : } f(x) = \frac{1}{1 + e^{-x}} \quad (5-4)$$

$$\text{Fonction tangente hyperbolique : } g(x) = \tanh(x) \approx \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (5-5)$$

Avec une architecture de trois niveaux (§ 5.3.1), la fonction d'activation intervient uniquement à deux reprises entre le niveau d'entrée et le niveau caché et entre le niveau caché et le niveau de sortie. Étant donné que les neurones du nouveau de sortie doivent fournir une réponse comprise entre 0 et 1, on a opté pour une fonction sigmoïde entre les deux derniers niveaux. Nous avons donc évalué l'effet de la fonction d'activation entre le niveau d'entrée et le niveau caché.

Suite à plusieurs tests d'apprentissage avec les deux fonctions d'activation, les résultats obtenus ont montré que la précision obtenue avec une fonction sigmoïde est légèrement supérieure que celle obtenue avec la tangente hyperbolique. Cette différence est probablement due à la présence des valeurs négatives à la sortie des neurones. Nous avons donc conservé la fonction d'activation sigmoïde dans les différentes couches du réseau.

## **5.5. Supervision de l'apprentissage du réseau**

Cette étape représente la dernière phase d'optimisation du réseau de neurones. Tous les paramètres ajustés précédemment seront utilisés dans cette étape. Ainsi, l'architecture utilisée sera composée de trois couches de neurones : un niveau d'entrée composé d'un nombre de neurones égal au nombre d'informations fournies au réseau, un niveau caché avec un nombre de neurones égal au double de neurones du niveau d'entrée et un niveau de sortie de quatre neurones (un neurone par classe). L'apprentissage sera effectué par un algorithme de rétropropagation avec un taux d'apprentissage variable (§ 5.4.1) en utilisant les paramètres présentés au tableau 5-3. Les sorties de neurones seront normalisées par une fonction d'activation sigmoïde.

Les données d'entraînement ont été préalablement réparties en six matrices. Trois matrices pour le niveau d'entrée du réseau et trois matrices pour le niveau de sortie. Les matrices d'entrée ont la composition suivante :

- Une première matrice de 3600 lignes pour l'apprentissage du réseau (groupe apprentissage).
- Une deuxième matrice de 1200 lignes pour décider le moment d'arrêt de l'apprentissage (groupe de validation).
- Une troisième matrice de 1200 lignes pour mesurer la performance du réseau (groupe test).

Les matrices de sortie sont composées de quatre lignes (une ligne pour chaque neurone) et d'un nombre de colonnes égal au nombre de pixels de chaque groupe.

#### **5.5.1. Apprentissage du réseau**

Au début de la phase d'apprentissage, les matrices d'entrée du groupe apprentissage et validation sont présentées au réseau avec les matrices de sortie correspondantes. Les valeurs des poids sont ajustées et affinées continuellement tout au long de la phase d'apprentissage. La correction des poids au cours de l'entraînement ne tient compte que des pixels appartenants au groupe d'apprentissage. Au cours de cette phase, les poids du réseau sont corrigés de manière à minimiser l'erreur au carré entre la réponse calculée par le réseau et la réponse attendue.

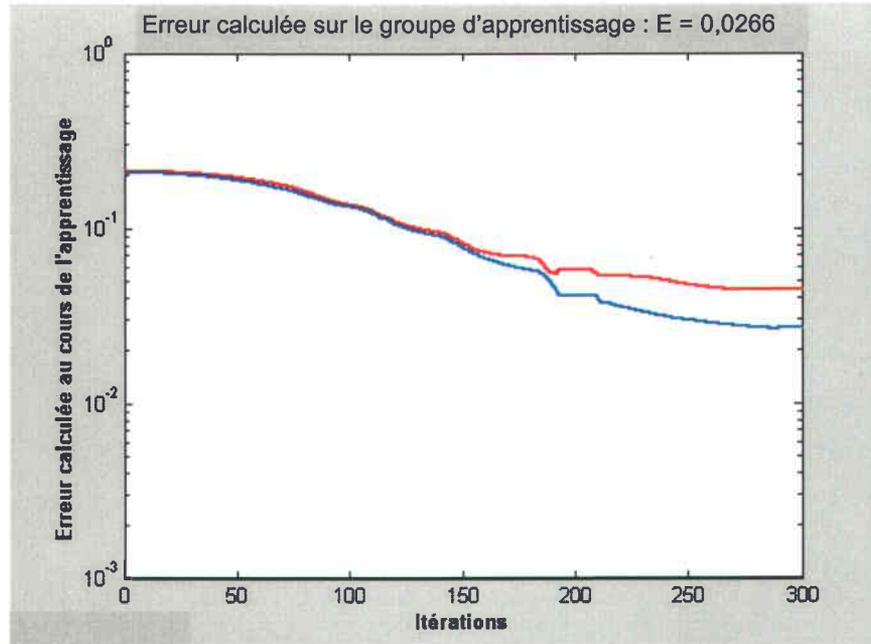


Figure 5-5. Évolution de l'erreur au cours de l'apprentissage.

Généralement, l'erreur calculée sur le groupe d'apprentissage diminue continuellement au cours de l'entraînement. Toutefois, une longue phase d'entraînement diminue la capacité de généralisation du réseau en l'adaptant uniquement aux données de l'apprentissage. Ce phénomène est appelé le surentraînement ou « *overfitting* » en anglais. À cet effet, nous avons ajouté un autre groupe de données (groupe de validation) pour déterminer à quel moment l'apprentissage doit être arrêté.

Le graphique de la figure 5-5 montre un exemple de variation de l'erreur des groupes apprentissage et validation au cours de l'entraînement du réseau. La courbe supérieure représente l'évolution de l'erreur calculée pour le groupe validation et la courbe inférieure représente l'erreur calculée pour le groupe apprentissage. Dans ce graphique, on voit bien que les deux erreurs suivent la même évolution pendant les 100 premières itérations avant de commencer un éloignement graduel pour le reste de l'apprentissage.

### 5.5.2. Critères d'arrêt d'apprentissage

Les critères d'arrêt d'apprentissage ont été rarement abordés dans des applications des réseaux de neurones en télédétection. Dans la majorité des cas, les auteurs arrêtent l'apprentissage lorsque l'erreur atteint une valeur optimale établie a priori ou lorsque le nombre d'itérations atteint une limite préétablie. Par exemple, Bruzzone *et al.* (1997) ont fixé deux

critères pour l'arrêt de l'apprentissage : si l'erreur moyenne au carrée atteint 0.05 ou si le nombre des itérations atteint 400. Cette méthode reste très limitée pour définir le moment idéal d'arrêt d'apprentissage à cause du comportement aléatoire du processus d'apprentissage. En plus, ces critères d'arrêt ne peuvent pas prévenir le surentraînement du réseau.

Dans ce projet, nous avons utilisé un deuxième groupe de données (groupe de validation) pour décider du moment idéal d'arrêt de l'apprentissage. Les pixels appartenants à ce groupe servent uniquement à vérifier le comportement du réseau au cours de l'entraînement face à des données qui lui sont étrangères. Contrairement à l'erreur calculée sur le groupe d'apprentissage qui diminue continuellement au cours de l'entraînement, celle calculée sur le groupe de validation diminue dans la première phase d'entraînement en suivant une allure semblable à celle du groupe d'apprentissage avant de commencer une lente ascension. Ceci est expliqué par le fait que le réseau commence à perdre son pouvoir de généralisation en adaptant ces neurones uniquement au groupe d'apprentissage. L'entraînement du réseau sera donc arrêté dès que cette erreur commence son ascension. Toutefois, afin d'éviter un arrêt prématuré d'apprentissage causé par une augmentation ponctuelle de l'erreur du groupe validation, nous avons introduit un seuil de décision qui tolère des légères ascensions successives de l'erreur. Si l'erreur validation continue son ascension au delà de ce seuil, on arrête l'apprentissage du réseau et on conserve les valeurs des poids qui correspondent à l'itération qui précède cette ascension. Après plusieurs tests, nous avons trouvé qu'un seuil de 20 itérations est largement suffisant pour détourner ce genre de situation.

### **5.5.3. Mesure de la performance du réseau**

Après l'arrêt d'apprentissage, nous nous procédons à vérifier la performance du réseau avec un troisième groupe de données (groupe test). Ce groupe est constitué d'un ensemble de pixels qui n'ont pas servi à l'apprentissage et qui n'ont joué aucun rôle dans la prise de décision dans l'arrêt de l'apprentissage. Le groupe test est utilisé uniquement pour mesurer la performance du réseau après l'arrêt de l'apprentissage. Si le réseau arrive à prédire correctement les classes correspondantes de ce groupe de pixels avec une précision acceptable, on peut dire que le réseau est opérationnel. Dans le cas contraire, il faut réviser les intrants du réseau et recommencer l'apprentissage. Les résultats calculés avec le groupe test seront utilisés pour le calcul des matrices de confusion.

L'organigramme illustré à la figure 5-6 résume les principales étapes suivies pendant l'apprentissage du réseau de neurones et montre le cheminement de chaque groupe de données.

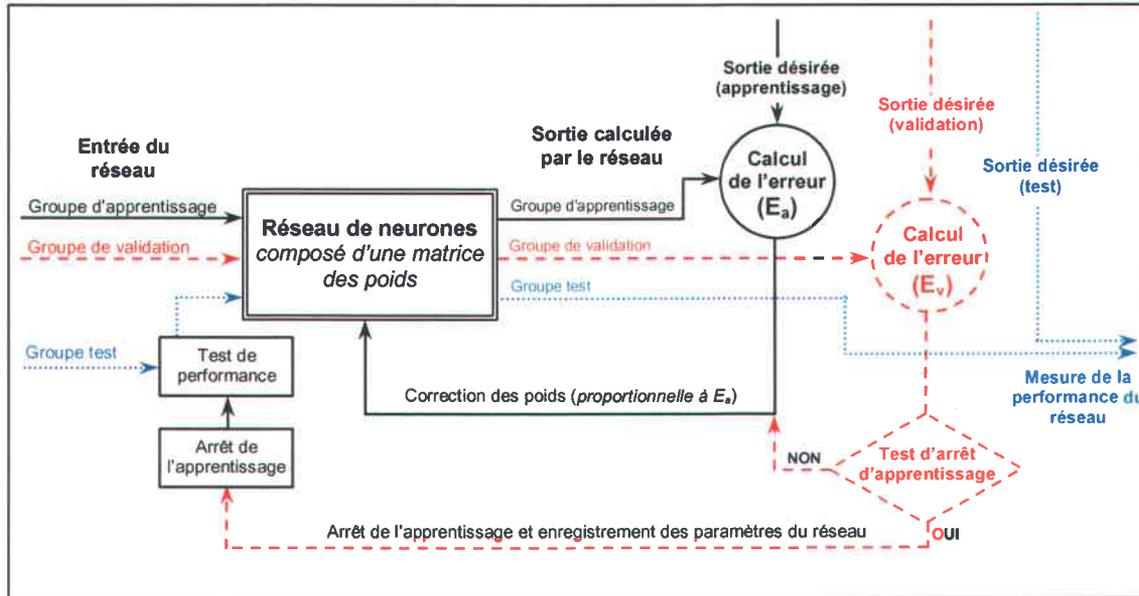


Figure 5-6. Description schématique de la phase d'apprentissage

### 5.6. Conclusion

Nous avons présenté dans ce chapitre les différentes étapes effectuées pour la préparation du réseau de neurones à la phase finale du projet, soit la classification des milieux humides avec une série d'images Radarsat-1. Ces étapes ont permis d'optimiser les paramètres internes du réseau. Tous ces paramètres (présentés au tableau 5-3) seront conservés et utilisés pour évaluer l'effet des paramètres externes au réseau (intrants) sur la précision de la classification. Cette dernière étape du projet sera présentée au chapitre suivant.

# CHAPITRE 6

## Classification des images

---

Ce chapitre décrit l'aboutissement final de cette recherche doctorale. Il présente les étapes suivies pour l'optimisation des paramètres externes du réseau de neurones et l'évaluation de leur apport à la performance générale de la classification des milieux humides. Les paramètres externes au réseau constituent les intrants du réseau. Ils sont composés des produits dérivés des images Radarsat-1 acquises dans le cadre de ce projet.

La plupart des méthodes de classification supervisées (ou par voie dirigée) suivent les étapes suivantes dans leur processus (Richards, 1993) :

1. Définir un ensemble de classes (ou couvertures du sol) selon les quelles l'image sera segmentée.
2. Choisir des pixels représentatifs de chacune de classes définies à l'étape précédente pour l'entraînement de l'algorithme de classification. Le choix de ces pixels peut se faire suite à des visites sur le terrain ou par photo-interprétation.
3. Diviser les zones d'entraînement en deux groupes : un premier groupe pour l'apprentissage et un deuxième pour la vérification.
4. Utiliser les données d'apprentissage pour l'estimation des paramètres de l'algorithme choisi pour la classification.
5. Utiliser l'algorithme déjà entraîné pour la classification de toute l'image.
6. Produire une carte thématique qui résume le résultat de la classification.

## 7. Vérifier la précision des résultats avec le groupe test.

Dans ce projet, nous avons utilisé la statistique Z calculée à partir des coefficients Kappa pour évaluer s'il existe une différence significative entre les différentes combinaisons d'intrants du réseau de neurones (voir section §4.10). Ce test permet de voir si l'ajout ou la suppression d'un nouvel intrant a un effet significatif sur la précision de la classification. Ce test a été aussi utilisé pour comparer les précisions obtenues avec les réseaux de neurones et la méthode de maximum de vraisemblance.

Le calcul des éléments des matrices de confusion utilisées dans ce chapitre a été effectué avec les pixels appartenants au groupe test (§ 5.5.3). Les pixels de ce groupe sont différents de ceux ayant servi à l'apprentissage. En plus, ces pixels n'ont joué aucun rôle dans la prise de décision dans l'arrêt de l'apprentissage.

Les matrices de confusion présentées dans ce chapitre sont exprimées en pourcentage. Étant donné que l'approche adoptée est basée sur une classification non forcée, les matrices obtenues seront formées de quatre lignes (C1, C2, C3 et C4) et de cinq colonnes (C1, C2, C3, C4 et nulle) :

C1 : Milieu forestier

C2 : Milieu humide fortement arboré

C3 : Milieu humide arbustif

C4 : Milieu humide moyennement arboré

### **6.1. Sélection des intrants**

L'optimisation des paramètres externes du réseau de neurones consiste à choisir la meilleure combinaison possible d'intrants à présenter au réseau. Ceci se fait en évaluant l'effet de chaque source d'information sur la précision de la classification. Ces sources d'informations sont constituées d'une multitude d'images multi-dates et multi-angles d'incidences présentées sous différents formats : images brutes, mesures de texture, composantes principales... etc.

La sélection des intrants dans une classification par réseaux de neurones joue un rôle primordial dans l'obtention d'une classification performante (Heermann and Khazenie, 1992,

Benediktsson et Sveinsson, 1997). Dans ce projet, les intrants du réseau ont été choisis parmi un ensemble de 24 bandes de données réparties comme suit :

- Six images Radarsat-1 brutes (les trois images S1 retenues et les trois images S7).
- Dix-huit mesures de textures dérivées de ces six images (trois mesures de texture pour chaque image : la Moyenne, l'Écart Type et la Corrélation).

Plusieurs combinaisons de ces données ont été testées pour mesurer leurs effets conjugués sur la précision des résultats. Le choix de ces intrants doit tenir compte de l'apport de chaque source d'information (date d'acquisition, angle d'incidence et texture) à l'identification des classes végétales de milieux humides. L'évaluation de cet apport nécessite une compréhension préalable de la physique de l'interaction des micro-ondes radar avec la scène observée. D'autre part, le choix de la meilleure combinaison doit offrir la meilleure précision avec le minimum d'images afin de minimiser les coûts liés à l'achat des données.

Une étude préalable a été effectuée pour évaluer l'apport de chaque information en se basant sur les caractéristiques statistiques des données (§ 3.8). Ces analyses ont montré la supériorité du mode S7 dans l'identification des composantes végétales de milieux humides. Ils ont prouvé aussi l'apport significatif des mesures de la texture, et surtout la texture Moyenne, à la précision des résultats.

## **6.2. Effet du seuil de décision**

Le niveau de sortie comprend quatre neurones où chaque neurone correspond à une classe. Avec cette configuration, chaque neurone du niveau de sortie sera entraîné pour donner une valeur proche de 1 si elle correspond à la classe du pixel présenté à l'entrée du réseau ou 0 dans le cas contraire. L'utilisation de la fonction d'activation sigmoïde entre le niveau caché et le niveau de sortie donne une valeur comprise entre 0 et 1 à la sortie du réseau. Le choix d'un seuil de décision permet d'éviter une classification forcée de tous les pixels. Ainsi, si tous les neurones du niveau de sortie donnent une valeur inférieure au seuil, le pixel concerné sera classé pixel nul. Dans le cas contraire, la classe attribuée au pixel sera celle qui correspond au neurone ayant la sortie la plus élevée.

Afin d'évaluer l'effet du seuil de décision sur la performance de la classification, nous avons effectué huit tests de performance en variant le seuil de décision entre 0,2 et 0,9. Le réseau de

neurones utilisé dans ces tests est composé de trois niveaux (6-12-4) avec les paramètres internes optimisés au chapitre précédent. Les intrants du réseau sont composés de trois mesures de texture (Moyenne, Écart Type et Corrélacion) extraites de l'image S1 du mois d'août et de l'image S7 du mois d'avril.

Le tableau 6-1 présente les huit matrices de confusion calculées suite à ces tests de performance. Ces matrices montrent l'effet important du seuil de décision sur la performance de la classification. En effet, l'augmentation du seuil de décision fait décroître le nombre de pixels incorrectement classifiés qui deviennent des pixels nuls. Toutefois, cette augmentation engendre aussi une diminution du nombre de pixels correctement classifiés ce qui fait décroître la performance de la classification.

Les courbes de la figure 6-1 sont produites à partir des matrices de confusion présentées au tableau 6-1. Ces courbes montrent l'effet du seuil de décision sur les pourcentages de pixels correctement classifiés, incorrectement classifiés et non classifiés. L'effet du seuil de décision sur le comportement de ces trois catégories de pixels est semblable pour les quatre classes mais son ampleur varie d'une classe à une autre. En général, la variation du seuil de décision entre 0,2 et 0,4 a un effet négligeable sur la performance de la classification sauf pour le milieu humide fortement arboré où le pourcentage des pixels correctement classifiés diminue de 3 % entre 0,3 et 0,4 (figure 6-1c).

**TABLEAU 6-1. Effet du seuil de décision sur la performance de la classification.**

*a. Seuil = 0,2*

	C1	C2	C3	C4	Nul
C1	<b>85</b>	13	0	2	0
C2	7	<b>72</b>	0	21	0
C3	0	0	<b>92</b>	8	0
C4	0	13	8	<b>79</b>	0
Précision totale :					<b>82</b>
Coefficient Kappa :					<b>0,76</b>
$\hat{\sigma}^2(\kappa) = 13 \cdot 10^{-5}$					

*b. Seuil = 0,3*

	C1	C2	C3	C4	Nul
C1	<b>85</b>	13	0	2	0
C2	6	<b>72</b>	0	21	1
C3	0	0	<b>92</b>	8	0
C4	0	13	8	<b>79</b>	0
Précision totale :					<b>82</b>
Coefficient Kappa :					<b>0,76</b>
$\hat{\sigma}^2(\kappa) = 13 \cdot 10^{-5}$					

*c. Seuil = 0,4*

	C1	C2	C3	C4	Nul
C1	<b>84</b>	13	0	1	2
C2	6	<b>69</b>	0	19	6
C3	0	0	<b>92</b>	7	0
C4	0	13	8	<b>79</b>	0
Précision totale :					<b>81</b>
Coefficient Kappa :					<b>0,75</b>
$\hat{\sigma}^2(\kappa) = 13 \cdot 10^{-5}$					

*d. Seuil = 0,5*

	C1	C2	C3	C4	Nul
C1	<b>81</b>	8	0	0	10
C2	5	<b>65</b>	0	16	14
C3	0	0	<b>92</b>	7	1
C4	0	12	7	<b>77</b>	4
Précision totale :					<b>79</b>
Coefficient Kappa :					<b>0,73</b>
$\hat{\sigma}^2(\kappa) = 12 \cdot 10^{-5}$					

*e. Seuil = 0,6*

	C1	C2	C3	C4	Nul
C1	<b>78</b>	5	0	0	17
C2	2	<b>58</b>	0	12	28
C3	0	0	<b>90</b>	5	5
C4	0	11	4	<b>70</b>	15
Précision totale :					<b>74</b>
Coefficient Kappa :					<b>0,68</b>
$\hat{\sigma}^2(\kappa) = 12 \cdot 10^{-5}$					

*f. Seuil = 0,7*

	C1	C2	C3	C4	Nul
C1	<b>71</b>	3	0	0	26
C2	1	<b>53</b>	0	8	38
C3	0	0	<b>86</b>	3	11
C4	0	9	3	<b>60</b>	28
Précision totale :					<b>67</b>
Coefficient Kappa :					<b>0,62</b>
$\hat{\sigma}^2(\kappa) = 12 \cdot 10^{-5}$					

*g. Seuil = 0,8*

	C1	C2	C3	C4	Nul
C1	<b>65</b>	1	0	0	34
C2	1	<b>46</b>	0	2	51
C3	0	0	<b>80</b>	2	18
C4	0	5	3	<b>42</b>	50
Précision totale :					<b>58</b>
Coefficient Kappa :					<b>0,53</b>
$\hat{\sigma}^2(\kappa) = 11 \cdot 10^{-5}$					

*h. Seuil = 0,9*

	C1	C2	C3	C4	Nul
C1	<b>51</b>	0	0	0	49
C2	0	<b>35</b>	0	1	64
C3	0	0	<b>69</b>	0	31
C4	0	2	2	<b>23</b>	73
Précision totale :					<b>44</b>
Coefficient Kappa :					<b>0,41</b>
$\hat{\sigma}^2(\kappa) = 10 \cdot 10^{-5}$					

C1 : Milieu forestier

C2 : Milieu humide fortement arboré

C3 : Milieu humide arbustif

C4 : Milieu humide moyennement arboré

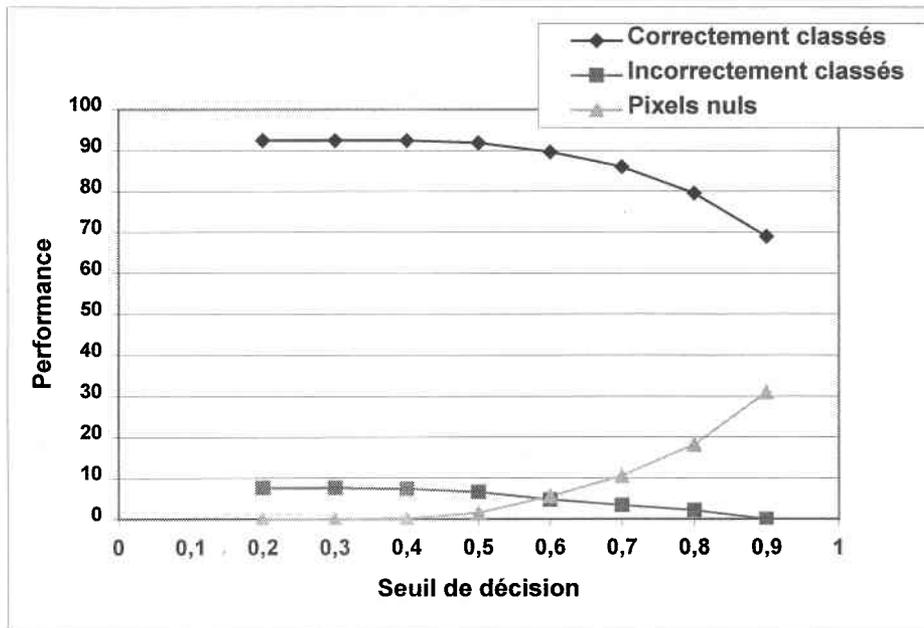


Figure 6-1a. Effet du seuil de décision : Milieu humide arbustif

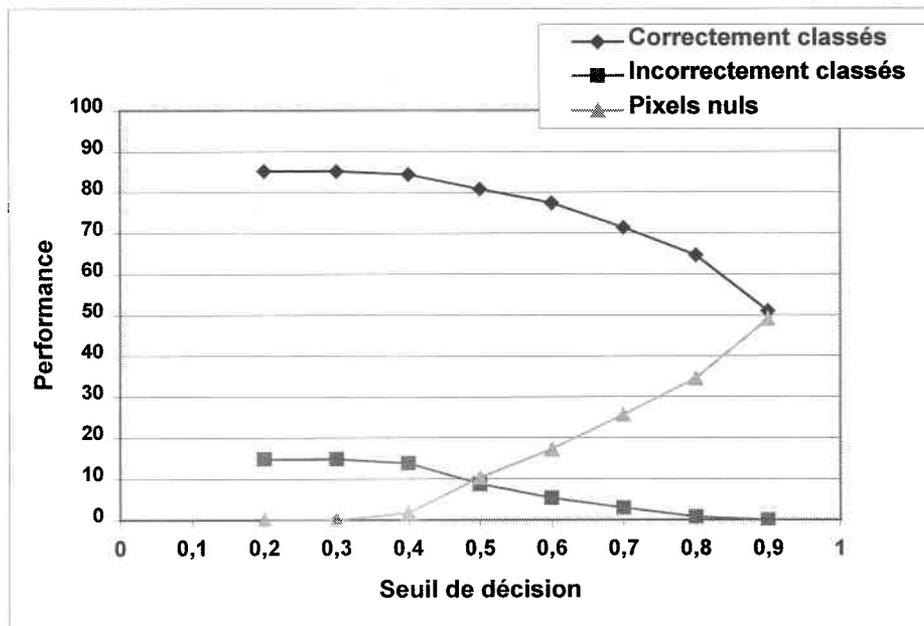
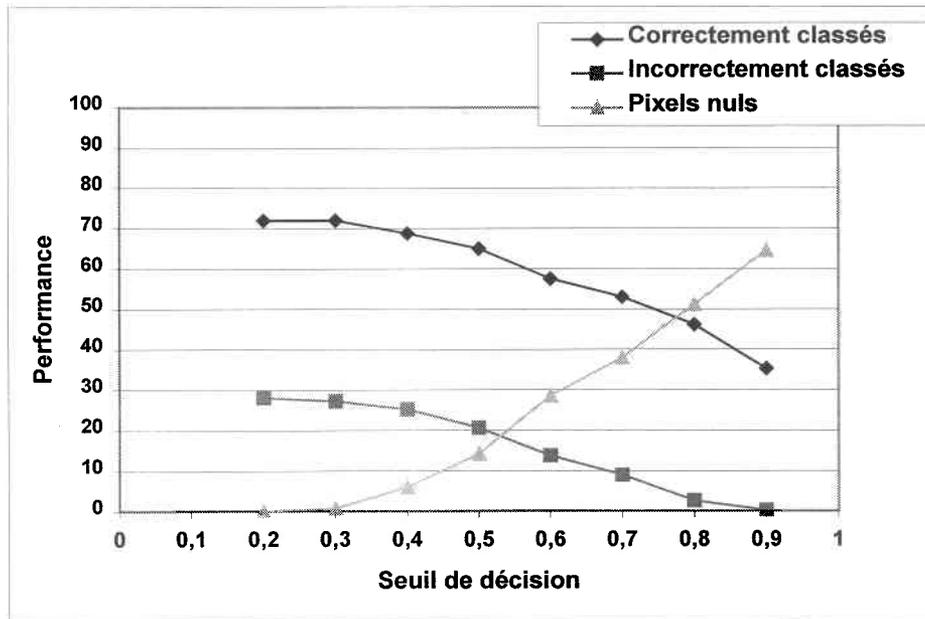
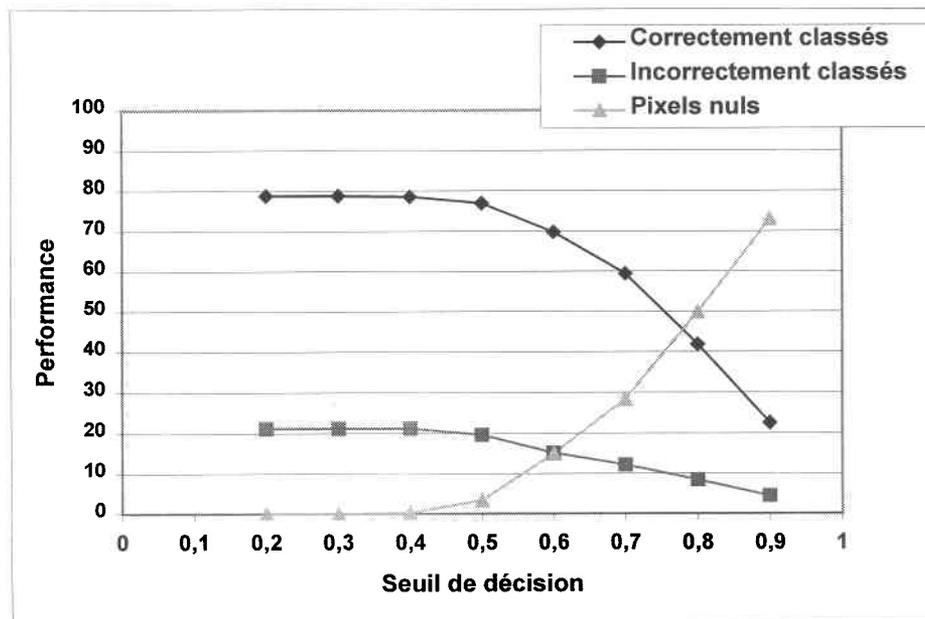


Figure 6-1b. Effet du seuil de décision : Milieu forestier



**Figure 6-1c.** Effet du seuil de décision : Milieu humide fortement arboré



**Figure 6-1d.** Effet du seuil de décision : Milieu humide moyennement arboré

L'effet de l'augmentation du seuil de décision sur la répartition des pixels devient plus visible avec des seuils supérieurs à 0,5. Au-dessus de ce seuil, la diminution du pourcentage des pixels correctement classifiés devient très rapide. Par exemple, pour les milieux humides moyennement arborés (figure 6-1d), le pourcentage de pixels correctement classifiés diminue

de 55 % (de 77 % à 23 %) en variant le seuil entre 0,5 et 0,9. Ces 55 % de pixels seront tout simplement classifiés comme pixels nuls. Cette limite de 0,5 a été utilisée par Bhattacharya et Parui (1997) pour détecter les tracés des routes dans une image SPOT.

Une deuxième évaluation de l'effet de seuil de décision a été effectuée par les statistiques-Z. Cette évaluation a permis d'évaluer les résultats obtenues avec ces différents seuils de décision ont une différence significative. Le tableau 6-2 présente les paramètres Z calculés pour des couples de seuils successifs.

**TABLEAU 6-2.** Évaluation par Statistique-Z de la similarité des classifications obtenues par différents seuils de décision.

<b>Seuils comparés</b>	<b>Staistique-Z</b>
0,2 / 0,3	<b>1,86 10<sup>-2</sup></b>
0,3 / 0,4	<b>0,68</b>
0,2 / 0,4	<b>0,66</b>
0,4 / 0,5	<b>1,42</b>
0,2 / 0,5	2,08
0,5 / 0,6	3,08
0,6 / 0,7	3,8
0,7 / 0,8	5,75
0,8 / 0,9	8,55

Les résultats présentés dans le tableau 6-2 montrent que la variation du seuil de décision entre 0,2 et 0,4 n'affecte pas d'une façon significative la précision de la classification (coefficient  $Z \leq 1,96$ ). Toutefois, la précision de la classification devient plus sensible en variant le seuil de décision au-dessus de 0,5. Les résultats obtenus par le test Z confirment bien les observations faites à partir des graphiques de la figure 6-1.

Dans ce projet, nous avons choisi un seuil égal à 0,3. Ce seuil a l'avantage de chercher la meilleure précision des pixels correctement classifiés avec une légère minimisation des pixels incorrectement classifiés. L'application ultérieure d'un filtre médian sur la classification obtenue pourra réduire le pourcentage des pixels incorrectement classifiés et améliorer la précision de la classification.

### 6.3. Optimisation des intrants

Cette section présente les résultats de classification obtenus pour différentes combinaisons d'intrants. Pour chaque combinaison, nous avons présenté l'évolution des erreurs moyennes au carré calculées à partir des groupes apprentissage et validation. Un suivi de cette évolution nous permet de comprendre le comportement du réseau face à un groupe d'intrants et de voir si le processus d'apprentissage est capable d'aboutir à une convergence de l'erreur. La performance du réseau a été aussi évaluée pour chaque combinaison avec une matrice de confusion. Cette évaluation permet de mesurer l'apport de chaque source d'information à la précision de la classification pour chaque classe.

#### 6.3.1. Six images brutes

Les deux courbes présentées dans la figure 6-2 présentent les meilleurs résultats obtenus après dix tests d'apprentissage effectués avec les six images brutes.

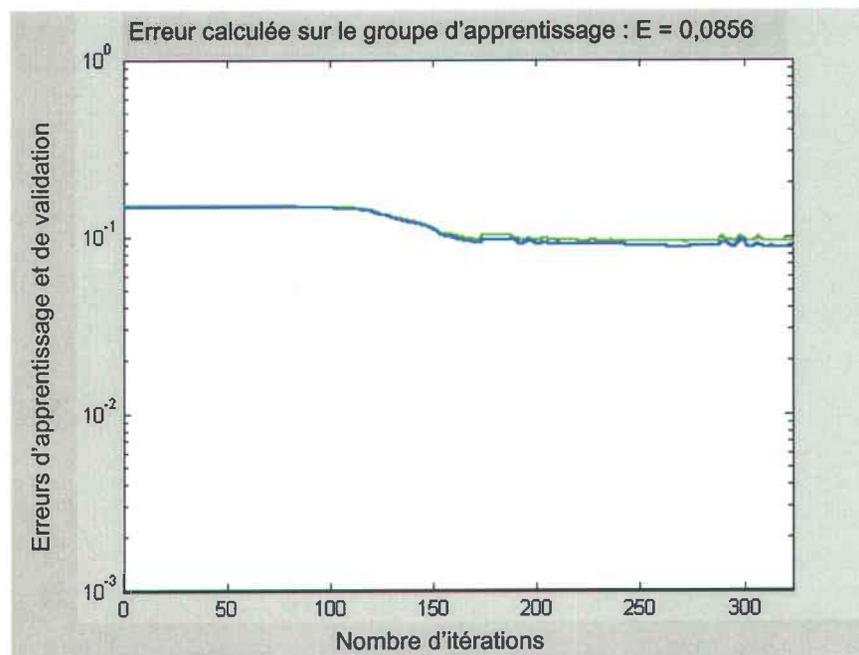


Figure 6-2. Évolution de l'apprentissage du réseau avec six images brutes.

Ces résultats montrent que l'évolution de l'erreur au cours de l'apprentissage n'aboutit pas à une convergence concluante du réseau. L'erreur moyenne au carré obtenue après 323 itérations est de l'ordre de 0,085 pour le groupe apprentissage et de 0,095 pour le groupe validation. Ceci confirme le faible potentiel des images brutes, déjà démontré par l'analyse de

séparabilité, pour la discrimination entre les composantes végétales de milieux humides (voir figure 3-14d).

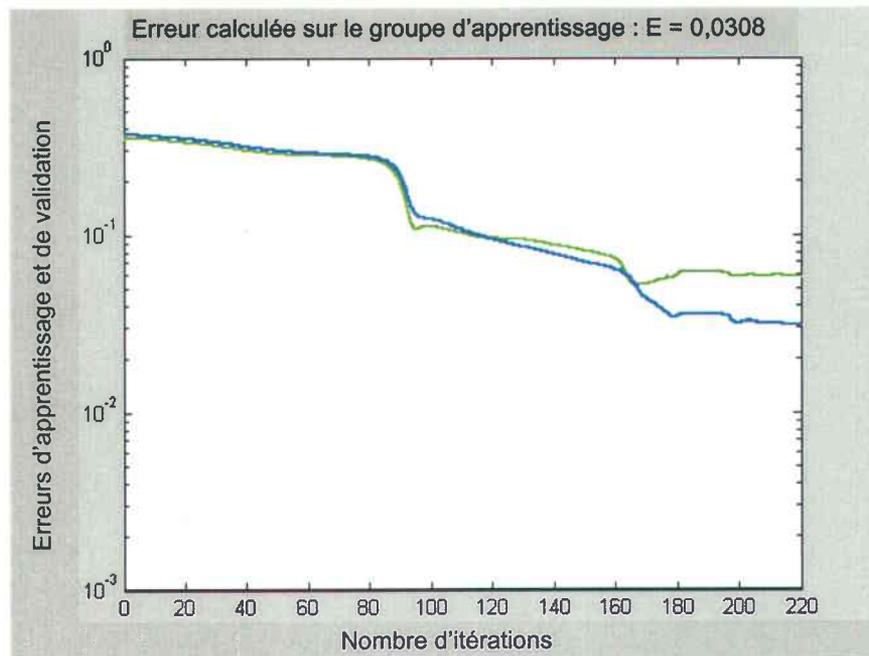
En analysant la matrice de confusion du groupe test (tableau 6-3), on voit que le réseau arrive à classifier les milieux forestiers avec une précision de 72 % et les milieux humides arbustifs avec une précision de 84 %. Toutefois, une grande confusion a été observée dans la classification du milieu humide fortement arboré qui se confond avec le milieu forestier (34 %) et le milieu humide moyennement arboré (34 %). Une grande confusion a été aussi observée pour le milieu humide moyennement arboré dont 45 % de pixels ont été confondus avec le milieu humide arbustif. Avec cette combinaison d'intrants, la précision totale de la classification (53 %) est considérée comme faible.

**TABLEAU 6-3.** Matrices de confusions obtenues avec les six images brutes.

	<i>Groupe d'apprentissage</i>					<i>Groupe test</i>					
	C1	C2	C3	C4	Nul	C1	C2	C3	C4	Nul	
C1	80	11	1	8	0	73	9	1	17	0	
C2	31	21	19	29	0	34	21	10	34	1	
C3	0	2	82	16	0	0	1	84	15	0	
C4	9	9	29	53	0	5	17	45	33	0	
Précision totale :					59	Précision totale :					52
Coefficient Kappa :					0,45	Coefficient Kappa :					0,37
$\hat{\sigma}^2(K) = 10 \cdot 10^{-5}$						$\hat{\sigma}^2(K) = 20 \cdot 10^{-5}$					

C1 : Milieu forestier                      C2 : Milieu humide fortement arboré  
C3 : Milieu humide arbustif              C4 : Milieu humide moyennement arboré

### 6.3.2. Six mesures de texture Moyenne



**Figure 6-3.** Évolution de l'apprentissage du réseau avec six mesures de la texture Moyenne.

Les courbes de la figure 6-3 montrent une bonne convergence du réseau entraîné avec six mesures de texture extraites de trois images S1 et de trois images S7. Les deux erreurs (apprentissage et validation) suivent le même cheminement au cours des 166 premières itérations avant que l'écart entre les deux erreurs commence à s'élargir. Après la 166<sup>ème</sup> itération, l'erreur du groupe apprentissage continue sa décroissance tandis que l'erreur du groupe validation commence une légère et lente ascension. Ce phénomène est dû au surentraînement du réseau. La décision d'arrêter l'apprentissage sera par conséquent prise dès que l'erreur du groupe validation enregistre une augmentation continue pendant 20 itérations successives. Ainsi, les valeurs de poids conservées pour la mesure de la performance du réseau seront celles calculées à la 166<sup>ème</sup> itération.

La comparaison entre les matrices de confusion obtenues avec six images brutes et celles obtenues à partir de six textures Moyenne (tableaux 5-2 et 5-3) montre l'apport significatif de la texture à la performance de la classification. Cet apport a été aussi observé avec une analyse de séparabilité réalisée au troisième chapitre (figures 3-14a et 3-14d). Avec cette combinaison d'intrants, la meilleure précision a été obtenue avec les milieux humides arbustifs qui ont été classés avec une précision de 94 % avec une légère confusion avec les milieux humides moyennement arborés (6 %). Cette confusion est due principalement au fait que les milieux humides moyennement arborés sont 100 % arbustifs et que la distance entre les arbres peut

dépasser parfois la taille d'un pixel. Ceci peut aussi expliquer le faible précision (63 %) qui a été enregistrée avec les milieux humides moyennement arborés. Ces milieux ont été confondus avec les milieux humides fortement arborés (20 %) et les milieux humides arbustifs (17 %).

**TABLEAU 6-4.** Matrices de confusions obtenues avec six textures Moyenne.

		<i>Groupe d'apprentissage</i>					<i>Groupe test</i>				
		C1	C2	C3	C4	Nul	C1	C2	C3	C4	Nul
C1		<b>98</b>	2	0	0	0	<b>90</b>	10	0	0	0
C2		6	<b>74</b>	2	18	0	8	<b>80</b>	1	11	0
C3		0	0	<b>97</b>	3	0	0	0	<b>94</b>	6	0
C4		0	20	15	<b>65</b>	0	0	20	17	<b>62</b>	0
		Précision totale :				<b>83</b>	Précision totale :				<b>82</b>
		Coefficient Kappa :				<b>0,78</b>	Coefficient Kappa :				<b>0,75</b>
		$\hat{\sigma}^2(K) = 6 \cdot 10^{-5}$					$\hat{\sigma}^2(K) = 13 \cdot 10^{-5}$				
C1 : Milieu forestier							C2 : Milieu humide fortement arboré				
C3 : Milieu humide arbustif							C4 : Milieu humide moyennement arboré				

Une bonne précision a aussi été enregistrée avec le milieu forestier (90 %). Tous les pixels forêt restants (10 %) ont été confondus avec les milieux humides fortement arborés. Cette confusion peut être expliquée par la ressemblance physiologique qui existe entre ces deux milieux. En effet, la théorie de l'interaction entre les micro-ondes radar et les milieux humides (§ 3.4) a montré que les images acquises avec un faible angle d'incidence (S1) sont plus influencées par l'humidité du sol et sont capables de discriminer entre un milieu forestier et un milieu humide fortement arboré. À mon avis, ce 10 % de confusion est probablement dû à la forte densité de la couverture arborée dans quelques zones de milieux humides qui limite l'interaction des micro-ondes radar avec l'humidité du sol.

### 6.3.3. Six mesures de texture Écart type.

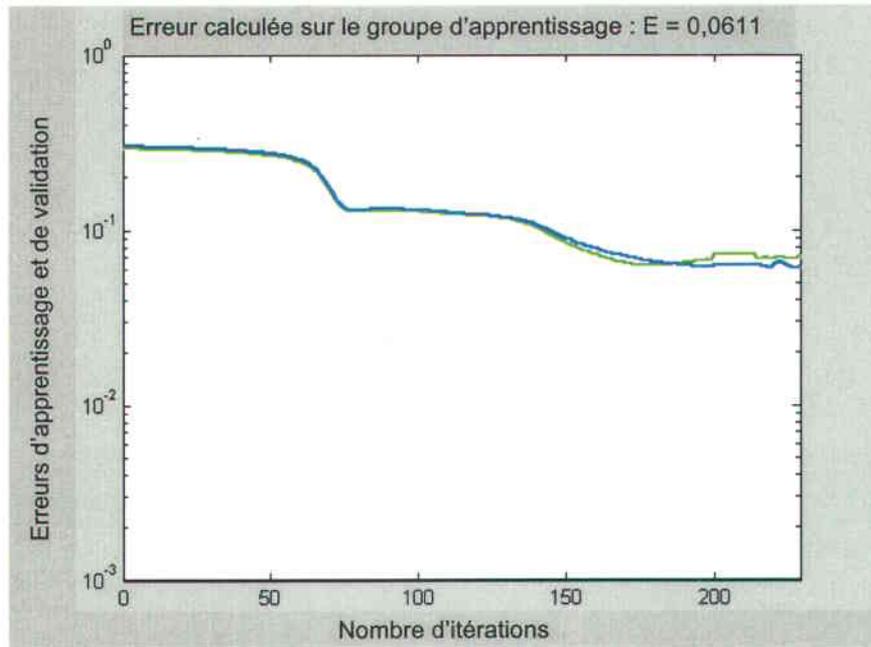


Figure 6-4. Évolution de l'apprentissage du réseau avec six mesures de la texture Écart Type.

Les deux courbes de la figure 6-4 montrent une convergence moins concluante que celle obtenue avec les textures Moyenne (figure 6-3). L'erreur optimale a été enregistrée à la 180<sup>ème</sup> itération. Cette erreur (~0,06) est semblable pour les deux groupes de pixels (apprentissage et validation).

TABLEAU 6-5. Matrices de confusions obtenues avec six textures Écart Type.

	Groupe d'apprentissage					Groupe test					
	C1	C2	C3	C4	Nul	C1	C2	C3	C4	Nul	
C1	72	11	0	16	0	85	8	0	7	0	
C2	17	71	2	10	0	33	53	4	10	0	
C3	0	0	92	8	0	0	0	86	14	0	
C4	20	3	18	58	1	11	6	13	70	0	
Précision totale :					73	Précision totale :					73
Coefficient Kappa :					0,64	Coefficient Kappa :					0,65
$\hat{\sigma}^2(K) = 9 \cdot 10^{-5}$						$\hat{\sigma}^2(K) = 17 \cdot 10^{-5}$					

C1 : Milieu forestier

C2 : Milieu humide fortement arboré

C3 : Milieu humide arbustif

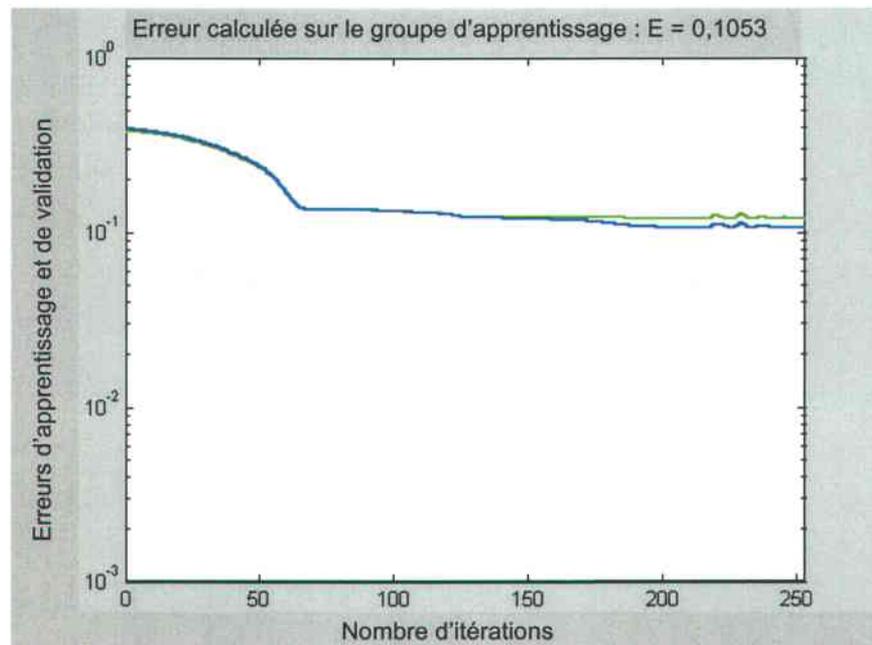
C4 : Milieu humide moyennement arboré

La précision totale obtenue avec les six textures Écart Type (tableau 6-5) est nettement inférieure à celle obtenue avec la texture Moyenne (tableau 6-4) 74 % contre 82 %. Le seul

point positif a été observé pour le milieu humide moyennement arboré qui a enregistré une précision légèrement supérieure à la texture Moyenne (70 % contre 63 %). Toutefois, cette amélioration apporte une nouvelle confusion entre les milieux humides moyennement arborés et les milieux forestiers (12 %). Cette confusion était nulle avec la texture Moyenne. La supériorité de la texture Moyenne par rapport à la texture Écart Type a été aussi constatée après une analyse de séparabilité (§ 3.8).

#### 6.3.4. Six mesures de texture Corrélation

Une combinaison d'intrants avec six textures Corrélation n'apporte aucune amélioration à la performance de la classification. Les courbes de la figure 6-5 montrent que le réseau n'arrive pas à converger et que l'erreur moyenne au carré n'a pas pu descendre sous la barre de 0,1. Les matrices de confusion (tableau 6-6) montrent aussi la faiblesse de cette combinaison d'intrants où seulement 34 % de pixels ont été bien classés. Le faible pouvoir discriminatoire de la texture Corrélation a été aussi démontré suite à une analyse de séparabilité (§ 3.8).



**Figure 6-5.** Évolution de l'apprentissage du réseau avec six mesures de la texture Corrélation.

**TABLEAU 6-6.** Matrices de confusions obtenues avec six textures Corrélation.

	Groupe d'apprentissage					Groupe test					
	C1	C2	C3	C4	Nul	C1	C2	C3	C4	Nul	
C1	38	6	26	29	1	23	9	32	35	1	
C2	10	51	16	23	1	7	39	26	28	0	
C3	24	8	44	23	1	34	10	24	31	1	
C4	23	19	17	40	1	26	16	9	48	1	
Précision totale :					<b>43</b>	Précision totale :					<b>34</b>
Coefficient Kappa :					<b>0,25</b>	Coefficient Kappa :					<b>0,12</b>
$\hat{\sigma}^2(K) = 10 \cdot 10^{-5}$						$\hat{\sigma}^2(K) = 19 \cdot 10^{-5}$					

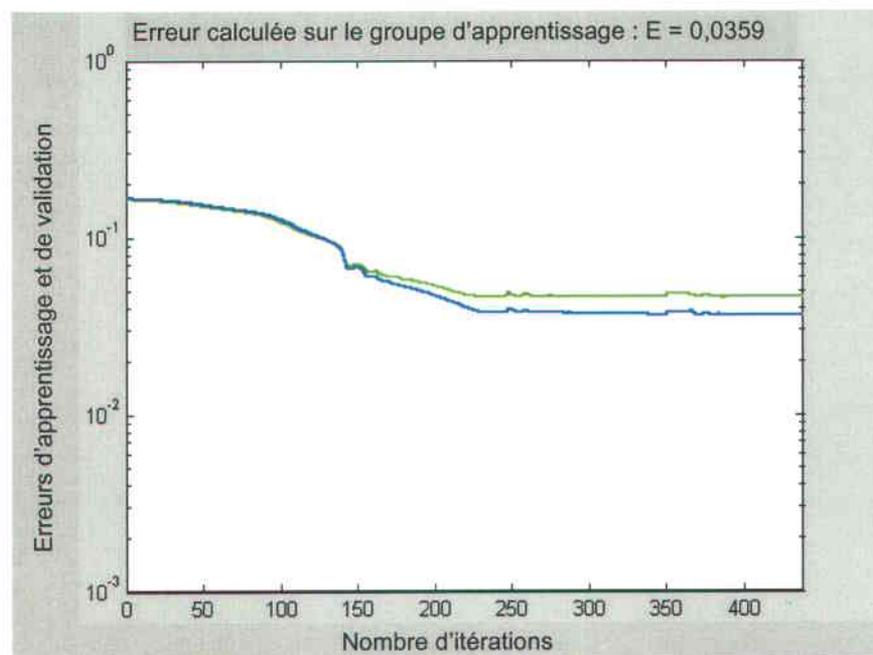
C1 : Milieu forestier

C2 : Milieu humide fortement arboré

C3 : Milieu humide arbustif

C4 : Milieu humide moyennement arboré

### 6.3.5. Trois textures moyennes extraites de trois images S7



**Figure 6-6.** Évolution de l'apprentissage du réseau avec 3 textures moyennes extraites des trois images S7.

La figure 6-6 présente le processus d'apprentissage pour le réseau de neurones entraîné avec trois textures Moyenne extraites de trois images S7. Le choix de la texture Moyenne pour évaluer l'effet de l'angle d'incidence sur la performance de la classification a été essentiellement motivé par les résultats des trois tests précédents (tableaux 6-4, 6-5 et 6-6). La supériorité de la

texture Moyenne a été aussi démontrée suite à une analyse de séparabilité effectuée au quatrième chapitre (figures 3-14a,b,c et d).

La précision obtenue avec cette combinaison est jugée acceptable (0,036 pour le groupe apprentissage et 0,045 pour le groupe validation). La comparaison entre la précision obtenue avec cette combinaison d'intrants (tableau 6-7) et celle obtenue avec les six textures Moyenne (tableau 6-4) montre que l'exclusion des images S1 n'affecte pas la précision totale de la classification (82 % avec les six images S1 et S7 contre 81 % avec des images S7 seules). En plus, une nette amélioration a été observée pour les milieux humides moyennement arborés dont la précision de la classification est passée de 63 % pour les six images S1 et S7 à 79 % pour les trois images S7.

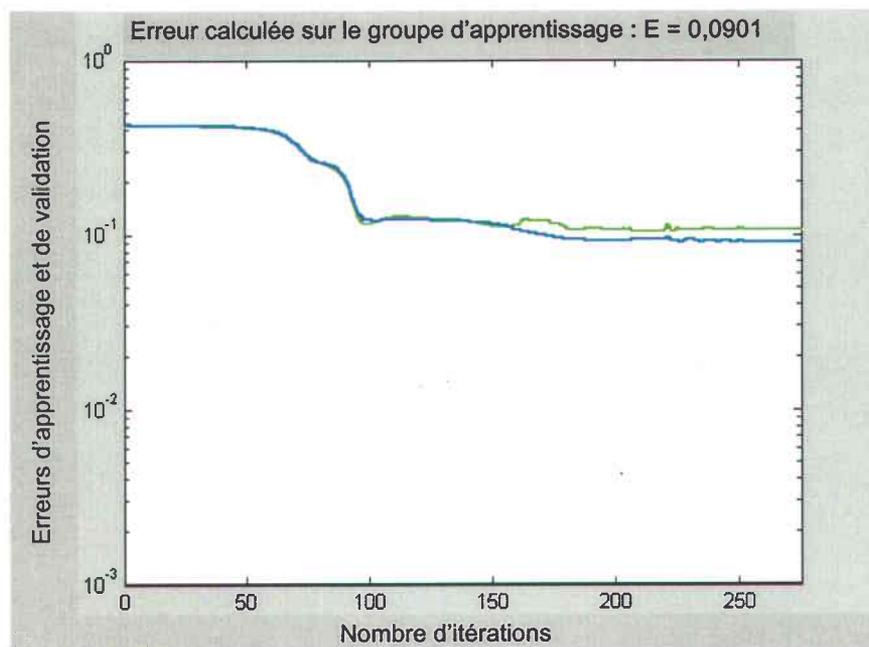
Toutefois, une classification avec des images S7 seules donne plus de confusion pour le milieu forestier qui devient plus exposé à se confondre avec les milieux humides fortement arborés (10 % de confusion avec les six images contre 18 % de confusion avec des images S7 seules). Cette observation confirme le pouvoir discriminatoire des images S1 entre les milieux forestiers et les milieux humides fortement arborés. Cet avantage du mode S1 a été théoriquement démontré au troisième chapitre en se basant sur l'effet de l'angle d'incidence sur la détection de l'humidité du sol. Ce pouvoir discriminatoire du mode S1 n'a pas été détecté avec l'analyse statistique de séparabilité (voir figure 3-14a).

**TABLEAU 6-7.** Matrices de confusions obtenues avec trois textures Moyenne (S7).

		<i>Groupe d'apprentissage</i>					<i>Groupe test</i>				
		C1	C2	C3	C4	Nul	C1	C2	C3	C4	Nul
C1		97	3	0	0	0	82	18	0	0	0
C2		6	71	1	21	1	5	80	1	14	0
C3		0	0	94	6	0	0	0	85	15	0
C4		0	14	10	76	0	0	14	7	79	0
		Précision totale :				84	Précision totale :				81
		Coefficient Kappa :				0,79	Coefficient Kappa :				0,75
		$\hat{\sigma}^2(K) = 5 \cdot 10^{-5}$					$\hat{\sigma}^2(K) = 13 \cdot 10^{-5}$				
C1 : Milieu forestier							C2 : Milieu humide fortement arboré				
C3 : Milieu humide arbustif							C4 : Milieu humide moyennement arboré				

### 6.3.6. Trois textures moyennes extraites des trois images S1

La figure 6-7 montre l'évolution de l'erreur d'apprentissage et de validation du réseau de neurones avec des intrants composés de trois textures Moyenne extraites de trois images S1. L'évolution de ces erreurs montre que le réseau n'a pas pu converger et l'erreur moyenne au carrée du groupe validation n'a pas pu descendre au-dessous de la barre de 0,1. Ces résultats sont largement inférieurs à ceux obtenus avec les trois images S7 (figure 6-6).



**Figure 6-7.** Évolution de l'apprentissage du réseau avec 3 textures moyennes extraites des trois images S1.

Les précisions obtenues avec une combinaison de trois textures Moyenne S1 (tableau 6-8) sont largement inférieures à celles obtenues avec les trois textures Moyenne S7 (tableau 6-7). La plus faible précision a été enregistrée avec les milieux humides moyennement arborés dont uniquement 3 % de pixels ont été correctement classifiés. 61 % de ces pixels ont été incorrectement classifiés comme milieux humides arbustifs. L'autre faible précision a été observée avec les milieux humides fortement arborés (35 %). Ces milieux ont été principalement confondus avec le milieu forestier (48 % des milieux humides fortement arborés ont été classés comme milieu forestier). Cette faible précision est due principalement à la forte sensibilité du mode S1 à l'humidité du sol et de la végétation des milieux humides. Cette sensibilité sature le signal et diminue le pouvoir discriminatoire du mode S1. Ainsi, le signal à

faible angle d'incidence sera moins sensible à la variation physiologique de la végétation des milieux humides.

Le seul point positif de cette combinaison d'intrants est la bonne précision (92 %) enregistrée pour le milieu forestier. Cette précision est supérieure à celle enregistrée avec les six textures Moyenne (3 S1 et 3 S7). Cette observation confirme une autre fois la supériorité du mode S1 dans la discrimination entre les milieux forestiers et les milieux humides toutes catégories incluses. Dans ce cas, la sensibilité du mode S1 à l'humidité joue un rôle positif dans la discrimination de ces deux milieux.

**TABLEAU 6-8.** Matrices de confusions obtenues avec trois textures Moyenne (S1).

	<i>Groupe d'apprentissage</i>					<i>Groupe test</i>					
	C1	C2	C3	C4	Nul	C1	C2	C3	C4	Nul	
C1	89	8	0	3	0	92	7	0	1	0	
C2	20	51	28	1	0	48	35	15	2	0	
C3	1	16	81	2	0	2	12	84	2	0	
C4	51	22	18	9	0	6	31	60	3	0	
Précision totale :					57	Précision totale :					53
Coefficient Kappa :					0,43	Coefficient Kappa :					0,38
$\hat{\sigma}^2(K) = 9 \cdot 10^{-5}$						$\hat{\sigma}^2(K) = 17 \cdot 10^{-5}$					

C1 : Milieu forestier

C2 : Milieu humide fortement arboré

C3 : Milieu humide arbustif

C4 : Milieu humide moyennement arboré

### 6.3.7. Trois textures pour l'image S1 et trois textures pour l'image S7

Le choix de cette combinaison entre dans le cadre de la recherche du meilleur compromis économique qui offre une classification la plus performante possible avec un nombre minimal d'images. Le choix d'une image S1 (du mois d'août) et d'une image S7 (du mois d'avril) repose sur la complémentarité physique qui existe entre ces deux modes d'acquisition (§ 2.6). L'utilisation de la texture offre une dimension supplémentaire au pouvoir discriminatoire du réseau de neurones et compense la réduction de la taille des intrants. Le choix de la texture Moyenne, Écart Type et Corrélation a été basé sur une analyse préalable de corrélation (§ 3-7.5).

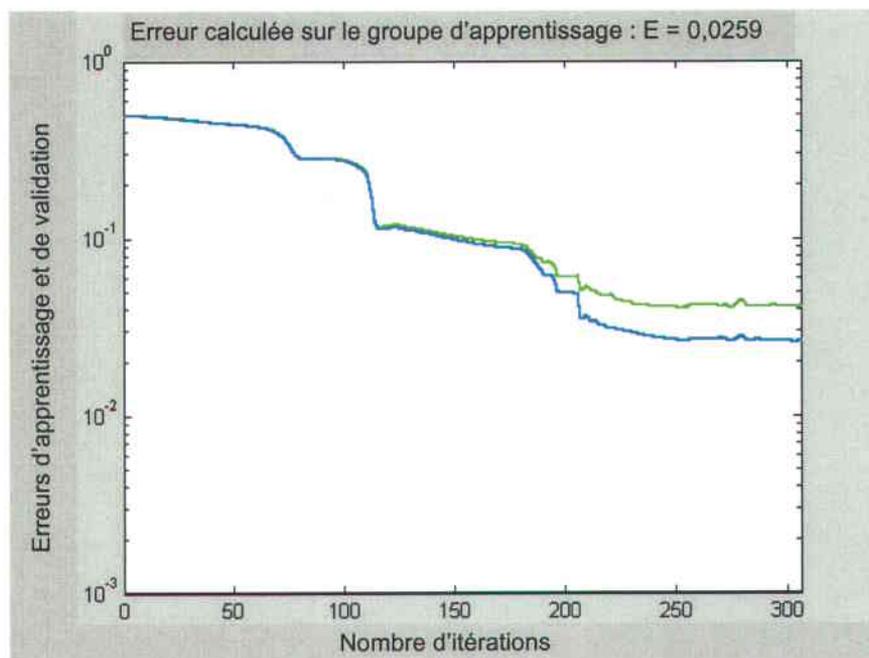


Figure 6-8. Évolution de l'apprentissage du réseau avec 6 textures (3 S1 et 3 S7).

La figure 6-8 montre que le réseau a obtenu une bonne convergence et atteint une erreur très satisfaisante (~ 0,03 pour le groupe validation). Cette erreur est supérieure à celles obtenues avec les six combinaisons précédentes.

TABLEAU 6-9. Matrices de confusions obtenues avec 3 textures S1 et 3 textures S7.

		Groupe d'apprentissage					Groupe test				
		C1	C2	C3	C4	Nul	C1	C2	C3	C4	Nul
C1		<b>98</b>	2	0	0	0	<b>84</b>	15	0	0	1
C2		5	<b>81</b>	0	14	0	10	<b>78</b>	0	11	1
C3		0	0	<b>95</b>	5	0	0	0	<b>94</b>	6	0
C4		1	7	9	<b>83</b>	0	0	12	9	<b>79</b>	0
		Précision totale :				<b>89</b>	Précision totale :				<b>84</b>
		Coefficient Kappa :				<b>0,86</b>	Coefficient Kappa :				<b>0,78</b>
		$\hat{\sigma}^2(K) = 4 \cdot 10^{-5}$					$\hat{\sigma}^2(K) = 12 \cdot 10^{-5}$				

C1 : Milieu forestier

C2 : Milieu humide fortement arboré

C3 : Milieu humide arbustif

C4 : Milieu humide moyennement arboré

La précision enregistrée avec cette combinaison d'intrants est très satisfaisante (précision totale de 84 %). Elle est même supérieure à celles obtenues avec les six images (82 %) ou avec les trois images S7 (82 %). La meilleure précision a été observée avec les milieux humides arbustifs (94 %). Cette précision est semblable à celle obtenue avec les six images (3 S1 et 3

S7) en texture Moyenne. Le principal point négatif de cette combinaison est le 15 % de pixels du milieu forestier qui ont été classés comme milieux humides fortement arborés.

### 6.3.8. Deux textures pour l'image S1 et deux textures pour l'image S7.

La réalisation d'une analyse de séparabilité avant la classification permet d'évaluer *à priori* l'apport de chaque source d'information à la performance de la classification. Une analyse de séparabilité effectuée au quatrième chapitre (§ 3-8) a montré le faible pouvoir discriminatoire de la texture corrélation. Dans cette analyse, l'indice de séparabilité (équation 3-14) n'a pas dépassé 0,5 pour les six images testées (figure 3-14c). En effet, même si l'ajout de cette mesure de texture n'exige aucun coût supplémentaire, son enlèvement apporte un allègement significatif de la taille du réseau et un gain considérable au temps d'apprentissage et de classification. Il est important donc de voir si l'ajout de la texture corrélation apportait une amélioration à la précision des résultats.

Afin d'évaluer cet apport, nous avons effectué plusieurs tests d'apprentissage avec uniquement la texture Moyenne et la texture Corrélation. Ces tests ont montré que la suppression de la texture Corrélation du processus d'apprentissage affecte légèrement la précision totale de la classification.

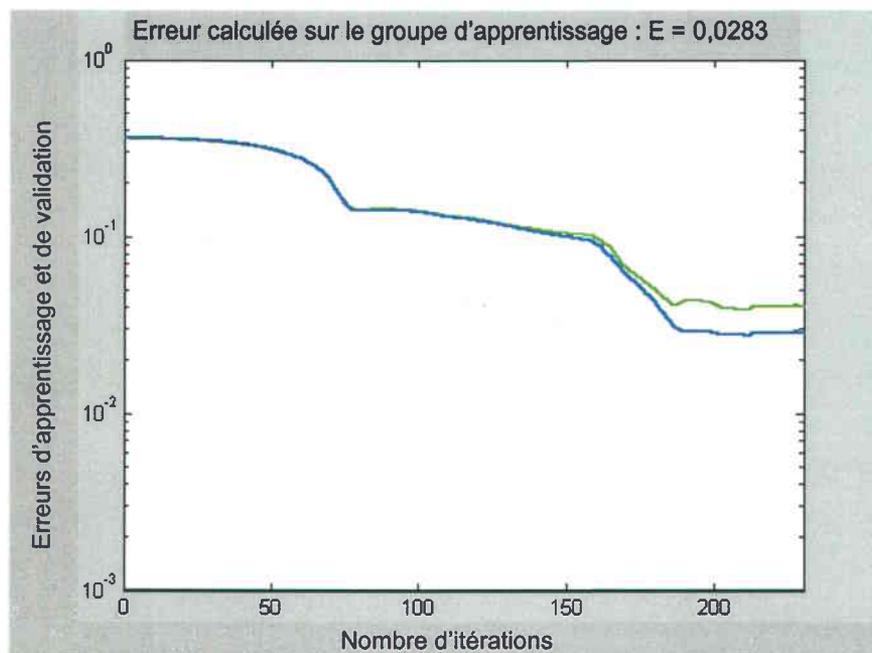


Figure 6-9. Évolution de l'apprentissage du réseau avec 4 textures (2 S1 et 2 S7).

La figure 6-9 montre que le réseau a obtenu une bonne convergence et une erreur satisfaisante ( $\sim 0,035$  pour le groupe validation). Cette erreur est à peine inférieure à celle obtenue avec la combinaison précédente (trois textures par image) qui est de l'ordre de 0,03.

**TABLEAU 6-10.** Matrices de confusions obtenues avec 2 textures S1 et 2 textures S7.

		<i>Groupe d'apprentissage</i>					<i>Groupe test</i>				
		C1	C2	C3	C4	Nul	C1	C2	C3	C4	Nul
C1		<b>96</b>	4	0	0	0	<b>82</b>	18	0	0	0
C2		4	<b>80</b>	0	16	0	5	<b>86</b>	0	9	0
C3		0	0	<b>94</b>	6	0	0	0	<b>93</b>	7	0
C4		1	8	8	<b>83</b>	0	0	11	14	<b>75</b>	0
		Précision totale :				<b>88</b>	Précision totale :				<b>84</b>
		Coefficient Kappa :				<b>0,84</b>	Coefficient Kappa :				<b>0,79</b>
		$\sigma^2(K) = 5 \cdot 10^{-5}$					$\sigma^2(K) = 12 \cdot 10^{-5}$				

C1 : Milieu forestier

C2 : Milieu humide fortement arboré

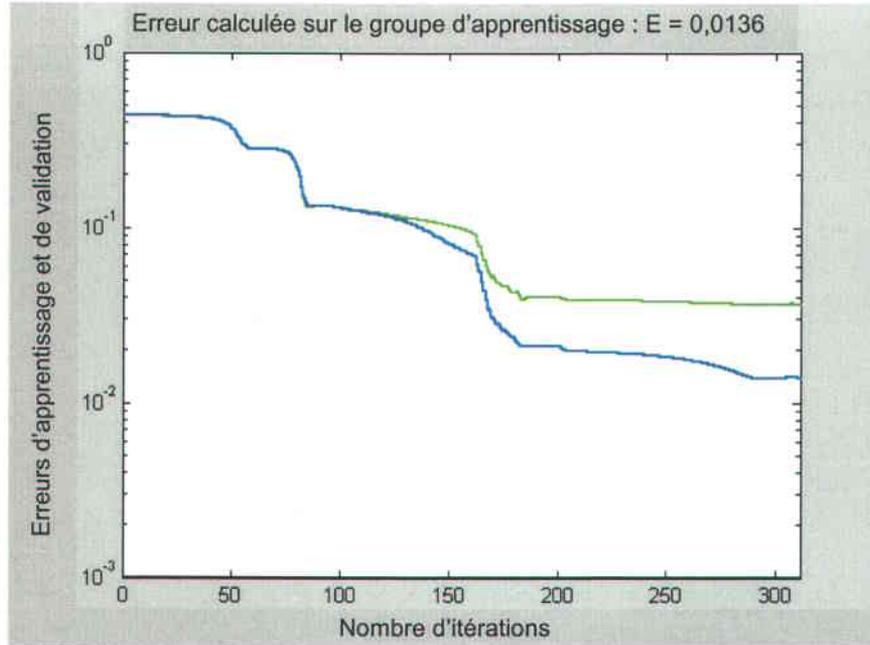
C3 : Milieu humide arbustif

C4 : Milieu humide moyennement arboré

Une comparaison entre les deux matrices de confusion présentées aux tableaux 6-9 et 6-10 montre que la suppression de la texture corrélation améliore la discrimination entre le milieu forestier et le milieu humide fortement arboré de  $\sim 7\%$  et dégrade les autres précisions de 2 à 4 %.

### 6.3.9. Dix-huit mesures de texture (3 par image)

Cette combinaison offre la meilleure précision (0,013 pour le groupe d'apprentissage et 0,028 pour le groupe validation). Toutefois, la lourde architecture de ce réseau (18-36-4) rend l'apprentissage très lent.



**Figure 6-10.** Évolution de l'apprentissage du réseau avec 18 textures (3 par image).

Les matrices de confusion présentées au tableau 6-11 montrent que l'amélioration de la précision n'est pas proportionnelle à la quantité d'informations fournies au réseau. Ainsi, un réseau entraîné par 18 bandes d'informations (extraites de 6 images) donne une précision à peine supérieure (2 %) à un réseau entraîné par 6 mesures de texture (extraites de 2 images).

**TABLEAU 6-11.** Matrices de confusions obtenues avec 18 textures (3 par image).

		<i>Groupe d'apprentissage</i>					<i>Groupe test</i>				
		C1	C2	C3	C4	Nul	C1	C2	C3	C4	Nul
C1		<b>99</b>	1	0	0	0	<b>87</b>	10	0	2	1
C2		2	<b>91</b>	1	6	0	9	<b>77</b>	0	13	1
C3		0	0	<b>99</b>	1	0	0	0	<b>96</b>	4	0
C4		1	4	2	<b>93</b>	0	0	9	8	<b>83</b>	0
		Précision totale :				<b>95</b>	Précision totale :				<b>86</b>
		Coefficient Kappa :				<b>0,94</b>	Coefficient Kappa :				<b>0,81</b>
		$\hat{\sigma}^2(K) = 2 \cdot 10^{-5}$					$\hat{\sigma}^2(K) = 11 \cdot 10^{-5}$				

C1 : Milieu forestier

C2 : Milieu humide fortement arboré

C3 : Milieu humide arbustif

C4 : Milieu humide moyennement arboré

### 6.3.10. Deux composantes principales

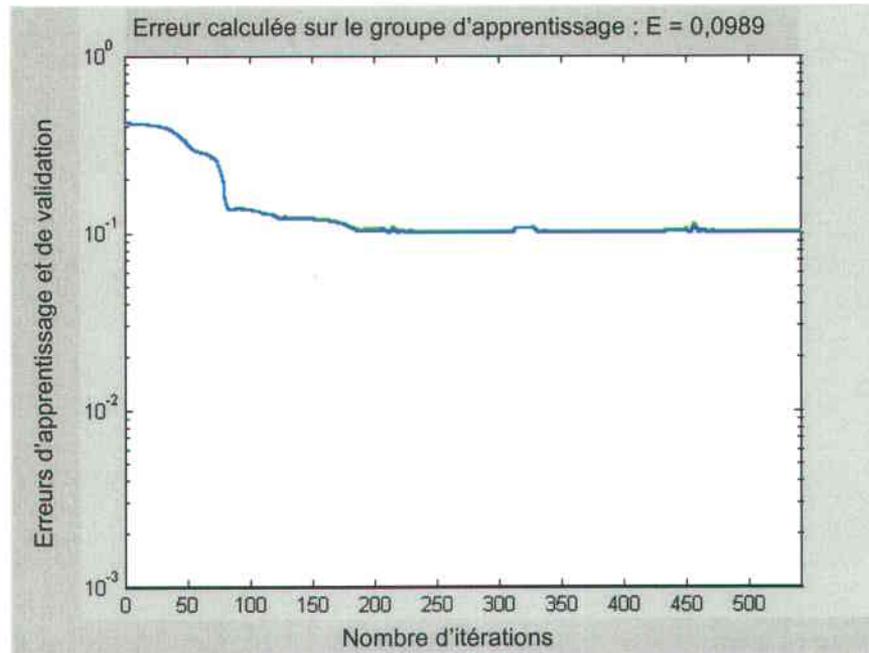


Figure 6-11. Évolution de l'apprentissage du réseau avec deux composantes principales.

Ce test a permis de vérifier si la transformation des données disponibles en composantes principales apporte une amélioration à la précision des résultats.

TABLEAU 6-12. Matrices de confusions obtenues avec deux composantes principales.

	Groupe d'apprentissage					Groupe test					
	C1	C2	C3	C4	Nul	C1	C2	C3	C4	Nul	
C1	83	4	0	13	0	76	5	1	18	0	
C2	43	5	18	34	0	45	7	11	37	0	
C3	4	2	58	36	0	3	2	62	33	0	
C4	20	6	24	50	0	16	3	35	46	0	
Précision totale :					49	Précision totale :					47
Coefficient Kappa :					0,32	Coefficient Kappa :					0,3
$\hat{\sigma}^2(K) = 9 \cdot 10^{-5}$						$\hat{\sigma}^2(K) = 19 \cdot 10^{-5}$					

C1 : Milieu forestier

C2 : Milieu humide fortement arboré

C3 : Milieu humide arbustif

C4 : Milieu humide moyennement arboré

Les résultats obtenus (tableau 6-12) ont montré que ce genre de transformation n'a aucun apport positif à la précision de la classification. En effet, Benediktsson et Sveinsson (1997) ont trouvé aussi que la réduction des neurones au niveau d'entrée en utilisant la composante principale n'apporte pas une grande amélioration à la précision de la classification. Cette

amélioration a resté inférieure à 1% pour toute les combinaisons utilisées. Dans notre cas, la précision obtenue avec les deux composantes principales est plus ou moins semblable à celle obtenue avec les six images brutes. Toutefois, cette précision reste de loin inférieure à celle obtenue avec six mesures textures extraites d'une image S1 et d'une image S7.

### **6.3.11. Évaluation des combinaisons d'intrants**

Fitzgerald et Lees (1994) ont évalué le degré d'exactitude d'une classification en plaçant le coefficient Kappa dans l'un de trois intervalles suivants :

$K < 0,4 \Rightarrow$  faible performance.

$0,4 \leq K < 0,75 \Rightarrow$  bonne performance.

$K \geq 0,75 \Rightarrow$  excellente performance.

Un résumé des précisions obtenues avec les dix combinaisons testées est présenté au tableau 6-13. Les combinaisons qui ont donné un coefficient Kappa supérieur à 0,75 pour le groupe test sont présentées en Gras.

Le seuil de  $K = 0,75$  a été atteint pour cinq combinaisons :

- Combinaison 2  $\Rightarrow$  Six textures Moyenne (3 S1 et 3 S7).
- Combinaison 5  $\Rightarrow$  Trois textures Moyenne (3 S7).
- Combinaison 7  $\Rightarrow$  Six textures : Moyenne, Écart Type et Corrélacion (S1 août et S7 avril).
- Combinaison 8  $\Rightarrow$  Quatre textures : Moyenne et Écart Type(S1 août et S7 avril).
- Combinaison 9  $\Rightarrow$  Dix-huit textures : Moyenne, Écart Type et Corrélacion (3 S1 et 3 S7).

Un test Z a été effectué entre ces cinq combinaisons pour évaluer s'il existe une différence significative entre eux. Ce test va permettre de juger, objectivement, si l'ajout d'une information supplémentaire (une texture ou une image) apporte une amélioration à la précision de la classification. Cette évaluation permet d'économiser sur le nombre d'images utilisées dans le processus de classification. Les résultats de ce test sont présentés dans le tableau 6-14.

**TABLEAU 6-13.** Tableau récapitulatif des résultats obtenus pour les différentes combinaisons d'intrants.

Combinaisons d'intrants		Groupe apprentissage			Groupe test			Perf. <sup>a</sup>
		Précision totale	Coefficient Kappa	$\hat{\sigma}^2(K) \times 10^5$	Précision totale	Coefficient Kappa	$\hat{\sigma}^2(K) \times 10^5$	
1	Six images brutes (3 S1 et 3 S7)	59	0,45	10	53	0,37	20	F
2	Six textures Moyenne (3 S1 et 3 S7)	84	0,78	6	82	<b>0,76</b>	13	E
3	Six textures Écart Type (3 S1 et 3 S7)	73	0,64	8	74	0,65	17	B
4	Six textures Corrélation (3 S1 et 3 S7)	43	0,25	11	34	0,12	19	F
5	Trois textures Moyenne (3 S7)	84	0,79	6	82	<b>0,75</b>	13	E
6	Trois textures Moyenne (3 S1)	57	0,43	9	53	0,38	17	F
7	Six textures : Moyenne, Écart Type et Corrélation (S1 août et S7 avril)	89	0,86	4	84	<b>0,78</b>	12	E
8	Quatre textures : Moyenne et Écart Type (S1 août et S7 avril)	88	0,84	5	84	<b>0,78</b>	12	E
9	Dix huit textures : Moyenne, Écart Type et Corrélation (3 S1 et 3 S7)	95	0,94	2	86	<b>0,81</b>	11	E
10	Deux composantes principales (3 S1) et (3 S7)	49	0,32	9	47	0,30	19	F

<sup>a</sup> F : Faible performance, B : Bonne performance, E : Excellente performance

Avec un coefficient  $Z = 0,32$  ( $< 1,96$ ), le premier test montre que l'ajout des trois textures Moyenne dérivées de trois images S1 n'apportent aucune amélioration à la précision obtenue uniquement avec les textures Moyenne dérivées de trois images S7.

Le test 2 montre que l'utilisation de six mesures de textures dérivées à partir d'une image S1 et d'une image S7 (combinaison 7) offre une précision comparable à une combinaison de six textures dérivées de six images (combinaison 2).

Le test 4 montre que l'ajout de la texture Corrélation n'a aucun effet sur la précision finale de la classification. En effet, même si l'ajout d'une mesure de texture ne nécessite pas des dépenses

supplémentaires (pas de nouvelles acquisitions d'images), la suppression de textures inutiles diminue considérablement le temps nécessaire pour la classification (entraînement et apprentissage).

Les deux tests 5 et 6 confirment aussi que l'utilisation d'une image S1 et d'une image S7 donnent des précisions comparables à celles obtenues avec six images (3 S1 et 3 S7).

Avec un coefficient  $Z = 2,25 (> 1,96)$ , le test 8 montre que l'utilisation d'une image S1 et d'une image S7 donne une précision supérieure à celle obtenue avec les trois images S7.

**TABLEAU 6-14.** Évaluation des précisions par un test Z

Tests	Combinaisons	Statistique-Z	Résultat <sup>a</sup>
1	2 vs 5	0,32	NS <sup>b</sup>
2	2 vs 7	1,82	NS
3	2 vs 9	3,58	S
4	7 vs 8	0,11	NS
5	7 vs 9	1,74	NS
6	8 vs 9	1,64	NS
7	5 vs 8	2,25	S

<sup>a</sup> avec un niveau de confiance de 95 %

<sup>b</sup> NS : différence non significative, S : différence significative

#### **6.4. Comparaison des résultats avec celles obtenus avec la méthode du maximum de vraisemblance.**

Une classification par maximum de vraisemblance a été effectuée avec une combinaison d'intrants en texture Moyenne et Écart Type. Au total, 6000 pixels ont été utilisés comme sites d'entraînement (1500 pixels par classe). Nous avons utilisé les mêmes pixels utilisés pour l'apprentissage et la validation des réseaux de neurones pour pouvoir comparer, objectivement, les précisions obtenues par les deux méthodes de classification. Les résultats obtenus seront comparés par la suite d'une façon descriptive et analytique.

#### **6.4.1. Comparaison descriptive des résultats**

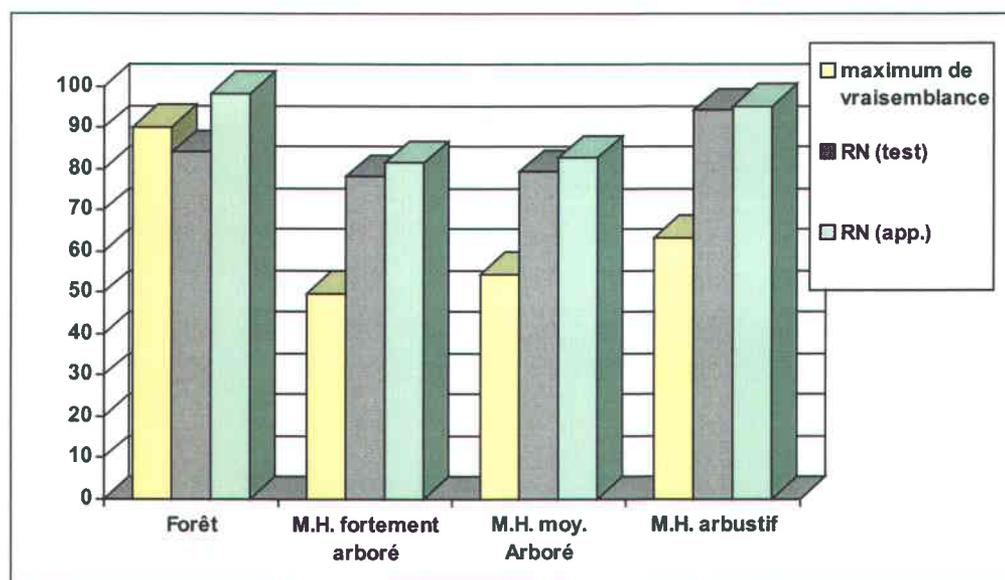
Le tableau 6-15, montre les trois matrices de confusions obtenues avec trois combinaisons d'intrants : 3 images S1 (en textures Moyenne), 3 images S7 (en texture Moyenne) et une image S1 (août) et une image S7 (avril) en textures Moyenne et Écart Type. Les trois combinaisons d'intrants utilisées dans ce test de comparaison correspondent aux combinaisons 5, 6 et 8 présentées au tableau 6-13).

Un coefficient Kappa et sa variance ont été calculés pour chaque matrice de confusion avec les formules présentées dans la section §4.10.3. Le calcul des précisions a été effectué en utilisant le même groupe test utilisé dans l'évaluation de la performance des réseaux de neurones.

Une première de lecture de ces précisions montre que les résultats obtenus avec les réseaux de neurones pour les mêmes combinaisons sont nettement supérieurs que celles obtenus avec la méthode de maximum de vraisemblance.

L'histogramme de la figure 6-12 présente une comparaison des précisions obtenues par les deux méthodes de classification. D'après ce graphique, on observe que le réseau de neurones arrive à identifier les trois classes végétales des milieux humides (fortement arborés, moyennement arborés et arbustifs) avec une précision nettement supérieure à celle obtenue par maximum de vraisemblance. La différence entre les deux précisions est de l'ordre de 20 %.

Par contre, en ce qui concerne le milieu forestier, la méthode du maximum de vraisemblance offre une précision de 6 % supérieure à celle obtenue par réseaux de neurones. Cette supériorité est due probablement au fait que les milieux forestiers sont plus homogènes que les composantes végétales des milieux humides et leur distribution statistique sont plus proche à la distribution normale que les autres classes (figures 5-12 et 5-13). Dans ce cas un modèle paramétrique est capable d'offrir une excellente discrimination étant donné qu'il suppose a priori que la distribution des valeurs numériques des pixels est normale (ou Gaussienne) pour chaque classe.



**Figure 6-12.** Comparaison entre les deux méthodes de classification: maximum de vraisemblance et réseaux de neurones

La supériorité observée des réseaux de neurones dans la discrimination des composantes végétales des milieux humides est due principalement à l'aspect non paramétrique de son fonctionnement. En effet, les réseaux de neurones ne nécessitent pas une connaissance a priori de la distribution statistique des classes. Cette caractéristique nous évite de fixer des conditions préalables sur la nature de la distribution qui ne sont pas toujours exactes. En effet, pour certaines classes, la distribution statistique des classes est loin d'être Gaussienne (figures 6-14a, b et c). Les histogrammes des figures 6-13 et 6-14 montrent que la distribution peut être bi-modale (comme il est le cas pour les milieux humides arbustifs en texture Moyenne S7, figure 6-13a) ou même aléatoire (comme c'est le cas pour les milieux humides fortement arborés en texture Écart Type : figure 6-13b ou en texture Corrélacion : figure 6-13c).

La supériorité des réseaux de neurones peut être aussi expliquée par le fait qu'un réseau de neurones nécessite moins de données d'entraînement que la méthode de maximum de vraisemblance pour construire son modèle (Augusteijn, *et al.*, 1995).

**TABLEAU 6-15.** Matrices de confusions obtenues par maximum de vraisemblance avec trois combinaisons d'intrants.

*Trois images S1*

	C1	C2	C3	C4	Nul
C1	<b>85</b>	9	0	4	2
C2	31	<b>29</b>	17	22	1
C3	1	4	<b>76</b>	17	2
C4	14	15	34	<b>36</b>	1
Précision totale :					<b>58</b>
Coefficient Kappa :					<b>0,43</b>
$\hat{\sigma}^2(K) = 19 \cdot 10^{-5}$					

*Trois images S7*

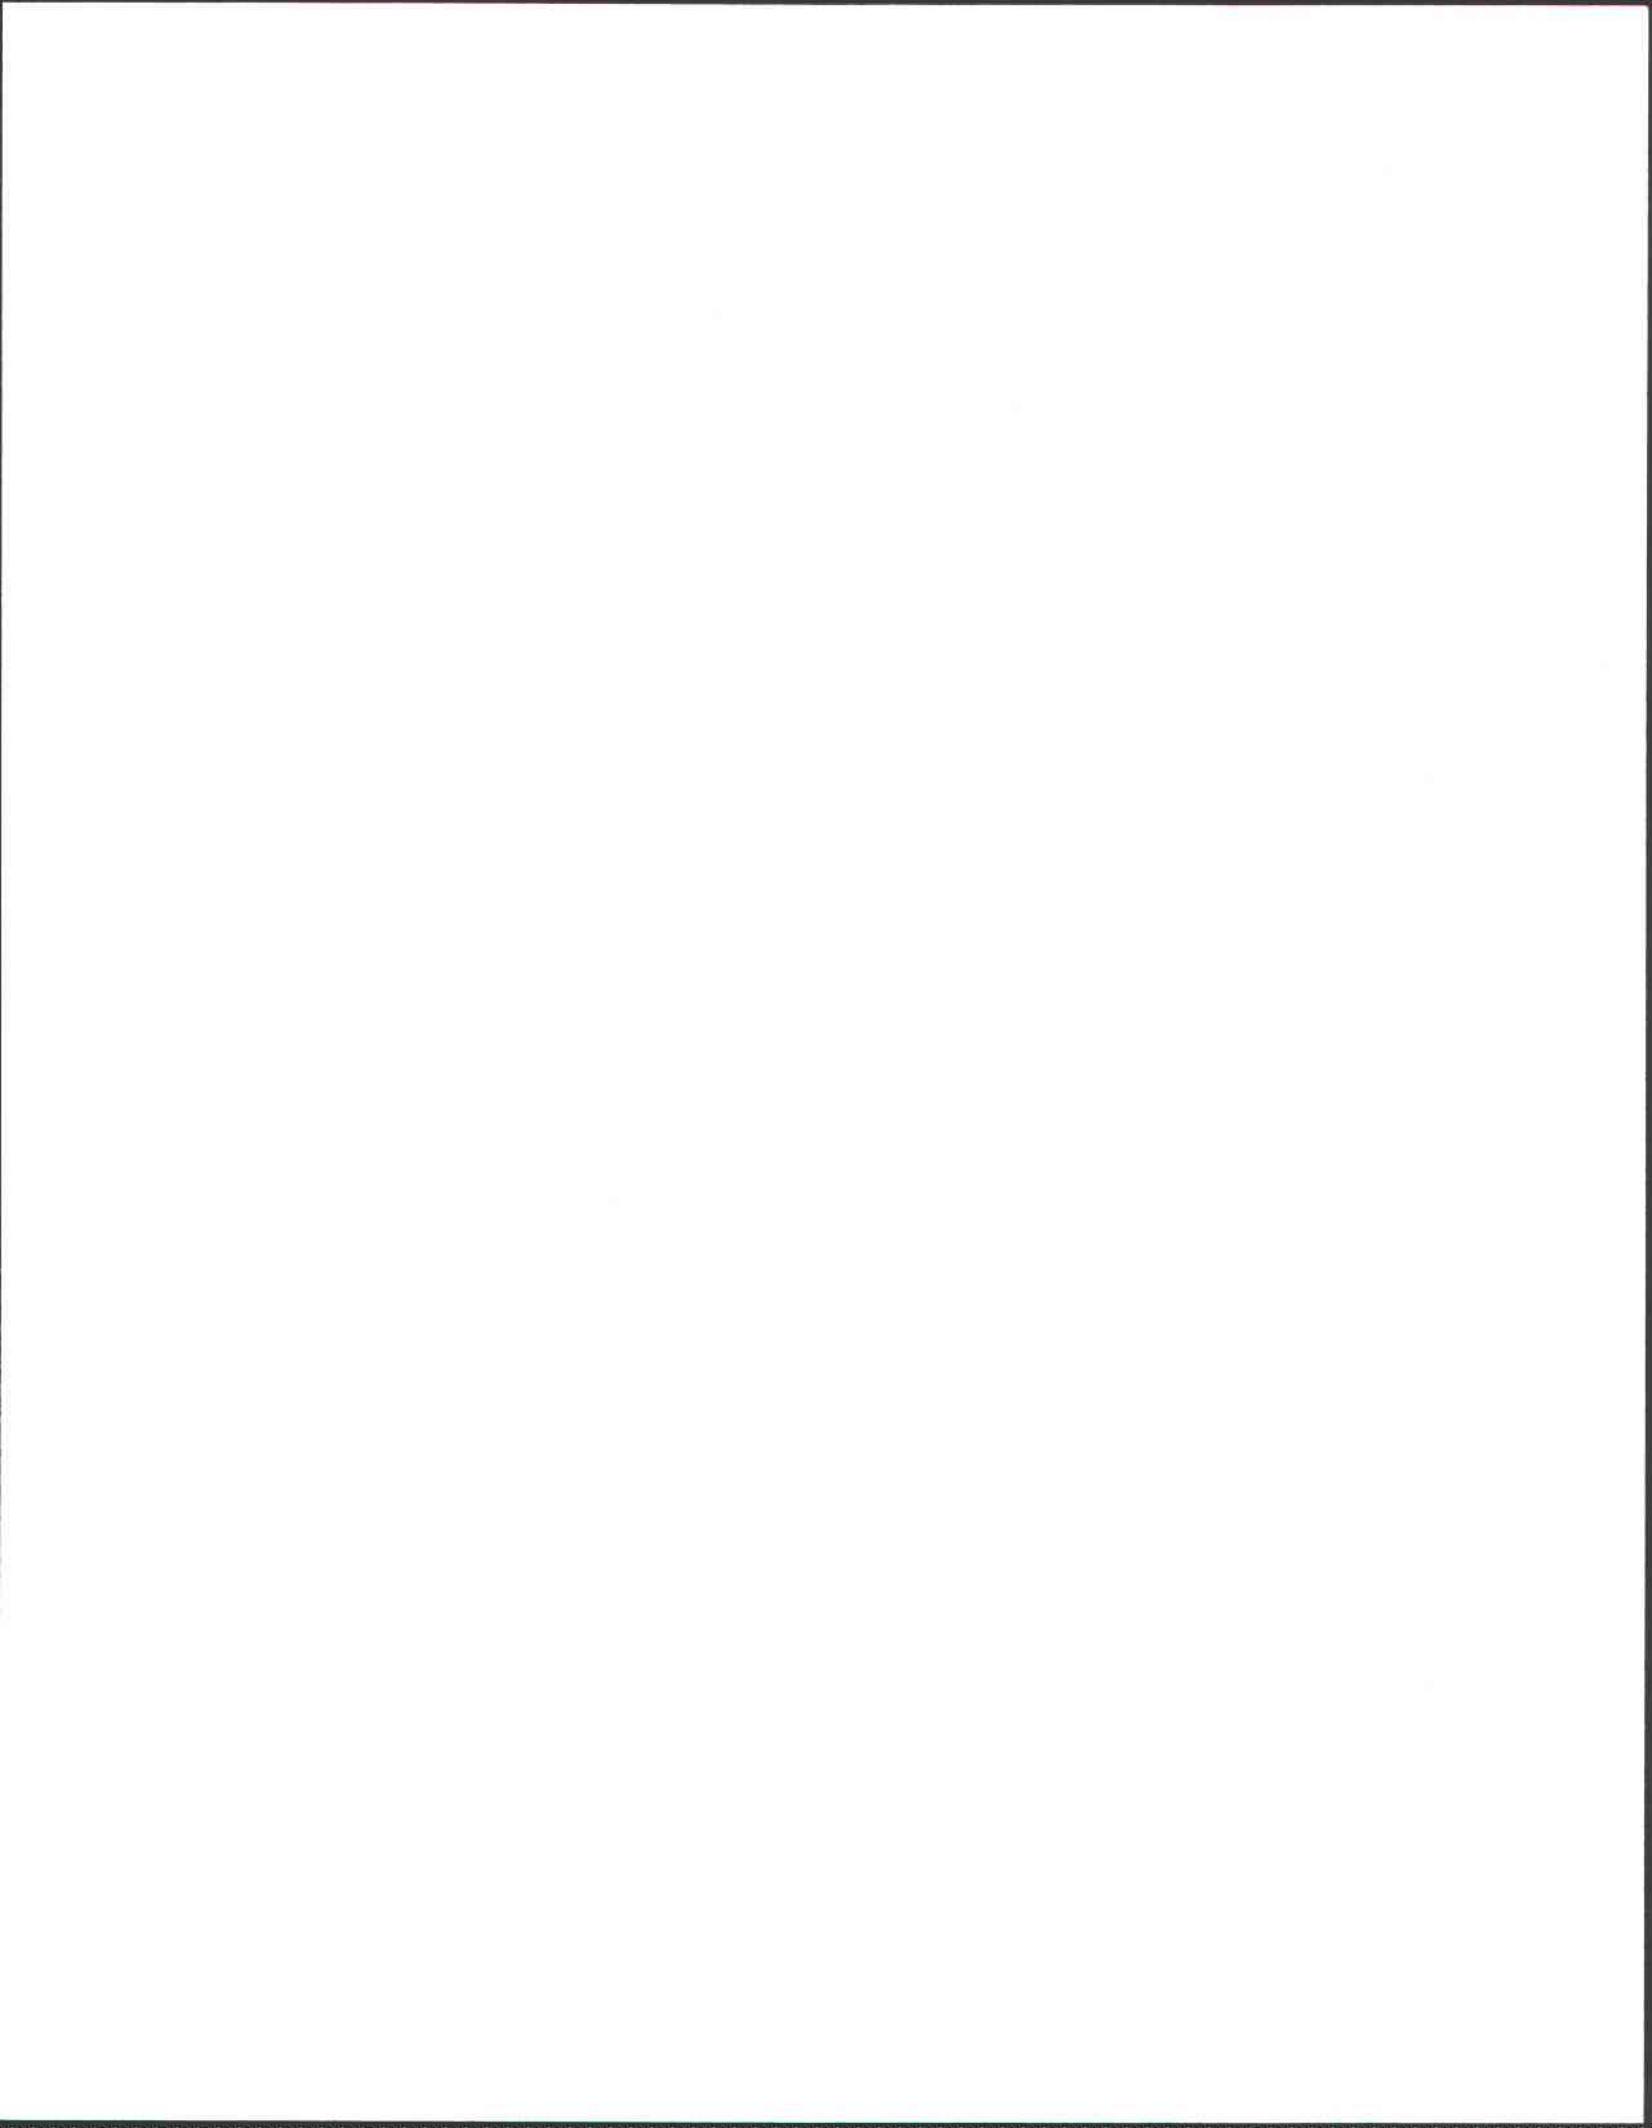
	C1	C2	C3	C4	Nul
C1	<b>90</b>	8	0	1	1
C2	17	<b>50</b>	5	27	1
C3	0	1	<b>88</b>	10	1
C4	1	25	19	<b>55</b>	0
Précision totale :					<b>71</b>
Coefficient Kappa :					<b>0,61</b>
$\hat{\sigma}^2(K) = 18 \cdot 10^{-5}$					

*Une image S1 et une image S7*

	C1	C2	C3	C4	Nul
C1	<b>89</b>	9	0	1	1
C2	22	<b>34</b>	10	34	0
C3	0	0	<b>84</b>	15	1
C4	2	20	17	<b>61</b>	0
Précision totale :					<b>67</b>
Coefficient Kappa :					<b>0,56</b>
$\hat{\sigma}^2(K) = 19 \cdot 10^{-5}$					

C1 : Milieu forestier  
C3 : Milieu humide arbustif

C2 : Milieu humide fortement arboré  
C4 : Milieu humide moyennement arboré



#### 6.4.2. Comparaison analytique des résultats

**TABLEAU 6-16.** Comparaison analytique entre les réseaux de neurones et le maximum de vraisemblance.

Combinaisons d'intrants		Maximum de vraisemblance			Réseaux de neurones			Statistique Z
		Précision totale	Coefficient Kappa	$\hat{\sigma}^2(K) \times 10^5$	Précision totale	Coefficient Kappa	$\hat{\sigma}^2(K) \times 10^5$	
1	Trois textures Moyenne (3 S7)	71	0,61	18	82	0,75	14	7,833
2	Trois textures Moyenne (3 S1)	57	0,43	19	53	0,38	17	2,742
3	Quatre textures : Moyenne et Écart Type (S1 août et S7 avril)	67	0,56	19	84	0,79	12	12,767

Le tableau 6-16 présente un résumé des résultats obtenus pour les deux méthodes de classifications testées. Le calcul de la statistique Z montre que la différence entre les deux classificateurs est significative pour les trois combinaisons testées ( $Z > 1,96$ ). La précision obtenue avec les trois images S1 est faible pour les deux classificateurs avec une légère supériorité de la méthode de maximum de vraisemblance (Kappa = 0,43 pour le maximum de vraisemblance et 0,38 pour les réseaux de neurones).

Pour la première et la troisième combinaison, les précisions obtenues par la méthode de maximum de vraisemblance sont considérées comme bonnes (Kappa > 0,40) mais elles restent nettement inférieures aux résultats obtenus avec le réseau de neurones qui peuvent être considérées comme excellentes avec un Kappa supérieur à 0,75. En plus, les valeurs de la variance du coefficient Kappa calculées à partir des matrices de confusion sont plus faibles pour les réseaux de neurones que ceux calculés avec la méthode de maximum de vraisemblance. Une faible variance du coefficient Kappa signifie qu'il y a moins de confusion entre les classes (Congalton, 1991).

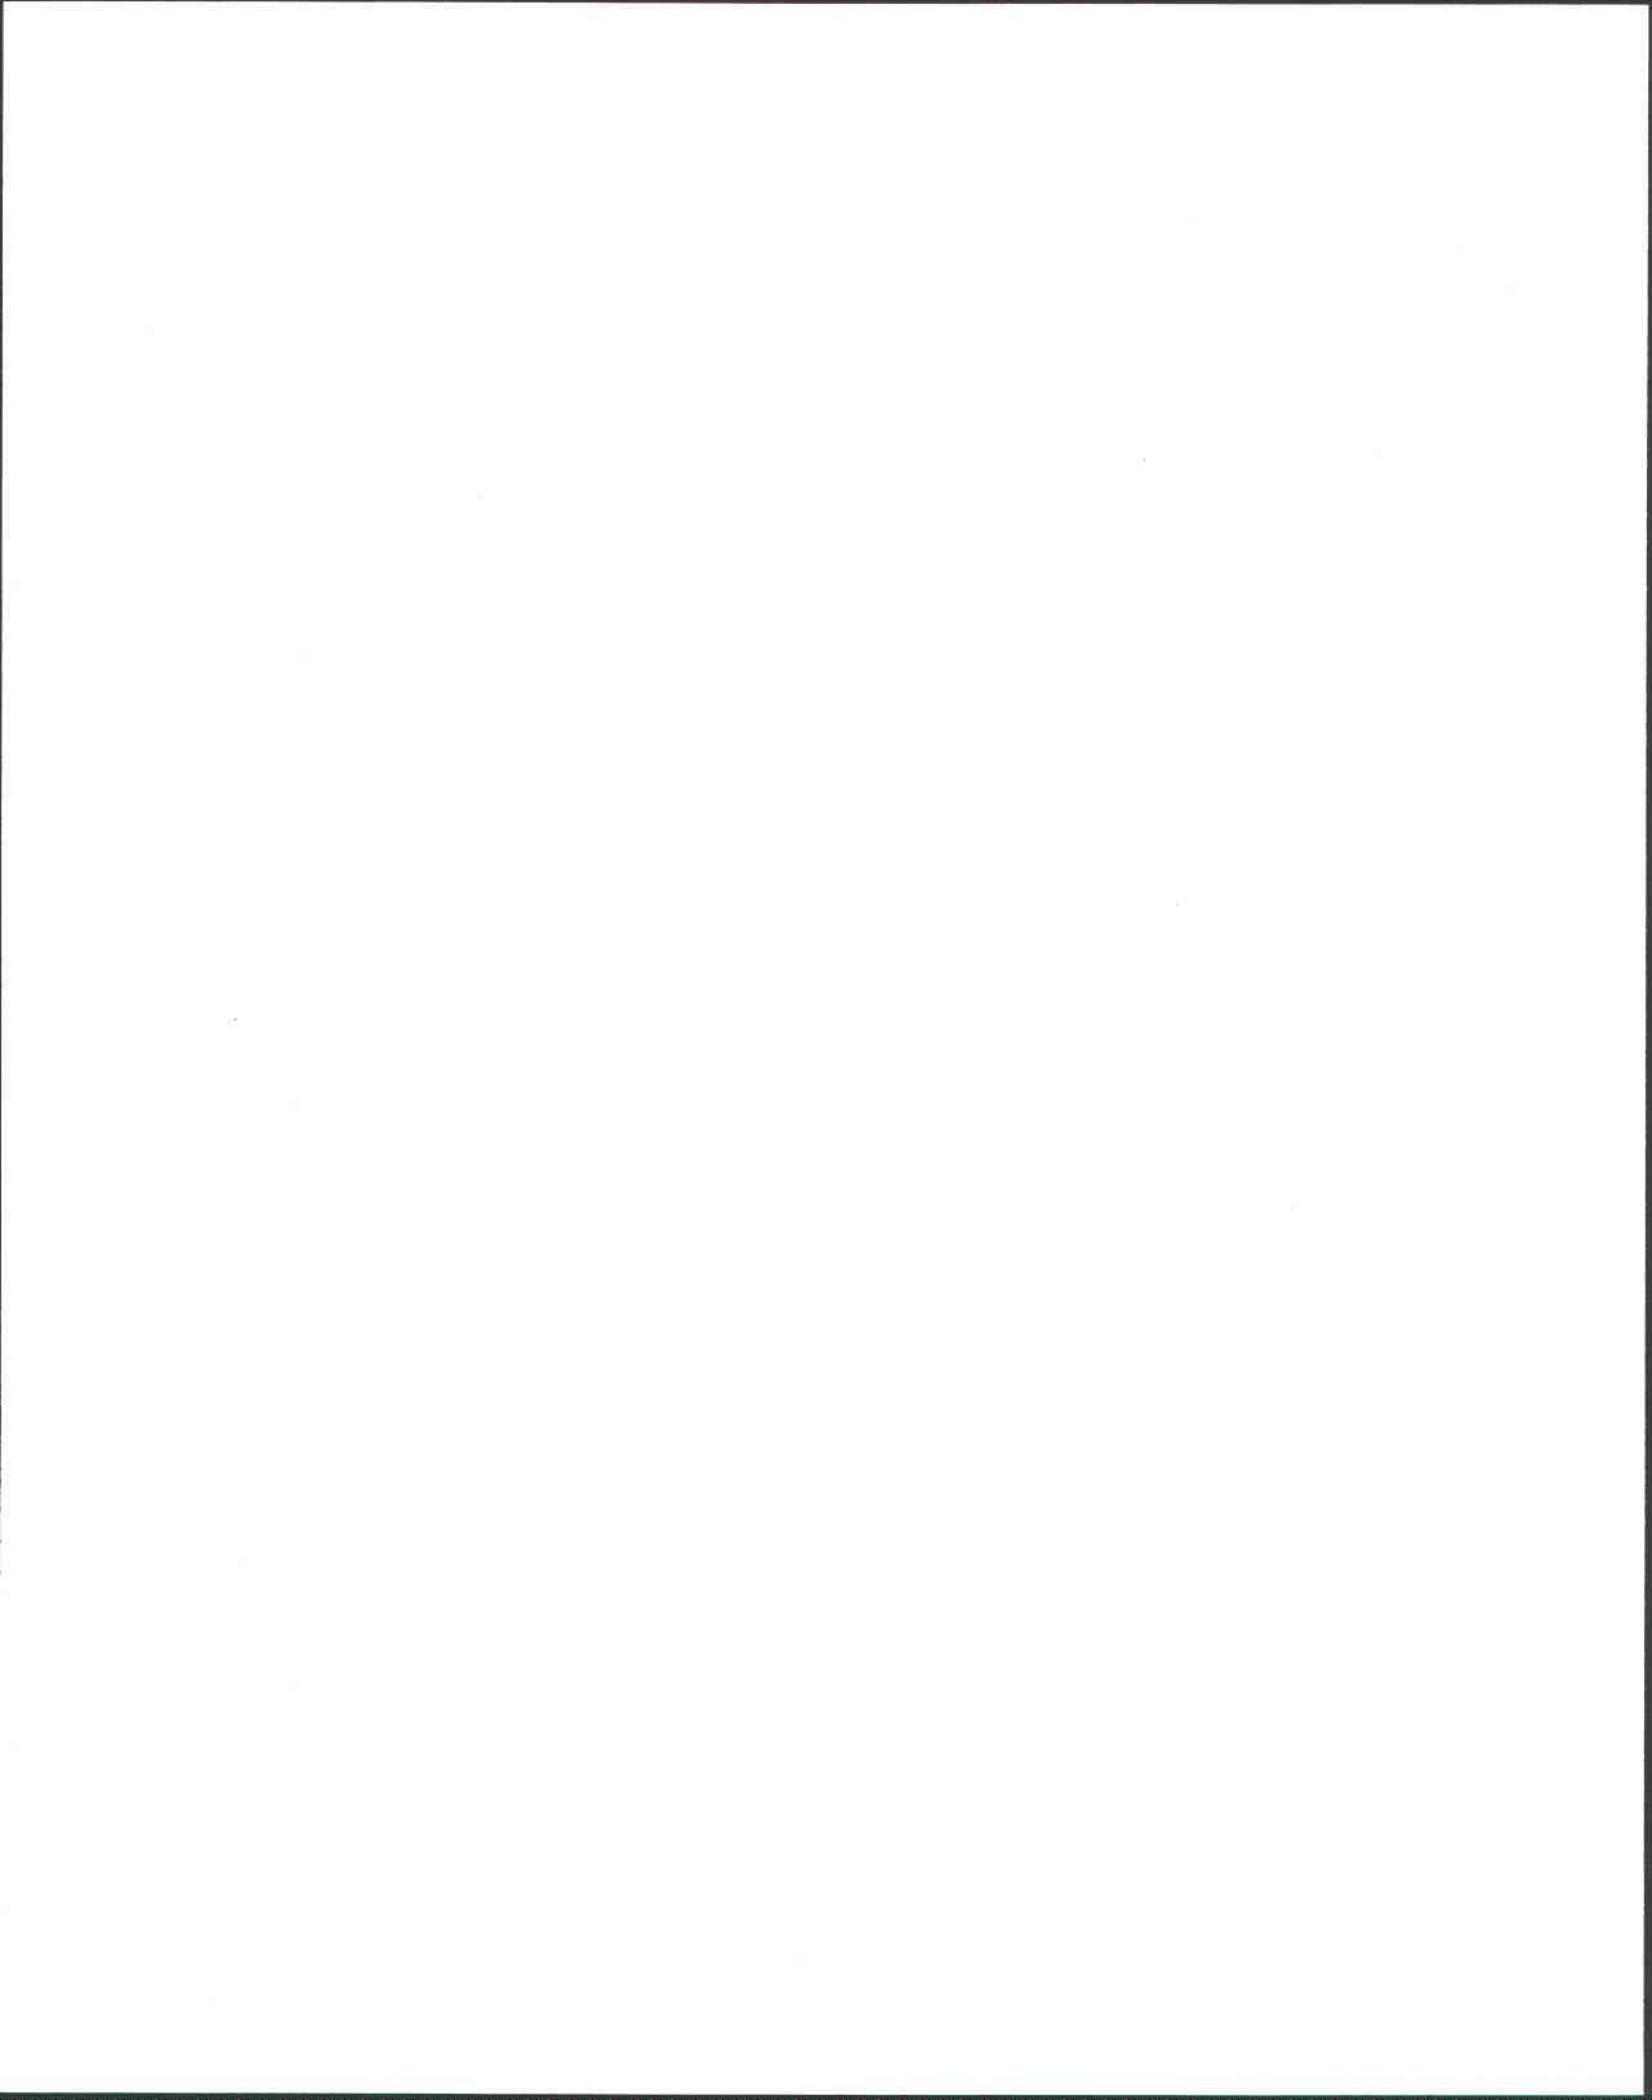


TABLEAU 6-17. Vérification de la complémentarité entre le mode S1 et le mode S7.

Classes		Réseaux de neurones			Maximum de vraisemblance		
		S1	S7	S1 + S7	S1	S7	S1 + S7
C1	Milieu forestier	92	82	82	85	90	90
C2	Milieu humide fortement arboré	35	80	86	29	50	33
C3	Milieu humide arbustif	84	85	93	76	88	85
C4	Milieu humide moyennement arboré	3	79	75	37	55	61
Précision totale :		<b>53</b>	<b>81</b>	<b>84</b>	<b>57</b>	<b>71</b>	<b>67</b>

Les précisions affichées au tableau 6-17 permettent d'évaluer le degré de complémentarité entre les deux modes d'acquisition S1 et S7 pour les deux méthodes de classification utilisées dans cette thèse : réseau de neurones et par maximum de vraisemblance. En effet, étant donnée la supériorité démontrée précédemment du mode S7, la comparaison entre les valeurs de précision présentées au tableau 6-17 permet de vérifier si l'ajout d'une image S1 a un apport significatif à la précision de chacune des classes et à la précision totale de la classification. Cette comparaison permet aussi de vérifier si l'ajout d'une image S1 a un effet négatif sur les précisions obtenues avec uniquement une image S7. En effet, l'ajout d'une image S1 peut être bénéfique dans l'identification d'une classe donnée mais risque d'apporter quelques confusion aux autres classes.

En ce qui concerne la méthode de réseau de neurones, l'ajout d'une image S1 a amélioré la précision pour les trois premières classes (C1, C2 et C3) et a fait diminuer la précision de la quatrième classe (C4) de 4 %. Cette diminution est sûrement due à la forte confusion entre les milieux humides moyennement arborés (C4) et les milieux humides arbustifs (C3) observée en utilisant uniquement des images S1 (voir matrice de confusion du tableau 6-8).

Concernant la méthode du maximum de vraisemblance, les conclusions sont contraires à celles observées avec le réseau de neurones. L'ajout d'une image S1 a fait diminuer la précision pour les trois premières classes (C1, C2 et C3) et augmenter pour la quatrième classe (C4).

Ces observations confirment l'hypothèse que les réseaux de neurones considèrent différemment l'apport de chaque mode d'acquisition pour la prise de décision d'une classe donnée.

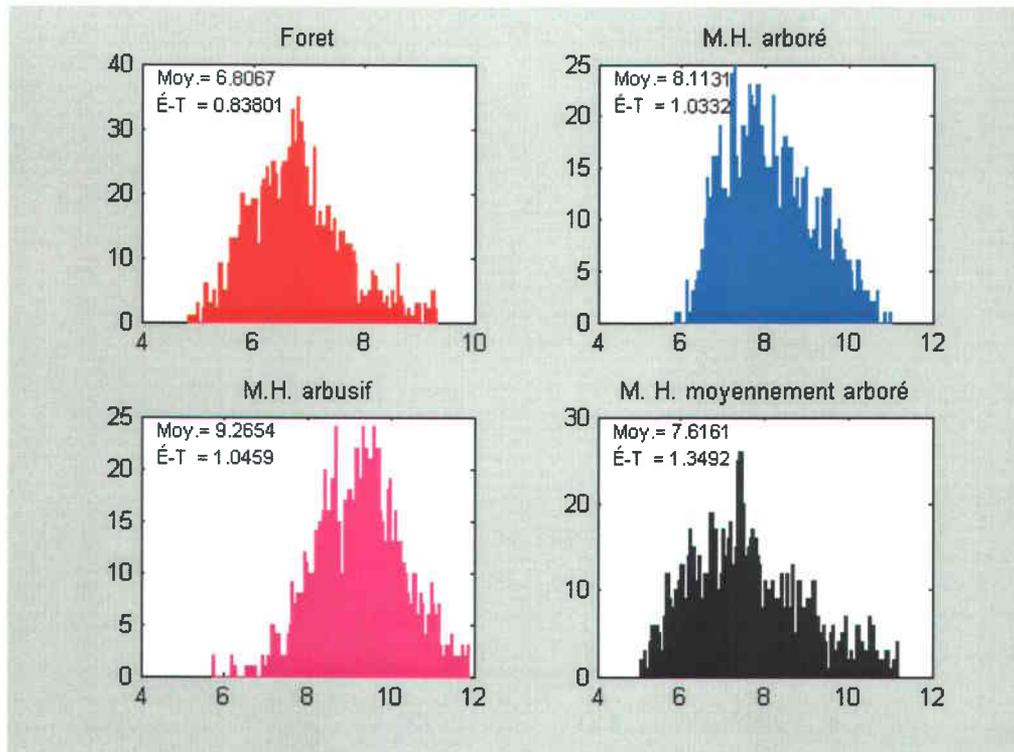


Figure 6-13a. Distribution statistique des classes : texture Moyenne de l'image S1 (août).

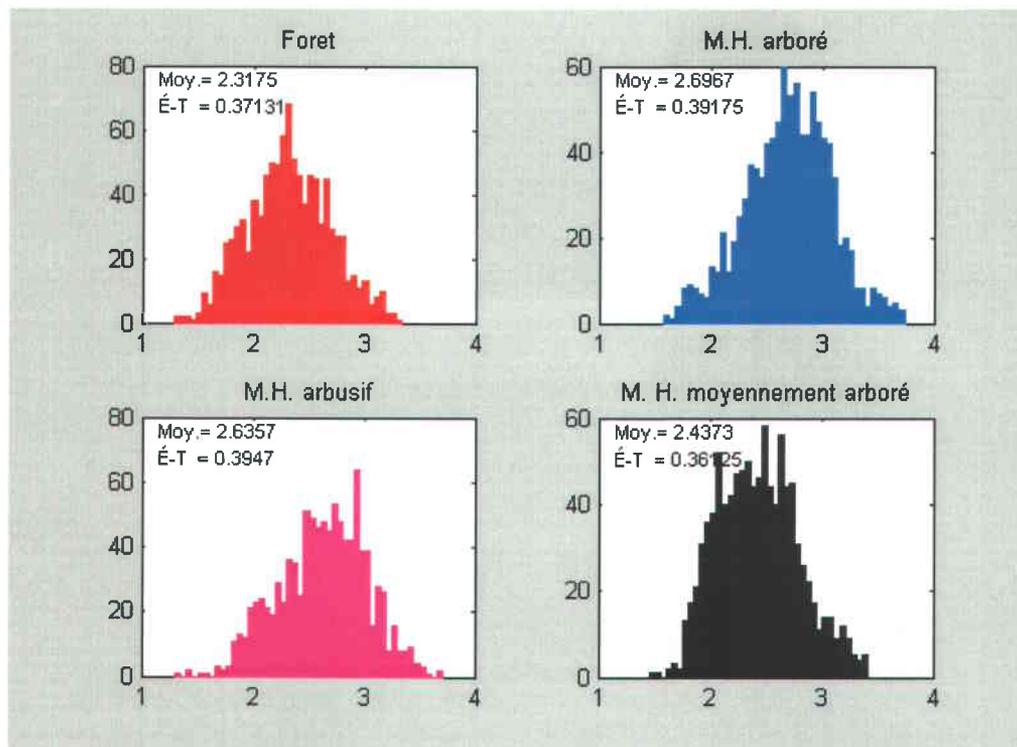


Figure 6-13b. Distribution statistique des classes : texture Écart Type de l'image S1 (août).

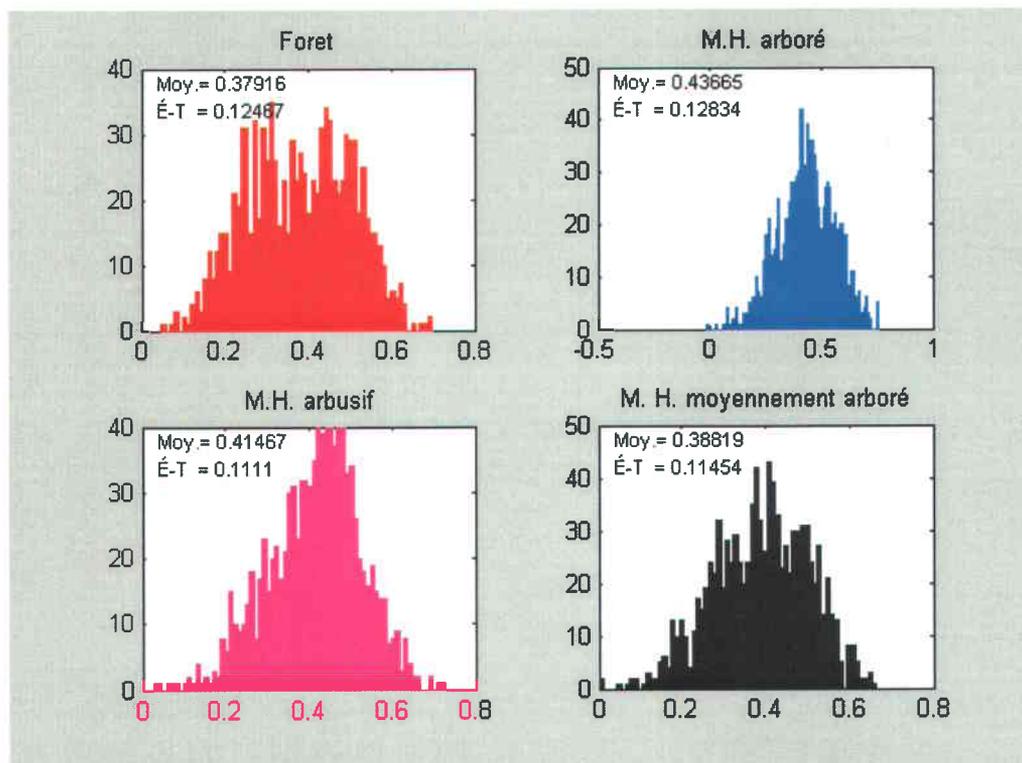


Figure 6-13c. Distribution statistique des classes : texture Corrélation de l'image S1 (août).

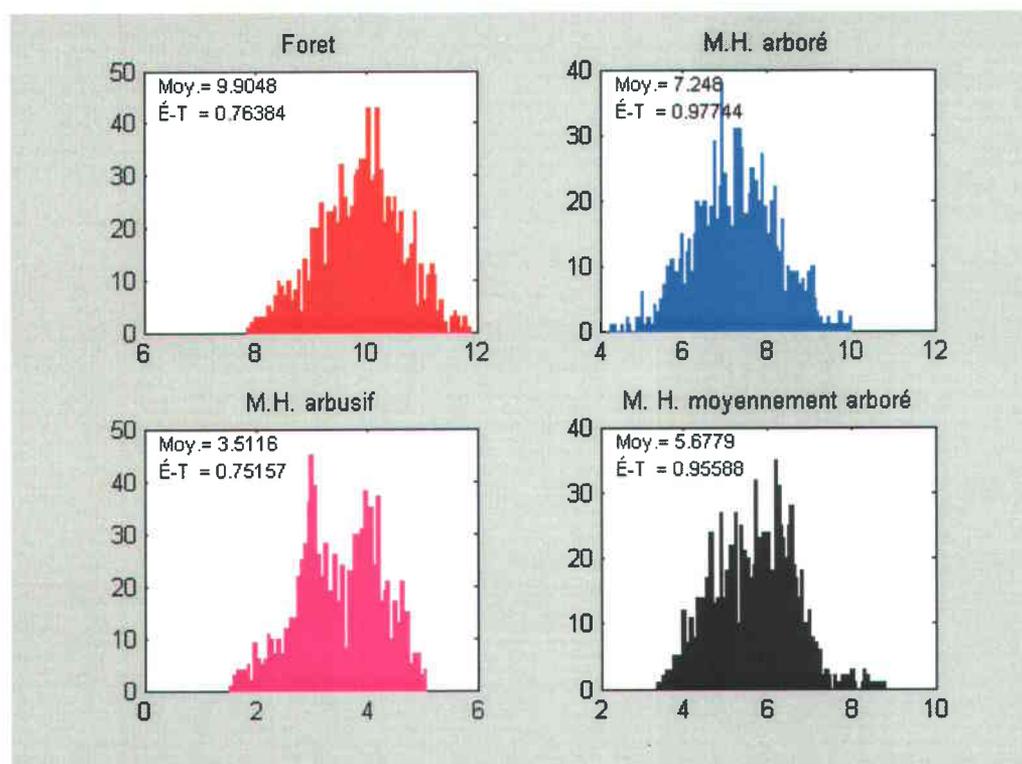


Figure 6-14a. Distribution statistique des classes : texture Moyenne de l'image S7 (avril).

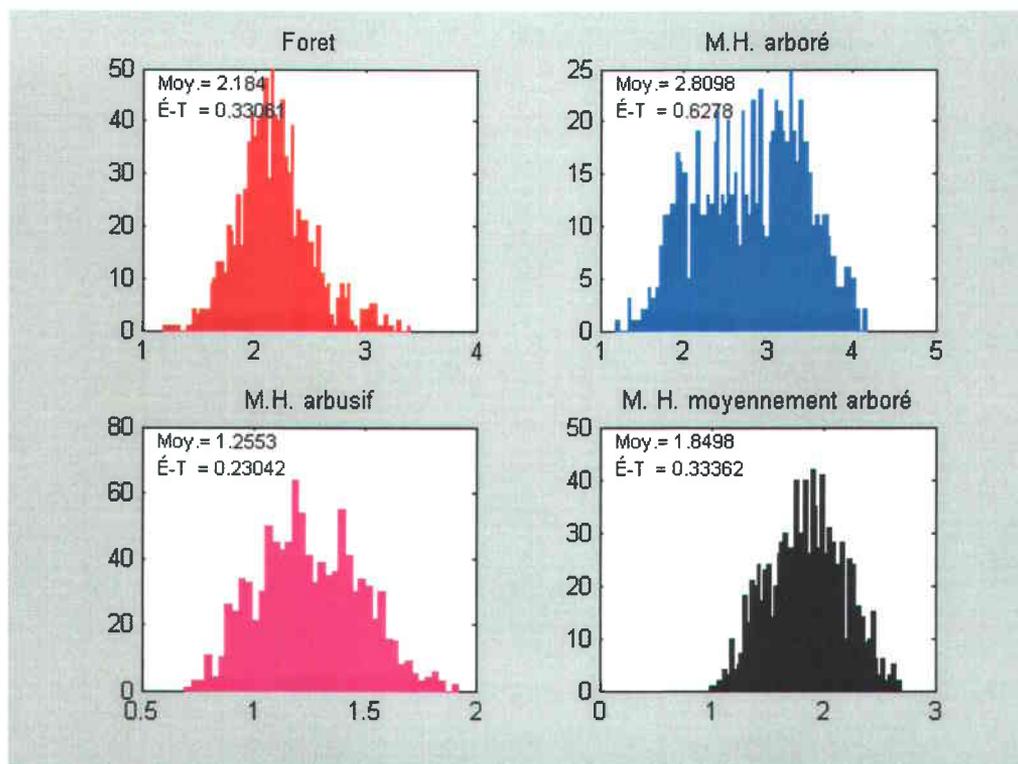


Figure 6-14b. Distribution statistique des classes : texture Écart Type de l'image S7 (avril).

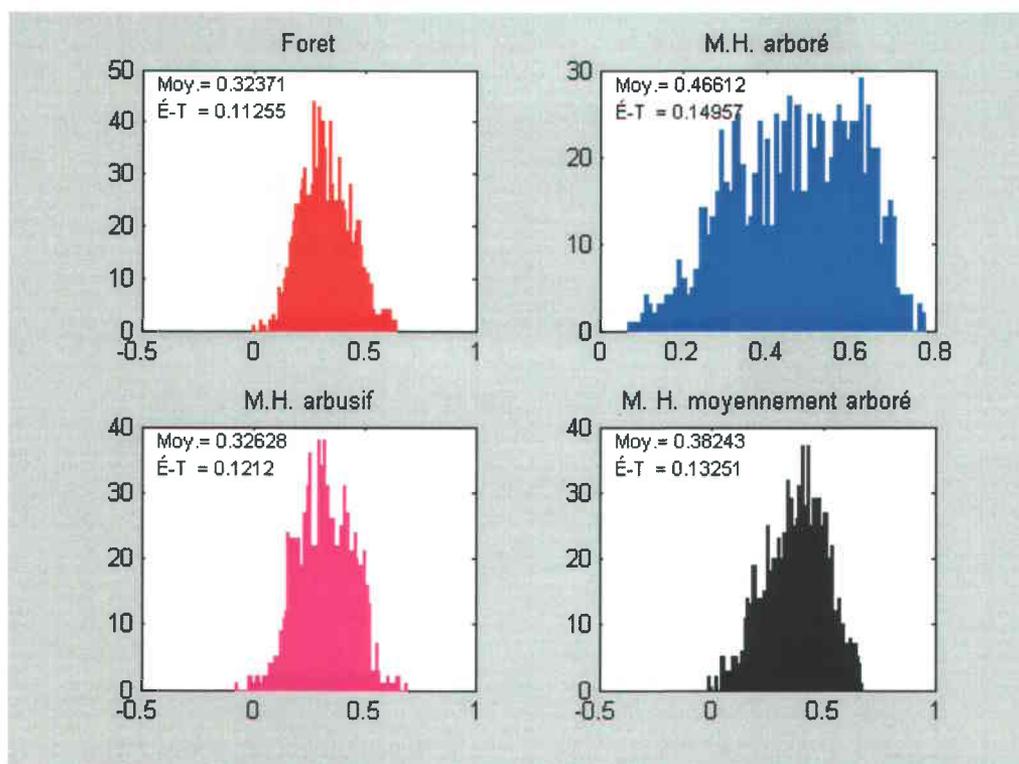


Figure 6-14c. Distribution statistique des classes : texture Corrélation de l'image S7 (avril).

## **6.5. Classification de l'image**

Comme suite à l'analyse d'optimisation des intrants présentée à la section (§ 6.3), nous avons conservé la combinaison de deux mesures de texture (Moyenne et Écart Type) extraites d'une image S1 du mois d'août et d'une image S7 du mois d'avril (§ 6.3.8). Ce choix représente le meilleur compromis entre le nombre d'images utilisées et la performance de la classification.

Le réseau de neurones entraîné a été testé sur une sous-image de 1056 x 680 pixels couvrant les milieux humides d'Albanel et de Dolbeau (au nord-ouest du lac St-Jean) entourés par une grande superficie de forêts. Ces milieux humides sont les seuls milieux naturels couverts en même temps par les deux faisceaux S1 et S7. Ils sont caractérisés par une flore dominée par une végétation arbustive. Ils contiennent aussi plusieurs colonies d'épinettes noires, à des densités variables, éparpillées dans plusieurs zones.

### **6.5.1. Le temps d'opération de la méthode**

Le temps nécessaire pour l'apprentissage du réseau et la classification de l'image représentent l'inconvénient majeur de réseaux de neurones (Augusteijn *et al.*, 1995). Ce temps est proportionnel à la taille du réseau et varie selon la vitesse du processeur de l'ordinateur utilisé. À titre d'exemple, un PC avec un processeur de 800 MHz est capable de classifier environ 60 pixels par seconde avec un réseau de 120 neurones (5-12-4). Ainsi, pour la sous-image testée dans ce projet qui contient 726528 pixels (1056 lignes x 688 colonnes), le réseau a pris 3 heures et demi pour classifier toute l'image.

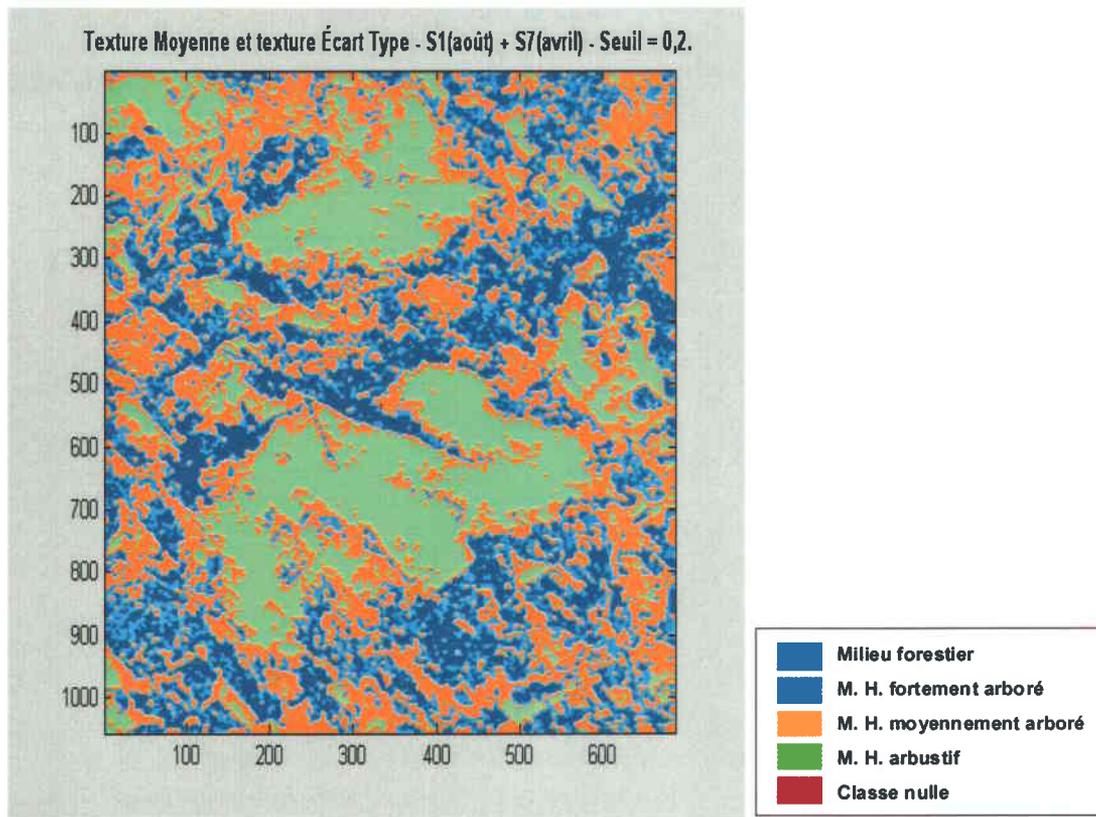
D'autre part, le temps nécessaire pour l'apprentissage est proportionnel à la taille du réseau et au nombre de pixels utilisés pour l'entraînement. Le temps d'apprentissage est aussi influencé par les paramètres liés au taux d'apprentissage comme le coefficient de freinage, le coefficient d'accélération, le momentum... etc. Toutefois, puisque les valeurs des poids initiaux sont aléatoirement choisies, le temps d'apprentissage peut varier entre deux tests avec une configuration identique. Dans ce projet, le temps nécessaire pour la convergence du réseau a rarement dépassé 30 minutes et ceci pour toutes les combinaisons d'intrants testées.

Avec la croissance phénoménale des accessoires informatiques, les inconvénients liés à lenteur de la classification par réseau de neurones seront de plus en plus minimes. Ainsi, l'augmentation phénoménale de la fréquence de calcul des nouveaux processeurs (qui atteint 2

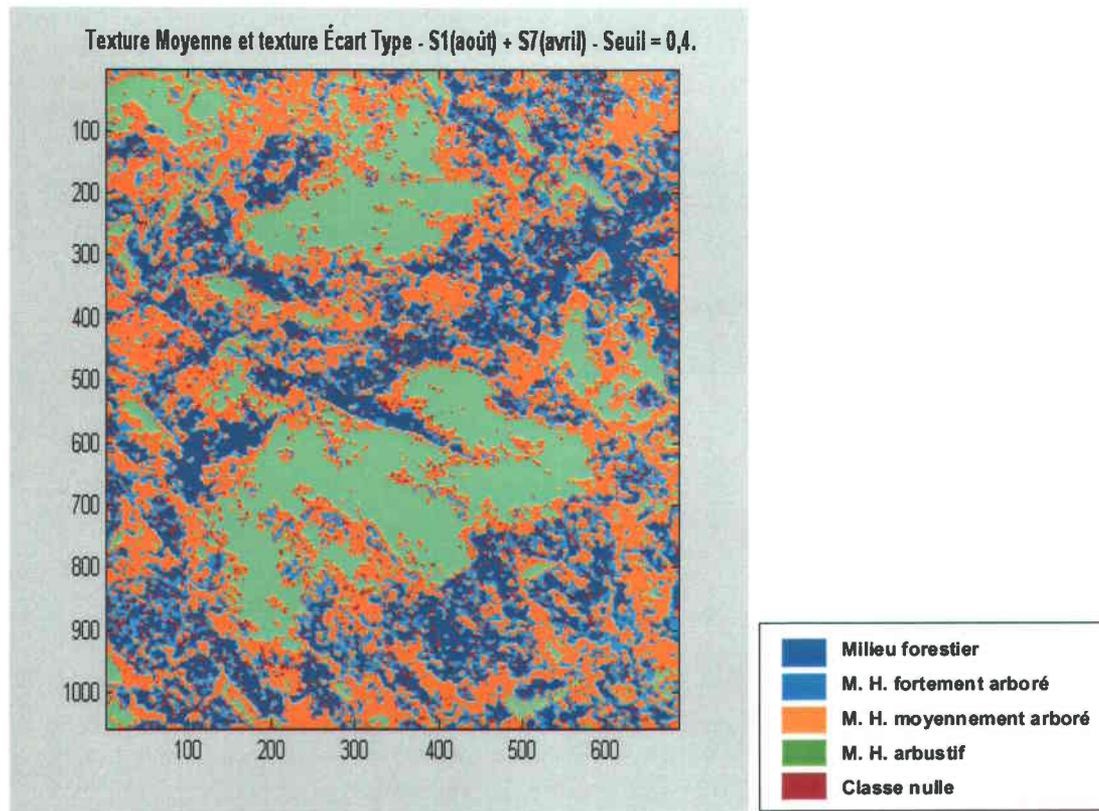
GHz avec le nouveau processeur Pentium IV de Intel Inc.) et l'agrandissement de la capacité mémoire des nouveaux ordinateurs ont considérablement contribué à l'accélération des calculs automatisés.

### **6.5.2. Effet du seuil de décision sur la classification.**

Cette section fait suite à l'analyse déjà réalisée au (§ 6.2) sur l'effet du seuil de décision sur la précision du groupe test. Les quatre planches de la figure 6-15 présentent les résultats de classification obtenus avec des seuils de décision variants entre 0,2 et 0,8. Comme il a été démontré auparavant dans les graphiques de la figure 5-1, le nombre de pixels nuls augmente considérablement avec l'augmentation du seuil de décision au-dessus de 0,5. Toutefois, la variation du seuil entre 0,2 et 0,4 n'a pas un effet visible sur l'apparence de la classification.



**Figure 6-15a.** Effet du seuil de décision sur la classification (seuil = 0,2).



**Figure 6-15b.** Effet du seuil de décision sur la classification (seuil = 0,4).

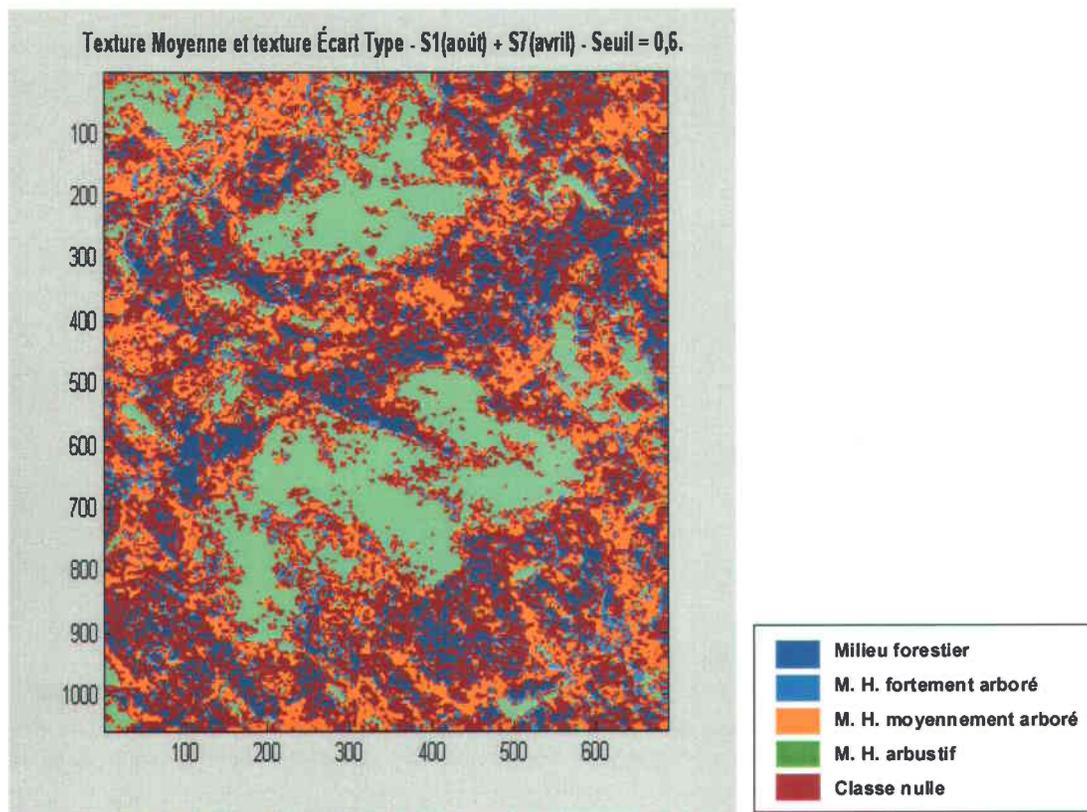
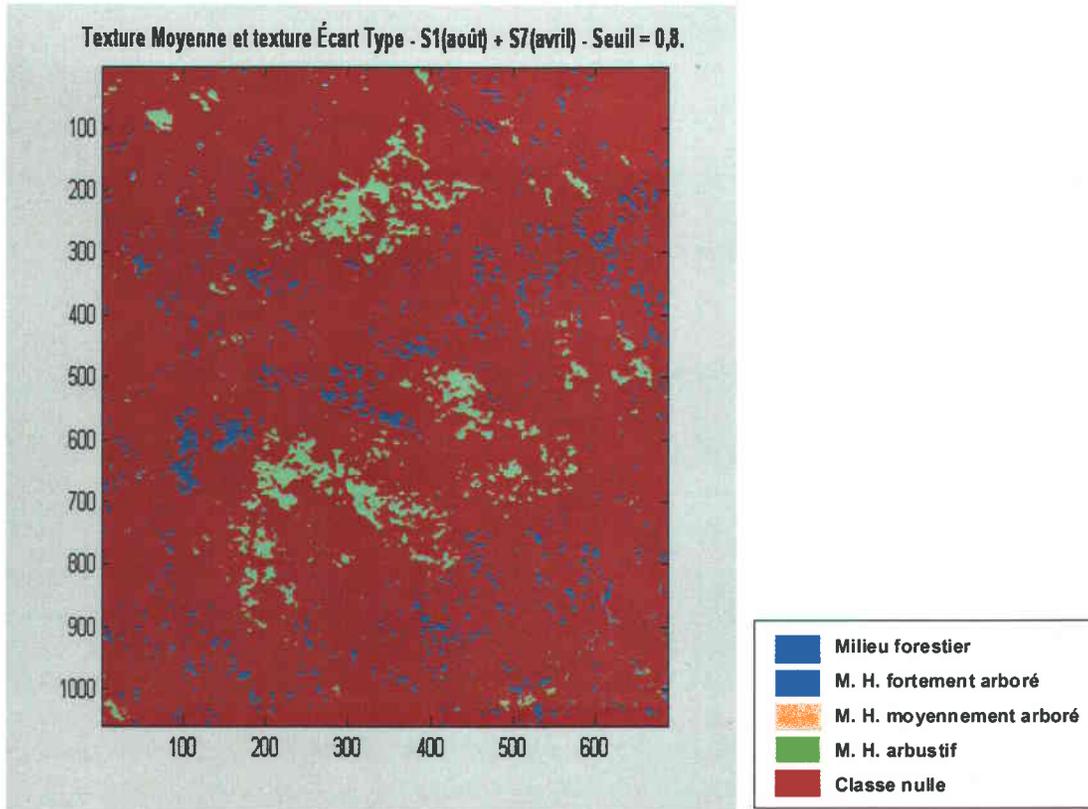


Figure 6-15c. Effet du seuil de décision sur la classification (seuil = 0,6).

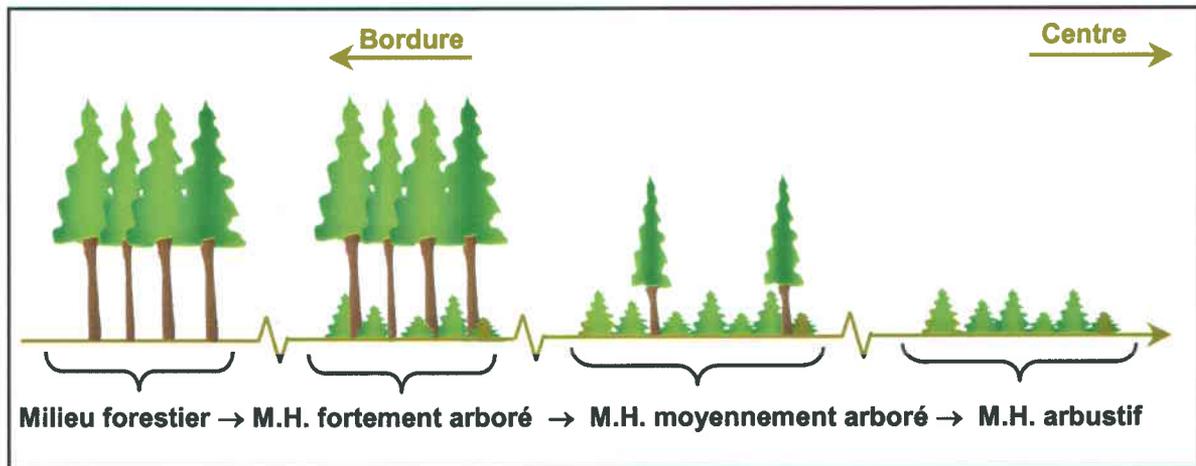


**Figure 6-15d.** Effet du seuil de décision sur la classification (seuil = 0,8).

### 6.5.3. Gradient de la végétation

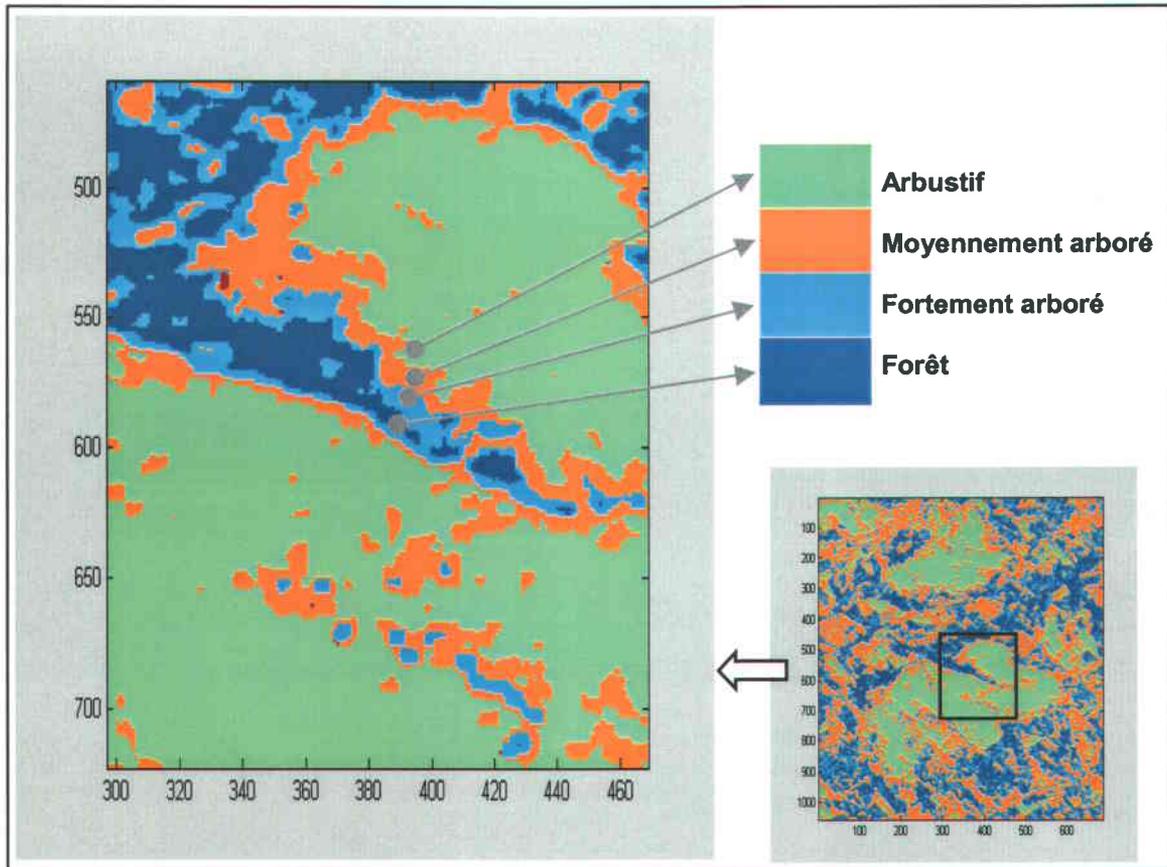
Après l'adoption de la configuration finale du réseau et après le choix de la combinaison optimale des intrants, il nous reste qu'à vérifier la qualité de la classification de l'image entière. En effet, même si une estimation descriptive et analytique de la précision donne une idée sur la qualité de la classification, une interprétation visuelle de la carte thématique produite reste une étape incontournable dans l'appréciation finale du résultat. Pour ce faire, nous avons choisi le respect du gradient de la végétation comme critère d'évaluation de la qualité de la classification.

L'évolution de la composition arborée d'un milieu humide suit, en général, un gradient précis entre le centre et la bordure du milieu (figure 6-16). En s'approchant des bordures, la présence d'arbres (comme les épinettes noires : *picea mariana* et les mélèzes *larix laricina*) s'accroît et leur taille devient de plus en plus imposante, ce qui peut entraîner la formation d'une lisière forestière près de la marge du milieu humide (Damman, 1977). La présence de ce gradient a été observée pendant les visites effectuées sur le terrain.



**Figure 6-16.** Gradient de la végétation.

Le gradient de la végétation est influencé par l'hydrologie et l'hydrogéologie du milieu humide (Damman, 1977). La présence d'une couverture arborescente dense dans les zones limitrophes de milieux humides est due principalement aux apports minéraux transportés de l'extérieur par les eaux de ruissellement enrichies des éléments minéraux (ou éléments nutritifs). La présence des minéraux au sol augmente le pH du milieu ( $4,6 > \text{pH} > 7,5$ ) ce qui favorise la poussée d'une végétation arborée (Glasser, 1992).



**Figure 6-17.** Vérification du gradient de la végétation.

La figure 6-17 présente un test de vérification de l'aptitude du réseau à détecter l'évolution du gradient de la végétation. La grande planche représente un agrandissement de la classification produite d'une zone limitrophe située entre un milieu humide et un milieu purement forestier. La classification présentée à cette figure montre que le réseau de neurones détecte l'évolution graduelle de la densité des arbres dans la zone limitrophe du milieu humide. Toutefois, une certaine confusion reste visible dans le milieu forestier où certaines zones ont été classifiées comme milieux humides fortement ou moyennement arborés. Cette confusion est probablement due à la présence d'une couche d'eau stagnante dans quelques endroits du milieu forestier. La présence de l'eau au sol augmente l'humidité du milieu ce qui engendre une augmentation de la rétrodiffusion dans cette zone.

# CHAPITRE 7

## Conclusion

---

L'objectif principal de cette recherche était de développer une méthodologie de classification des images Radarsat-1 par réseaux de neurones pour identifier les grandes classes physiologiques des milieux humides. Pour ce faire, deux objectifs secondaires ont été poursuivis : (1) comprendre le comportement du signal radar face aux différentes composantes des milieux humides et (2) établir un mode de fonctionnement pour les différentes étapes de classification des données Radarsat-1 par réseaux de neurones.

L'objectif principal ainsi que les deux objectifs secondaires sont atteints. L'approche développée dans ce projet devrait être transférée au Ministère des Ressources Naturelles (MRN) du Québec pour une éventuelle cartographie des milieux humides dans le Nord de la province.

### ***7.1. Vérification des hypothèses***

Au début de la thèse, nous avons défini nos objectifs en se basant sur quatre hypothèses liées au choix de l'imagerie radar pour la cartographie des milieux humides (hypothèses 1 et 2) et au choix de réseau de neurones comme classificateur (hypothèses 3 et 4). Ces hypothèses ont été vérifiées et analysées tout au long de la thèse. Les paragraphes suivants discutent de la validation des quatre hypothèses énoncées au premier chapitre. Aussi, les recommandations finales de la thèse seront étroitement liées aux étapes parcourues pour la vérification de ces hypothèses.

### **7.1.1. Le potentiel de l'imagerie radar pour la cartographie des milieux humides**

**Hypothèse 1 :** *le pouvoir des données Radarsat-1 en mode Standard à discriminer entre les composantes végétales des milieux humides.*

L'analyse théorique effectuée au troisième chapitre (§3.4) sur la rétrodiffusion radar a montré que les micro-ondes radar interagissent différemment pour chacune des quatre classes : (1) milieu forestier, (2) milieu humide fortement arboré, (3) milieu humide moyennement arboré et (4) milieu humide arbustif. Par contre, les analyses de séparabilité effectuées sur ces quatre classes (§3.8) ont montré que les images acquises en mode S1 offrent une faible discrimination des composantes végétales des milieux humides. Cependant, le mode d'acquisition S7 est plus puissant quand il s'agit de discriminer les différentes composantes à l'intérieur des milieux humides. Ces analyses ont ainsi montré que le mode S7 reste plus sensible à la variation de la composition végétale malgré la faiblesse du signal retourné au satellite. Toutefois, la précision obtenue avec une image S1 et une image S7 (84 %) n'a été que légèrement supérieure à celle obtenue avec trois images S7 (82 %).

Les mesures de texture se sont avérées très utiles pour ressortir les informations dissimulées dans les images radar. En fait, contrairement aux algorithmes de filtrage qui affectent considérablement la résolution de l'image, la texture permet de réduire l'effet du chatoiement tout en gardant une certaine sensibilité pour l'identification des objets ou des régions d'intérêt dans l'image. En plus, l'utilisation de la texture permet de réduire l'effet négatif d'une classification pixel par pixel en fournissant au réseau une information sur la zone avoisinante du pixel concerné. Les analyses de séparabilité effectuées sur les quatre classes retenues (§3-8) ont montré que l'utilisation de la texture améliore considérablement la séparabilité des classes. Cette amélioration atteint 300 % avec la texture Moyenne (figures 3-14a,b,c et d). L'hypothèse 1 a donc été validée.

Toutefois, étant donné la forte corrélation qui existe entre plusieurs mesures de texture, il s'avère important d'effectuer une analyse de corrélation sur ces mesures afin de réduire la quantité d'intrants à fournir au réseau de neurones. En effet, la suppression des informations inutiles dans un processus de classification par réseau de neurones réduit considérablement la taille de réseau qui implique une réduction du temps nécessaire pour l'apprentissage du réseau et la classification de l'image.

Comparativement aux images brutes, l'utilisation de la texture Moyenne a considérablement augmenté la capacité du mode S7 à discriminer entre un milieu forestier et un milieu humide fortement arboré. L'apport de la texture Moyenne dans la discrimination entre ces deux milieux peut être remarqué en comparant le comportement de la rétrodiffusion (figure 3-6) et de la texture Moyenne (figure 3-12a) pour les quatre classes testées. Cet apport de la texture Moyenne explique aussi la bonne performance obtenue dans la classification des pixels forêts avec trois images S7 seules (82 %). Cette performance est légèrement inférieure à celle obtenue avec une image S1 et une image S7 (84 %).

**Hypothèse 2 :** *Effet discriminatoire des angles d'incidence.*

La deuxième hypothèse stipulant que les micro-ondes émises en mode S1 (faible angle d'incidence) sont capables de pénétrer une couverture arborée et être ainsi sensibles à l'humidité du sol n'a cependant pas été confirmée. En effet, la supériorité du mode S1 à délimiter les milieux forestiers de milieux humides n'est pas évidente et la complémentarité entre les deux modes d'acquisition S1 et S7 présentée au début de la thèse était surévaluée. Les résultats présentés au septième chapitre ont montré que la contribution du mode S1 reste faible dans un processus de classification des milieux humides. Le faible apport du mode S1 a été causé essentiellement par l'utilisation de la texture Moyenne qui augmente la capacité du mode S7 à séparer toutes les classes incluant les forêts.

La comparaison entre les deux matrices de confusions présentées dans les tableaux 6-7 et 6-8 confirme bien cette observation. En effet, même si 92 % des pixels forêts sont correctement classifiés en utilisant uniquement trois images S1, il est important de signaler que 48 % de pixels des milieux humides fortement arborés ont été incorrectement classifiés comme forêts. Ceci confirme aussi l'importance de tenir compte de la précision du producteur et de la précision de l'utilisateur quand il s'agit de faire une analyse descriptive des matrices de confusion. En effet, une excellente précision dans la diagonale d'une matrice de confusion ne signifie pas que le classificateur arrive à identifier correctement la classe correspondante; mais, la valeur réelle de cette précision doit tenir compte des confusions enregistrées entre cette classes et les autres classes de la matrice.

La confusion enregistrée dans la classification des milieux humides fortement arborés par des images en mode S1 est due probablement au fait que les micro-ondes radar ne réussissent pas à pénétrer des denses couvertures arborées dans les milieux humides du Lac Saint-Jean

(Québec, Canada). Dans ce cas, la rétrodiffusion radar sera moins sensible à l'humidité du sol qui représente le principal facteur différenciant ces deux milieux.

Les résultats de la classification par réseaux de neurones ont aussi confirmé cette observation. Ainsi, la différence entre la précision obtenue avec trois images S1 et celle obtenue avec trois images S7 est très visible (82 % pour les images S7 contre 53 pour les images S1). Ceci est dû principalement à la prédominance de l'humidité du sol sur la rétrodiffusion à faible angle d'incidence (S1). L'humidité du sol est considérée, dans ce cas, comme une source indésirable du bruit. Cependant, avec le mode S7, l'effet du sol devient négligeable sur la rétrodiffusion totale qui devient plus sensible à la variation des composantes de la végétation.

### **7.1.2. Réseaux de neurones**

Le choix de réseaux de neurones comme algorithme de classification a été essentiellement motivé par les résultats encourageants obtenus avec cette technique dans plusieurs applications récentes en télédétection. La précision de ces résultats était, dans la plupart des cas, supérieure à celle obtenue avec les méthodes conventionnelles de classification. En effet, la supériorité des réseaux de neurones est essentiellement due à son aspect non paramétrique qui évite l'utilisateur de faire des suppositions sur la distribution statistique des données. En plus, les réseaux de neurones ont l'avantage de considérer différemment l'apport de chaque source d'information pour la prise de décision d'une classe donnée. Ce dernier avantage permet de renforcer automatiquement le poids des informations qui ont une contribution majeure dans la discrimination de certaines classes. Les résultats obtenus dans cette thèse ont montré que le réseau de neurones est un puissant outil de classification des données Radarsat-1.

Les tests effectués sur les paramètres internes du réseau de neurones ont montré que leur effet reste très influencé par la qualité des intrants. En effet, le rôle de ces paramètres se limite à faire ressortir le maximum d'informations de données fournies au réseau et de faciliter la phase d'apprentissage. En effet, la qualité et la nature des intrants fournis au réseau jouent le rôle le plus important dans le perfectionnement de la classification.

Au début de la thèse, nous avons donné une grande importance à l'optimisation des paramètres internes du réseau tel que l'architecture, les paramètres d'apprentissage, format des données, fonction d'activation... etc. Les centaines de tests effectués ont montré que même

si les paramètres internes du réseau de neurone jouent un rôle non négligeable dans l'optimisation de la méthode, la nature et la qualité des intrants restent les facteurs les plus influents dans la précision d'une classification. Par exemple, les tests effectués avec différentes architectures ont montré que le nombre de niveaux et le nombre de neurones par niveau ont un effet très limité sur la précision finale de la classification (tableau 4-2). Ces paramètres affectent principalement l'évolution de l'apprentissage et la vitesse de convergence du réseau. Ainsi, avant de s'aventurer dans l'optimisation des paramètres internes du réseau, il faut partir sur des bons pieds en choisissant la meilleure combinaison des intrants disponibles.

Le choix des intrants du réseau doit tenir compte des phénomènes physiques intervenus lors de la formation de l'image. Étant donné la nature synthétique de l'image radar, son interprétation ne doit pas se fier uniquement à l'apparence visuelle de l'image mais, elle doit tenir compte de la relation qui existe entre les valeurs numériques des pixels et les caractéristiques physiques de la scène observée.

Nous avons évalué la performance des réseaux de neurones avec une série d'images Radarsat-1 en mode Standard S1 et S7. L'étude et l'optimisation de cet outil de classification ont permis d'obtenir un système efficace et prometteur pour une classification précise et efficace. Les résultats obtenus avec différentes combinaisons d'intrants ont montré que la performance de la classification augmente avec le nombre d'images utilisées pour produire les intrants du réseau (tableau 6-13). Toutefois, des contraintes économiques obligent souvent chaque utilisateur à chercher un meilleur rapport qualité prix entre la quantité de données requises et la précision escomptée.

La meilleure précision a été obtenue avec un réseau de neurones entraîné par 18 mesures de textures dérivées des six images disponibles. Avec cette combinaison, le réseau arrive à une précision de 86 % avec le groupe test et 96 % avec le groupe apprentissage. Toutefois la combinaison de quatre mesures de texture (Moyenne et Écart Type) extraites de deux images S1 et S7 offre une précision de (84 %) qui est légèrement inférieure à la première (18 textures). Dans ce cas, il ne sera pas raisonnable d'utiliser six images au lieu de deux images juste pour améliorer la précision d'environ 2 % surtout dans le cas où un grand nombre d'images serait nécessaire pour couvrir le site d'étude.

**Hypothèse 3 :** *Les réseaux de neurones tiennent compte différemment de l'apport de chaque source de données*

La validation de cette hypothèse consiste à vérifier si le réseau de neurone arrive à identifier l'apport de chaque source de données dans le processus de classification en amplifiant sa contribution positive pour certaines classes et en minimisant toute influence négative sur les autres classes.

Pour ce faire, nous avons vérifié si l'ajout d'une image S1 à une image S7 peut être bénéfique à l'identification de la classe forêt tout en gardant ou améliorant la bonne précision déjà obtenue pour les autres classes. Nous avons testé la contribution des images S1 sur la précision globale de la classification étant donné la faible précision obtenue avec ce mode d'acquisition dans l'identification des classes à l'intérieur d'un milieu humide.

Les précisions présentées au tableau 6-17 confirment bien cette hypothèse et montrent bien que, contrairement à la méthode de maximum de vraisemblance, les réseaux de neurones considèrent différemment l'apport de chaque source de données pour la prise de décision d'une classe donnée. Cette troisième hypothèse a donc été validée.

**Hypothèse 4 :** *Supériorité des réseaux de neurones aux méthodes conventionnelles de classification.*

La comparaison entre ces deux méthodes de classification a montré que les réseaux de neurones offrent une précision supérieure à celle obtenue avec la méthode du maximum de vraisemblance pour les classes végétales des milieux humides. Toutefois, quand il s'agit de la classe forêt, la précision obtenue avec la méthode de maximum de vraisemblance a été 6 % supérieure à celle obtenue par les réseaux de neurones.

Cette précision dans les classes des milieux humides est due principalement à la supériorité des réseaux de neurones quand il s'agit des classes naturelles où la distribution statistique des pixels est généralement asymétrique. L'hypothèse 4 a été validée pour les classes aux distributions asymétriques. Par contre, dans le cas d'une classe homogène, une méthode paramétrique de classification (comme celle du maximum de vraisemblance) peut offrir une précision supérieure aux réseaux de neurones.

En outre, contrairement aux confusions «aléatoires» enregistrées avec la méthode de maximum de vraisemblance, celles obtenues avec les réseaux de neurones suivent une certaine logique

liée à la ressemblance structurale des classes (voir tableau 6-10). Ainsi, les forêts se confondent uniquement avec les milieux humides fortement arborés, les milieux humides arbustifs se confondent uniquement avec les milieux humides moyennement arborés et ces derniers se confondent avec les milieux humides arbustifs et les milieux humides fortement arborés. C'est à dire, chaque classe se confond uniquement avec les classes qui lui sont adjacentes dans le gradient de la végétation (figure 6-16). En fait, dans les milieux humides étudiés dans cette thèse, le passage d'une classe à une autre se fait graduellement c'est qui rend difficile le traçage d'une limite précise des classes.

En somme, l'hypothèse 1 liée au potentiel de l'imagerie radar pour la cartographie des milieux humides a été confirmée. Par contre, la deuxième hypothèse sur l'effet discriminatoire des angles d'incidence n'a pas été validée. En ce qui concerne les réseaux de neurones, les hypothèses 3 et 4 liées à l'utilité de cet outil dans la classification des données de télédétection ont été pratiquement validées. Cependant, il est important de signaler que la supériorité des réseaux de neurones sur la méthode de maximum de vraisemblance a été confirmée que pour les classes ayant des distributions statistiques asymétriques.

## ***7.2. Orientation des travaux futurs***

Jusqu'à maintenant, les intrants utilisés dans le développement de cette méthodologie de classification a été restreint à des canaux de textures dérivés d'images de modes S1 et S7. Pour bien cerner l'effet de l'angle d'incidence sur la précision finale, d'autres aspects, comme l'apport d'autres modes d'acquisition et d'autres angles d'incidences, méritaient une évaluation en regard de leur effet sur la précision de la classification.

Les méthodes conventionnelles de classification, comme la méthode du maximum de vraisemblance, donnent souvent des excellents résultats quand il s'agit des classes homogènes et statistiquement séparables. Les précisions obtenues pour ce genre de classes sont souvent supérieures à celles obtenues par des méthodes non paramétriques comme les réseaux de neurones. Cette supériorité a été observée dans la précision obtenue pour la classe forêt où la distribution statistique des pixels est plus proche à la distribution normale que les trois autres classes (voir histogrammes de la figure 6-14). L'utilisation de deux méthodes différentes de classification peut être envisageable dans des telles situations. Ainsi, les classes homogènes et statistiquement séparables peuvent être préalablement identifiées par une méthode paramétrique. Ensuite, après avoir masquer la classe déjà identifiée, une méthode de réseau

de neurones peut être appliquée pour l'identification des classes hétérogènes (ayants des distributions asymétriques). En outre, une identification de la source réelle de l'erreur (omission et commission) peut être utile pour réduire le nombre de pixels incorrectement classifiés. Cette erreur peut être due soit à une mauvaise identification du groupe d'entraînement soit à la méthodologie de classification elle-même.

Finalement, dans une perspective d'avenir, nous croyions qu'il serait intéressant et relativement facile d'adapter la méthodologie développée dans cette thèse pour d'autres milieux naturels. Pour ce faire, le choix des intrants (textures, modes d'acquisition, angles d'incidence,... etc.) doit tenir compte des mécanismes d'interaction entre le signal radar et la composition physique et structurale des nouvelles classes.

# CHAPITRE 8

## Bibliographie

---

AUGUSTEJIN, M.F., CLEMENS, L.E., and SHAW, K. A., 1995, Performance Evaluation of Texture Measures for Ground Cover Identification in Satellite Images by Means of a Neural Network Classifier. IEEE Transactions on Geoscience and Remote Sensing, vol. 33, no. 3, 616-626.

BAGHDADI, N., BERNIER, M., GAUTHIER R., and NEESON, I., 2001, Evaluation of C-Band SAR data for wetlands mapping. International Journal of Remote Sensing. vol. 22. no. 1, pp. 71-88.

BENEDIKTSSON, J. A., SWAIN, P. H., and ERSOY, O. K., 1990, Neural Network Approaches Versus Statistical Methods in Classification of Multisource Remote Sensing Data. IEEE Transactions on Geoscience and Remote Sensing, vol. 28, no. 4, 540-552.

BENEDIKTSSON, J. A., and SVEINSSON, J. R., 1997, Feature extraction for multisource data classification with artificial neural networks. International Journal of Remote Sensing, vol. 18, no 4, 727-740.

BHATTACHARYA, U., and PARUI, S. K., 1997, An improved backpropagation neural network for detection of road-like feature in satellite imagery. International Journal of Remote Sensing, vol. 18, no 16, 3379-3394.

BISCHOF, H., SCHNEIDER, W., and PINZ, A. J., 1992, Multispectral Classification of Landsat-Images Using Neural Networks. IEEE Transactions on Geoscience and Remote Sensing, vol. 30, no. 3, 482 - 490.

- BISHOP, C. 1995. Neural network for pattern recognition. Clarendon Press, 482 p.
- BISHOP, Y. M. M., FEINBERG, S. E. and HOLLAND, P. W. 1975. Discrete Multivariate Analysis – Theory and Practice. MIT Press, Cambridge, Massachusetts. 575 p.
- BOISVERT, J. B., PULTZ, T.J., BROWN, R. J. and BRISCO, B. 1995a. Potential of Synthetic Aperture Radar for large-scale soil moisture monitoring: A review. Canadian Journal of Remote Sensing, vol. 22, no 1, pp. 2-13.
- BOISVERT, J. B., GWYN, Q. H. J., BRISCO, B., MAJOR, D. J. and BROWN, R. J. 1995b. Evaluation of soil moisture monitoring estimation techniques and microwave penetration depth for radar applications. Canadian Journal of Remote Sensing, vol. 21, no 2, pp. 110-123.
- BOISVERT, J. B., GWYN, Q. H. J., CHANZY, A., MAJOR, D. J., BRISCO, B., et BROWN, R. J., 1997, Effect of surface soil moisture gradients on modeling radar backscattering from bare fields. International Journal of Remote Sensing, vol. 18, no 1, 153-170.
- BONN, F. et ROCHON, G., 1992, Précis de télédétection : Principes et méthodes, vol 1, Presses de l'Université du Québec, AUPELF.
- BRUZZONE, L., CONESE, C., MASELLI, F., and ROLI, F., 1997, Multisource Classification of Complex Rural Areas by Statistical and Neural-Network Approaches. Photogrammetric Engineering & Remote Sensing, vol. 63, no. 5, 523-533.
- BUTEAU, P., DIGNARD, N., GRONDIN, P., 1994, Système de Classification des Milieux Humides du Québec. Publication du Ministère des Ressources Naturelles du Québec, Secteur des mines. pp. 2-10.
- CHAN, B., BIBBY, M. and H. HOLTZ, 1996, Predicting 800 to 500 degrees C weld cooling times by using backpropagation neural networks. Trans. Can. Soc. Mech. Eng., 20, 75-85.
- CHAN, J. C. -W., DEFRIES, R. S., ZHAN, X., HUANG, C., and TOWNSHEND, J. R. G., 2000, Texture Features for land cover change detection at 250m resolution – An application of machine learning feature subset selection. In proc. International Geoscience and Remote Sensing Symposium. IGARSS'2000, Honolulu Hawaii USA, July 24-28, 2000.

CHEN, K. S., YEN, S. K., and TSAY, D.W., 1997, Neural classification of SPOT imagery through integration of intensity and fractal information. *International Journal of Remote Sensing*, vol. 18, no 4, 763-783.

CHRISTENSEN, E. J. jr, JENSEN, E. W., RAMSEY, H. E., and MACKEY J., 1988, Aircraft MSS data registration and vegetation classification for wetland change detection. *International Journal of Remote Sensing*. vol. 9, no. 1, pp 23-38.

COHEN, J. 1960. A coefficient of Agreement for Nominal Scales. *Educational and Psychological Measurement*, vol. 20, no. 1, pp. 37-46.

CONGALTON, R. G., 1991. A review of Assessing the Accuracy of Classification of Remotely Sensed Data. *Remote Sensing of Environment*, vol. 37, pp. 35-46.

CUMMING, I. G., and VAN ZYL, J. J., 1989, Feature utility in polarimetric radar image classification. *Proceedings of IGARSS'89*, pp. 1841 – 1846.

DAMMAN, A. W. H., 1977, Geographic changes in the vegetation pattern of raised bogs in the Bay of Fundy region of Maine and New Brunswick. *Vegetatio*, vol. 35, pp. 137 – 151.

DAWSON, M. S., FUNG, A. K., and MANRY, M. T. 1997, A Robust Statistical-Based Estimator for Soil Moisture Retrieval from Radar Measurements. *IEEE Transactions on Geoscience and Remote Sensing*, vol. 35, no. 1, 57-67.

DANSEREAU, P., 1957. *Biogeography, an ecological perspective*. The Ronald Press Company, New York, 394 p.

DE SÈVE, D., TOUTIN T., DESJARDINS R. 1996, Evaluation de deux méthodes de correction géométrique d'images Landsat TM et ERS-1 RAS dans une étude de linéaments géologiques. *International Journal of Remote Sensing*, vol. 17, no 1, 131-142.

DOBSON, M. C., ULABY, F. T., PIERCE, L. E., SHARICK, T. L., BERGEN, K. M., KELLNDORFER, J., KENDRA, J. R., LI, E., LIN, Y. C., NASHASHIBI, A., SARABANDI, K., and SIQUEIRA, P., 1995. Estimation of forest biophysical characteristics in Northern Michigan with SIR-C/X-SAR, *IEEE Transactions on Geoscience and Remote Sensing*, vol. 33, no. 4, pp. 877-895.

FARDANESH, M. T., and ERSOY, O. K., 1998, Classification Accuracy Improvement of Neural Network Classifiers by Using Unlabeled Data. *IEEE Transactions on Geoscience and Remote Sensing*, vol. 36, no. 3, 1020-1025.

FITZGERALD, R. W. and B. G. LEES, 1994. Assessing the Classification Accuracy of Multisource Remote Sensing Data. *Remote Sensing of Environment*, vol. 47, pp. 362-368.

FOODY, G. M., and ARORA, M. K., 1997, An evaluation of some factors affecting the accuracy of classification by an artificial neural network. *International Journal of Remote Sensing*, vol. 18, no. 4, pp. 799-810.

FOODY, G. M. 2002. Status of land cover classification accuracy assessment. *Remote Sensing of Environment*, vol. 80, pp. 185-201.

FROST, V. S., SHANMUGAN, K. S., and HOLTZMAN, J. C., 1984. The Influence of Sensor and Flight Parameters on Texture in Radar Images. *IEEE Transactions on Geoscience and Remote Sensing*, vol. GE-22, no. 5, pp. 440- 448.

GARNEAU, M., 2000. Professeure, Département de géographie (Université du Québec à Montréal : UQAM) : Communication personnelle.

GIRARD M. C. & GIRARD C. M. 1999. *Traitement des données de télédétection*. DUNOD Ed. Paris, pp. 326-334.

GLASSER, P. H., 1992, Raised Bogs in Eastern North America – Regional Controls for species Richness and Floristic Assemblages. *Journal of Ecology*, vol. 80, pp. 535-554.

GOPAL, S., and WOODCOCK, C., 1996, Remote sensing of forest change using artificial neural networks. *IEEE transaction on geoscience and remote sensing*, vol. 34, no. 2, 398-404.

GORHAM, E., 1990, Biotic impoverishment in northern peatlands. In *the earth in transition : patterns and processes of biotic impoverishment*. Édité par G. M. Woodwell. Cambridge University Press, New York. pp. 65-98.

HAGAN, M. T., DEMUTH, H. B. and BEALE, M. H., 1996, *Neural Network Design*, Boston, MA (USA), PWS Publishing.

HARALICK, R. M., 1979, Statistical and structural approaches to texture. Proceedings of the IEEE, vol. 67, no. 5, pp. 786-804.

HARRIS J., and DIGBY-ARGUS S., 1986. The detection of wetlands in radar imagery. 10th Canadian Symposium on Remote Sensing, Edmonton, Alberta, vol.1, pp. 529-543.

HEERMANN, P. D., and KHAZENIE, N., 1992, Classification of Multispectral Remote Sensing Data Using a Back-Propagation Neural Network. IEEE Transactions on Geoscience and Remote Sensing, vol. 30, no. 1, 81-88.

HEPNER, G. F., LOGAN, T., RITTER, N., and BRYANT, N., 1990, Artificial Neural Network Classification Using a Minimal Training set: Comparison to Conventional Supervised Classification. Photogrammetric Engineering & Remote Sensing, vol. 56, pp. 469-473.

HOWARTH, P. J., WANG, J., SHANG, J., and JOLLINEAU, M. Y., 1998, Feasibility of Integrating Radar and Optical Data for Wetland Mapping and Monitoring : a Case Study from Southern Ontario. Symposium Radarsat ADRO, Montréal, Canada, Octobre 1998.

HUDSON, W. D. and C. W. RAMM, 1987. Correct Formulation of the Kappa Coefficient of Agreement. Photogrammetric Engineering and Remote Sensing, vol. 53, no 4, pp. 421-422.

KASISCHKE, E. S. and CHRISTENSEN, N. L. JR, 1990. Connecting forest ecosystem and microwave backscatter models. International Journal of Remote Sensing, vol. 11, no. 7, pp. 1277-1298.

KANELLOPOULOS, I., and WILKINSON, G.G., 1997, Strategies and best practice for neural network image classification. International Journal of Remote Sensing, vol. 18, no 4, 711-725.

KARAM, M. A., AMAR, F., FUNG, A. K., MOUGIN, E., LOPES, A., LE VINE, D. M., and BEAUDOIN, A., 1995. A microwave polarimetric scattering model for forest canopies based on vector radiative transfer theory. Remote Sensing of Environment, vol. 53, pp. 16-30.

KARRAS, A. D., 1995, An efficient constrained training algorithm for feedforward networks. IEEE Trans. Neural Networks, vol. 6, 1420-1434.

KASISCHKE, E. S., and BOURGEOU-CHAVEZ, L. L., 1997, Monitoring South Florida Wetlands Using ERS-1 SAR Imagery. Photogrammetric Engineering & Remote Sensing, vol. 63, no. 3, pp. 281-291.

KENNETT, R. G., and LI, F. K., 1989a, Seasat Over-Land Scatterometer Data, Part I : Global Overview of the Ku-Band Backscatter Coefficients. IEEE Transactions on Geoscience and Remote Sensing, vol. 27, no. 5, 592-605.

KENNETT, R. G., and LI, F. K., 1989b, Seasat Over-Land Scatterometer Data, Part II : Selection of Extended Area Land-Target Sites For the Calibration of Spaceborne Scatterometers. IEEE Transactions on Geoscience and Remote Sensing, vol. 27, no. 6, 779-788.

KIMES, D.S., RANSON, K. J., and SUN, G., 1997, Inversion of a forest backscatter model using neural networks. International Journal of Remote Sensing, vol. 18, 2181-2199.

KIMES, D.S., NELSON, R.F., MANRY, M. T., and FUNG, A.K., 1998, Attributes of neural networks for extracting continuous vegetation variables from optical and radar measurement. International Journal of Remote Sensing, vol. 19, no 5, 2639-2663.

LEWIS, A.J., HENDERSON, F. M., and HOLCOMB, D.W., 1998, The Geoscience Perspective, Chapter 3 : Radar Fundamentals : Technical Perspective. Manual of Remote Sensing, Third Edition, John Wiley & Sons. Inc., vol. 2, pp. 131-181.

LIVINGSTONE, G., WILLIAMS, D., and MORRISSEY, L., 1998, Monitoring Seasonal Inundation in Arctic Wetlands Using Radarsat ScanSAR Imagery. Symposium Radarsat ADRO, Montréal, Canada, Octobre 1998.

MAGAGI, R., BERNIER, M., and BOUCHARD, M.-C., 2002, Use of ground observations to simulate the seasonal changes in the backscattering coefficient of the subarctic forest. IEEE Transactions on Geoscience and Remote Sensing Journal. Vol. 40, pp. 281-297.

MAGAGI, R., BERNIER, M., and UNG, C. H., 2001b, Quantitative analysis of RADARSAT SAR data over a sparse forest canopy. Soumis à IEEE Transactions on Geoscience and Remote Sensing Journal.

McCLELLAND, J. L., and RUMALHART, D. E., 1986, Parallel distributed processing, MIT Press, vol. 1. , Cambridge (MA).

McCULLOCH, W. S., and PITTS W., 1943. A logical calculus of the ideas immanent in nervous activity, Bull. Mathem. Biophys, 5, p.115-133.

MILNE, A. K., and HORN, G., 1998a, Monitoring Wetland Inundation Patterns Using Radarsat Multitemporal Data. Symposium Radarsat ADRO, Montréal, Canada, Octobre 1998.

MILNE, A. K., 1998b, Monitoring wetlands in northern Australia using Radarsat. Symposium Radarsat ADRO, Montréal, Canada, Octobre 1998.

MULLINS, D.W., and LECONTE, R., 1993, Determination of wetland water level changes using C-Band SAR Imagery. 16<sup>th</sup> Canadian Symposium on Remote Sensing, 337-340.

PAOLA, J. D., and SCHOWENGERDT, R. A., 1994, Comparisons of neural networks to standard techniques for image classification and correlation. Proceedings of the International Geoscience and Remote Sensing Symposium (IGARSS'94). Pasadena, CA (USA), August 1994, pp. 1404-1406.

PAOLA, J. D., and SCHOWENGERDT, R. A., 1995, A review and analysis of backpropagation neural networks for classification of remotely-sensed multi-spectral imagery. International Journal of Remote Sensing, vol. 16, no 16, pp. 3033-3058.

PCI/EASI/PACE Software. PCI Geomatics INC., 1997.

PIPER, J., 1992, Variability and bias in experimentally measured classifier error rates. Pattern Recognition Letters, vol. 13, pp. 685-692.

PIERCE, L. E., SARABANDI, K., and ULABY, F. T., 1994, Application of an artificial neural network in canopy scattering inversion. International Journal of Remote Sensing, vol. 15, no 16, 3263-3270.

POPE, K. O., REY-BENAYAS, J. M., and PARIS, J.F., 1994, Radar Remote Sensing of Forest and Wetland Ecosystems in the Central American Tropics. Remote Sensing of Environment, vol.48, 205-219.

RAMSEY III, E.W., and JENSEN, J. R., 1996, Remote Sensing of Mangrove Wetlands : Relating Canopy Spectra to site-Specific Data. Photogrammetric Engineering & Remote Sensing, vol. 62, no. 8, pp. 939-948.

RAMSEY III, E.W., CHAPPELL, D.K., and BALDWIN, D. G., 1997, AVHRR Imagery Used to Identify Hurricane Damage in a Forested Wetland of Louisiana. Photogrammetric Engineering & Remote Sensing, vol. 63, no. 3, pp. 293-297.

RAMSEY III, E.W., CHAPPELL, D.K., JACOBS, D.M., SAPKOTA, S.K., and BALDWIN, D. G., 1998, Resource Management of forested Wetlands : Hurricane Impact and Recovery Mapped by Combining Landsat TM and NOAA AVHRR Data. *Photogrammetric Engineering & Remote Sensing*, vol. 64, no.7, pp. 733-738.

RANEY, R.K., 1998, Principles & Applications of Imaging Radar, Chapter 2 : Radar Fundamentals : Technical Perspective. *Manual of Remote Sensing, Third Edition*, John Wiley & Sons. Inc., vol. 2, pp. 9-130.

RICHARDS, J. A., 1993, *Remote Sensing Digital Image Analysis : An Introduction*. Second edition. Springer-Verlag Publishing Company. Germany.

RSI. RADARSAT Illuminated : Your Guide to Products & Services, Preliminary version, July 1995. Education Department, RADARSAT International, Richmond (BC) Canada.

RUMELHART, D. E., HINTON, G. E. and R. J. WILLIAMS, 1986, Learning internal representation by error propagation. *Parallel distributed processing : Exploration in the microstructure of cognition*. MIT. , Cambridge Press, MA pp 318-364.

SADER, S. A., AHL, D., and LIOU, W. S., 1995, Accuracy of Landsat-TM and GIS Rule-Based Methods for Forest Wetland Classification in Maine. *Remote Sensing of Environment*, vol. 53, pp.133-144.

SCHOWENGERDT, R. A., 1997. *Remote Sensing: Models and Methods for Image Processing*, Second Edition, Academic Press Limited. 522 p.

SETIONO, R. and L. C. K HUI, 1995, Use of Quasi-Newton method in a feedforward neural network construction algorithm. *IEEE Trans. Neural Networks*, vol. 6, 273-277.

SEUTHÉ C., et BUTEAU P., 1994. Les tourbières au Québec: une ressource importante à connaître et à protéger. *Téledétection de l'environnement dans l'espace francophone*. Publié aux presses de l'Université du Québec, Chapitre 5, pp. 101-112.

SHI, J., DOZIER, J., and ROTT, H., 1994, Snow mapping in Alpine regions with Synthetic Aperture Radar. *IEEE Transactions on Geoscience and Remote Sensing*, vol. 32, pp. 152- 158.

SMITS, P. C., DELLEPIANE, S. G., and SCHOWENGERDT, R. A., 1999. Quality assessment of image Classification algorithms: a review and a proposal of a cost based approach. *International Journal of Remote Sensing*, vol. 20, no. 8, pp. 1461-1486.

Symposium RADARSAT ADRO. Bringing radar applications down to Earth, , October 13-15 1998, Montreal, Canada.

TARASSENKO, L. 1998. *A Guide to Neural Computing Applications*. New York-Toronto, John Wiley & Sons Inc - Arnold, 139p

TOUTIN, T., et CARBONNEAU, Y. 1992a, La création d'ortho-images avec MNE : Description d'un nouveau système. *Journal canadien de télédétection*, vol. 18, no. 3, pp. 136-141.

TOUTIN, T. and CARBONNEAU, Y. 1992, MOS and SEASAT Image Geometric Corrections. *IEEE Transactions on Geoscience and Remote Sensing*, vol. 30, no. 3, 603-609.

TOWNSEND, P. A., 1998, Detection of Hydroperiod in Forested Wetlands using Multi-temporal RADARSAT Imagery. *Symposium Radarsat Adro, Montréal, Canada, Octobre 1998*.

TOWNSEND, P. A., 2002, Estimating forest structure in wetlands using multitemporal SAR. *Remote Sensing of Environment*, vol. 79, pp. 288-304.

ULABY, F. T., BATLIVALA, P. P. and DOBSON M. C., 1978, Microwave Backscatter Dependence on Surface Roughness, Soil Moisture and Soil Texture, Part I: Bare soil. *IEEE Transactions on Geoscience and Remote Sensing*, GE-16, pp. 286-295.

ULABY, F. T., MOORE, R.K., KUNG, A. D., *Microwaves Remote Sensing, Active and Passive*, Vol. 2, Addison-Wesley Publishing Company, 1982a, pp 457 - 1064 pages.

ULABY, F. T., MOORE, R.K., KUNG, A. D., *Microwaves Remote Sensing, Active and Passive*, Vol. 3, Addison-Wesley Publishing Company, 1982b, pp 1065 - 2162 pages.

ULABY, F. T., KOUYATE, F., BRISCO, B., and LEE WILLIAMS, T. H., 1986. Textural Information in SAR Images. *IEEE Transactions on Geoscience and Remote Sensing*, vol. GE-24, no. 2, pp. 235-245.

ULABY, F. T., SARABANDI, K., McDonald, K., WHITT, M., and DOBSON, M. C., 1990. Michigan microwave scattering model. *International Journal of Remote Sensing*, vol. 11, no. 7, pp. 1223-1253.

VOGL, T. P., MANGIS, J. K., RIGLER, A. K., ZINK, W. T. and ALKON, D. L. 1988. Accelerating the convergence of the back-propagation method. *Biological Cybernetics*, vol. 59, pp. 257-263.

WANG, J., SHANG, J., BRISCO, B., and BROWN, R. J., 1998, Evaluation of multirate ERS-1 and multispectral Landsat imagery for wetland detection in southern Ontario. *Canadian Journal of Remote Sensing*, vol. 25, no 1, pp. 60-68.

WARNER, B. G., 2000. Directeur, Wetlands Research Centre (Université de Waterloo) : Communication personnelle.

WERBOS, P. J., 1974, Beyond regression : new tools for prediction and analysis in the behavioral sciences. Thèse de Ph.D. en mathématiques appliquées (1974).

WIKANTIKA, K., HARTO, A. B., TATEISHI, R., WIHARTINI, J., TETUKO, S.S., and PARK, J.H., 2000a, An investigation of textural characteristics Associated with spectral information for land use classification. In proc. International Geoscience and Remote Sensing Symposium. IGARSS'2000, Honolulu Hawaii USA, July 24-28, 2000.

WIKANTIKA, K., WIHARTINI, J., TATEISHI, R., and HARTO, A. B., 2000b, Spectral and textural information of multisensor data for land use classification in metropolitan area. In proc. International Geoscience and Remote Sensing Symposium. IGARSS'2000, Honolulu Hawaii USA, July 24-28, 2000.

YOSHIDA, T., and OMATU, S., 1994, Neural Network Approach to Land Cover Mapping. *IEEE Transactions on Geoscience and Remote Sensing*, vol. 32, no. 5, 1103-1109.

ZHUANG, X., ENGEL, B.A., LOZANO-GARCIA, D.F., FERNANDEZ, R.N., and JOHANNSEN, C. J., 1994, Optimization of training data required for neuro-classification. *International Journal of Remote Sensing*, vol. 15, no 16, 3271-3277.

# ANNEXE A

## Distribution Statistique des classes:

Image 1: S1 (03/08/1998)

Image 2: S1 (14/10/1998)

Image 3: S1 (11/06/1999)

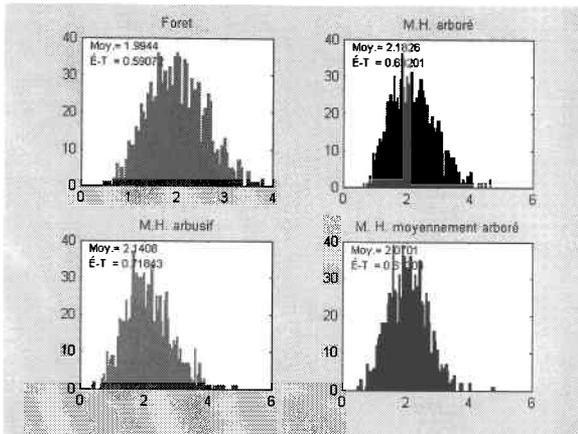
Image 4: S7 (04/02/1999)

Image 5: S7 (13/04/1999)

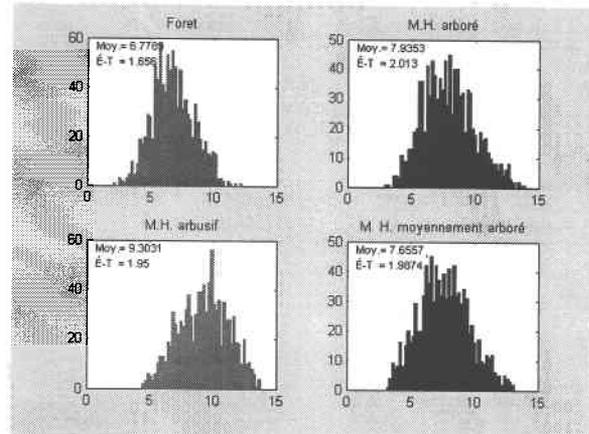
Image 6: S7 (31/05/1999)

## Textures : Fenêtre (3 x 3)

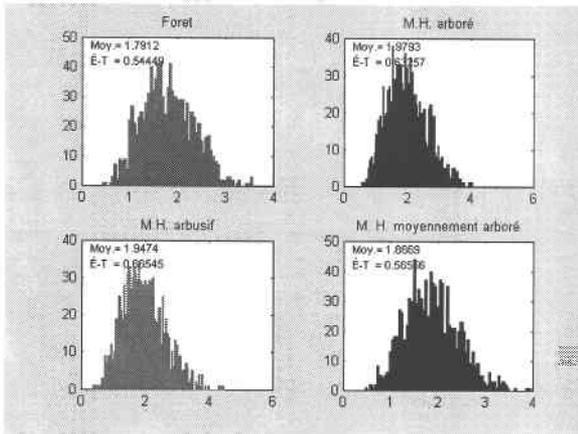
### Texture Dissemblance (image 1)



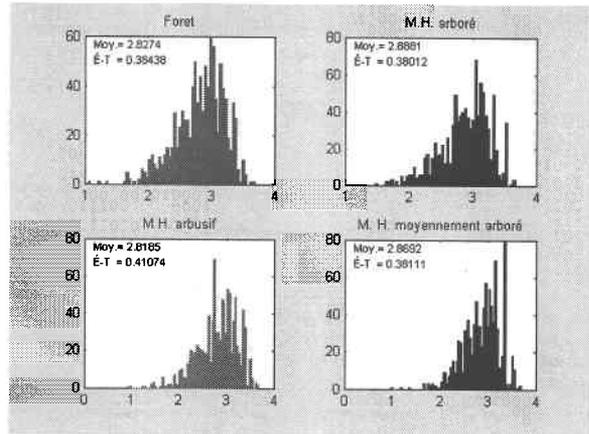
### Texture Moyenne (image 1)



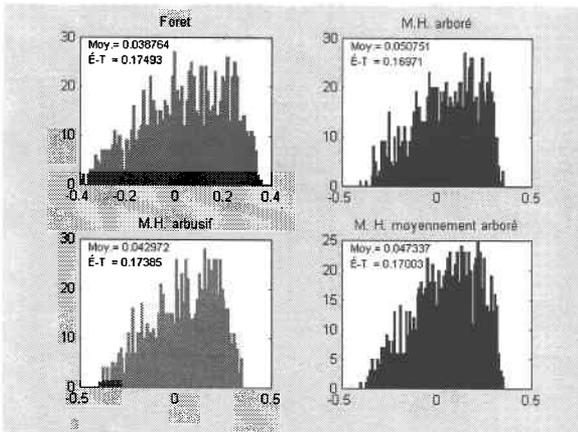
### Texture Écart Type (image 1)



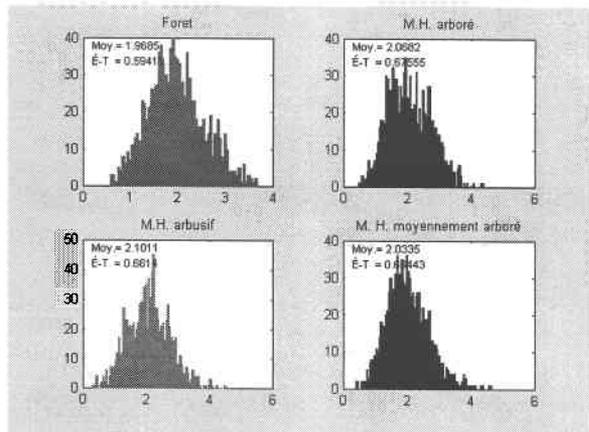
### Texture Entropie (image 1)



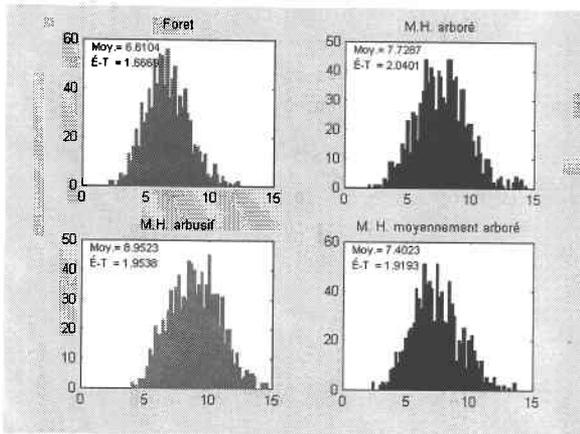
### Texture Corrélation (image 1)



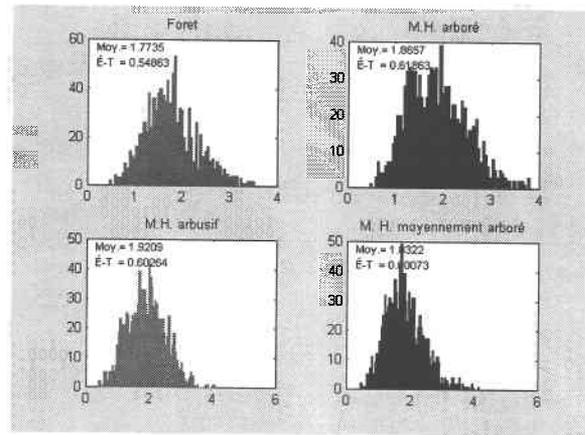
### Texture Dissemblance (image 2)



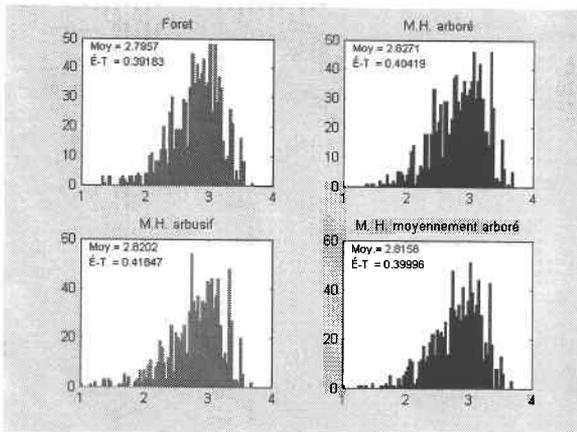
**Texture Moyenne (image 2)**



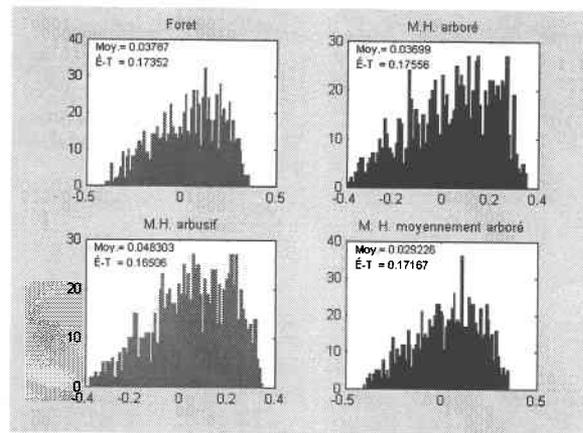
**Texture Écart Type (image 2)**



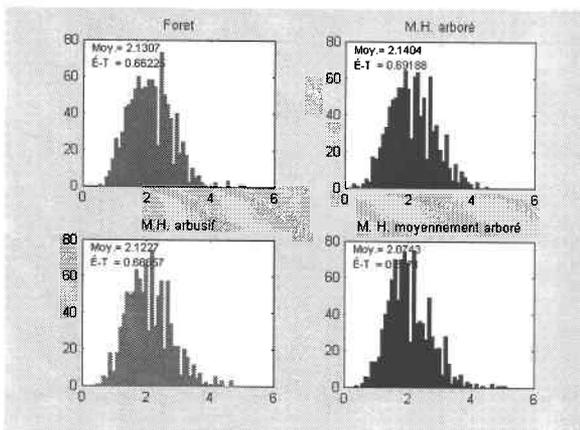
**Texture Entropie (image 2)**



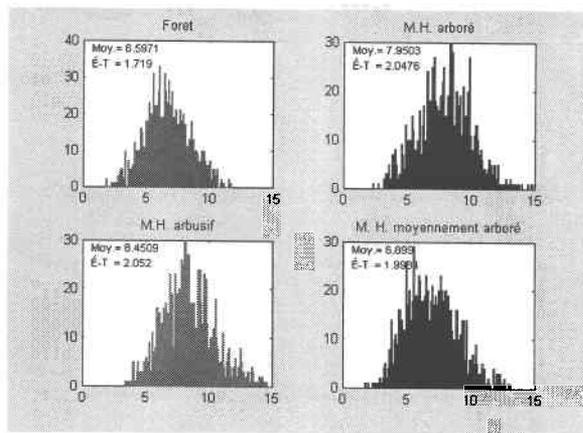
**Texture Corrélation (image 2)**



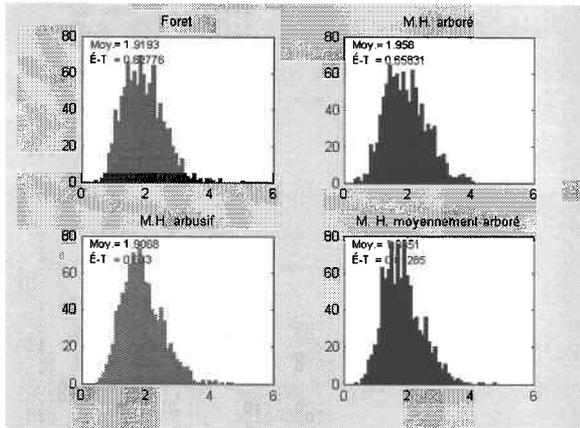
**Texture Dissemblance (image 3)**



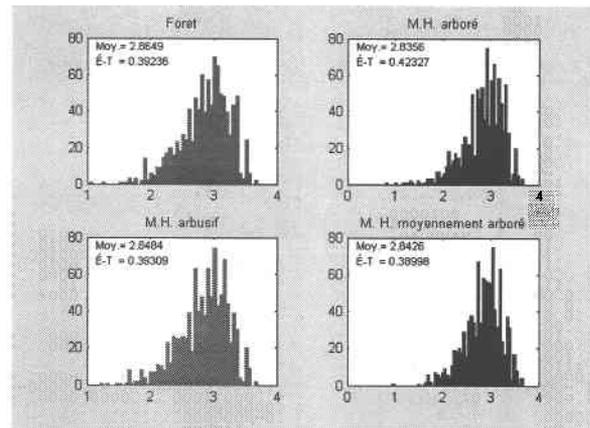
**Texture Moyenne (image 3)**



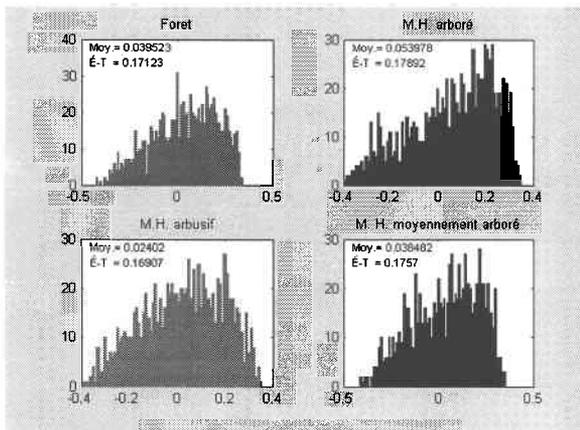
**Texture Écart Type (image 3)**



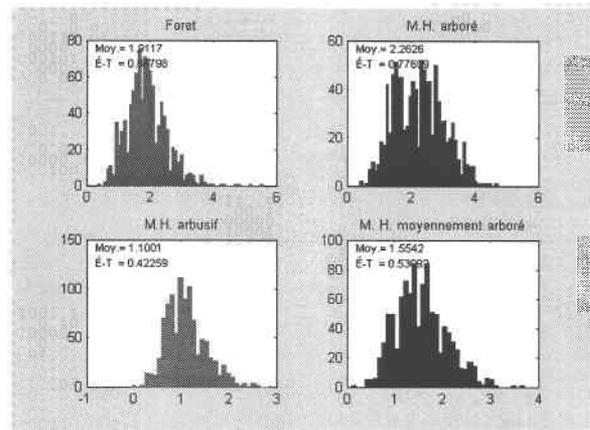
**Texture Entropie (image 3)**



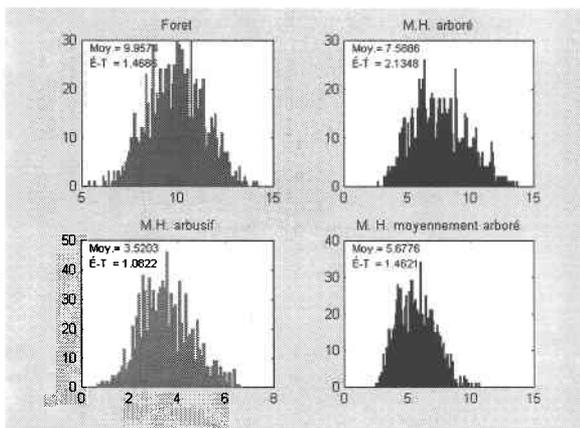
**Texture Corrélation (image 3)**



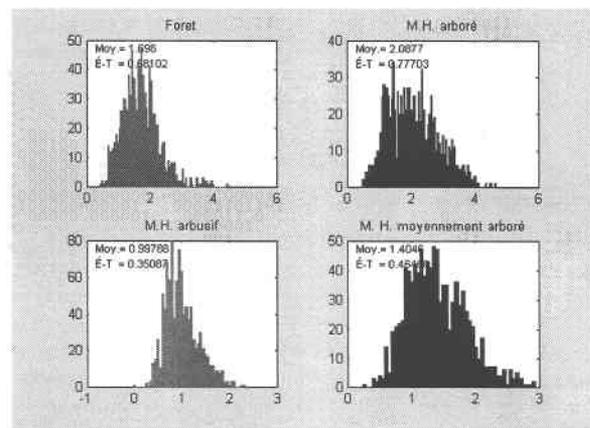
**Texture Dissemblance (image 4)**



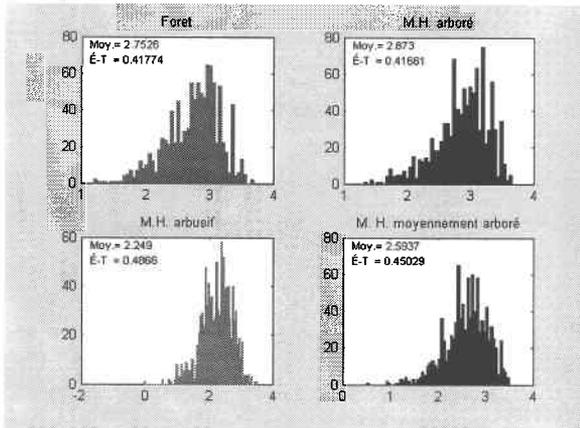
**Texture Moyenne (image 4)**



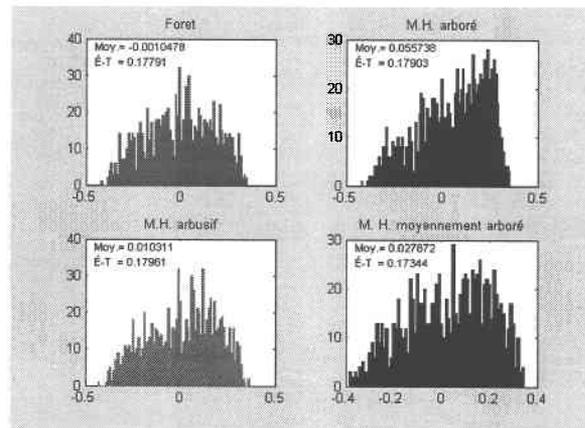
**Texture Écart Type (image 4)**



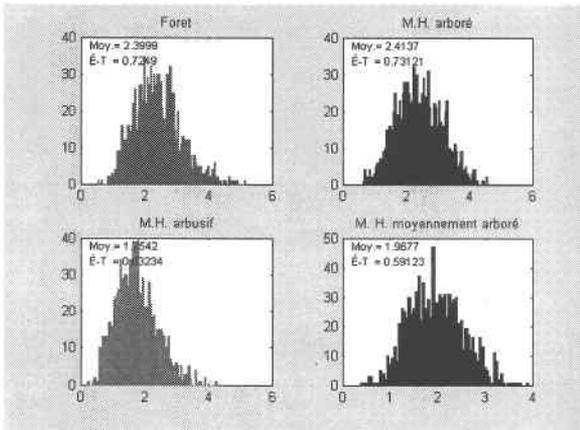
### Texture Entropie (image 4)



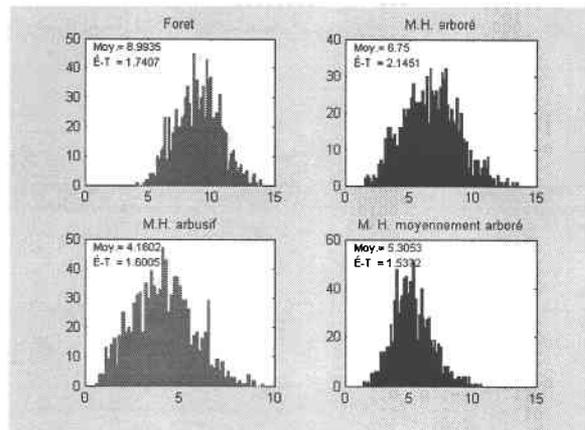
### Texture Corrélation (image 4)



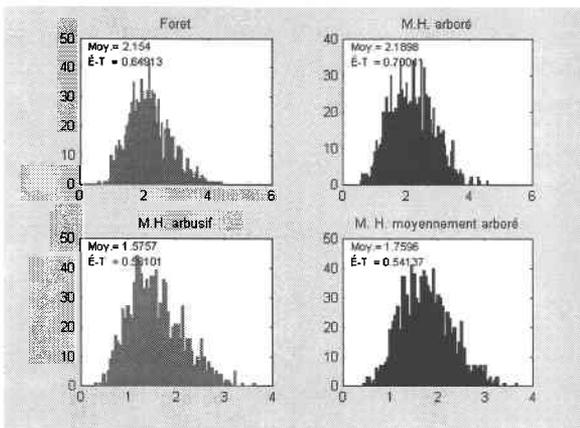
### Texture Dissemblance (image 5)



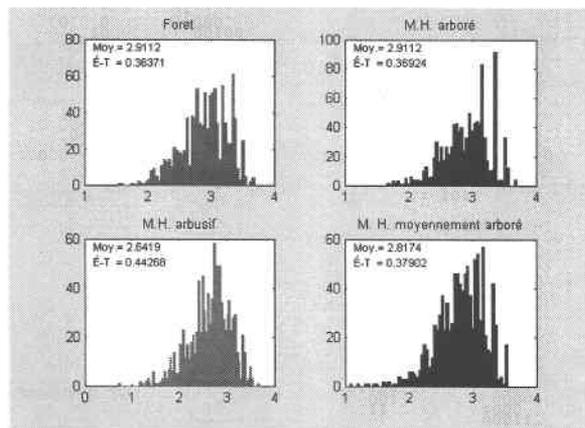
### Texture Moyenne (image 5)



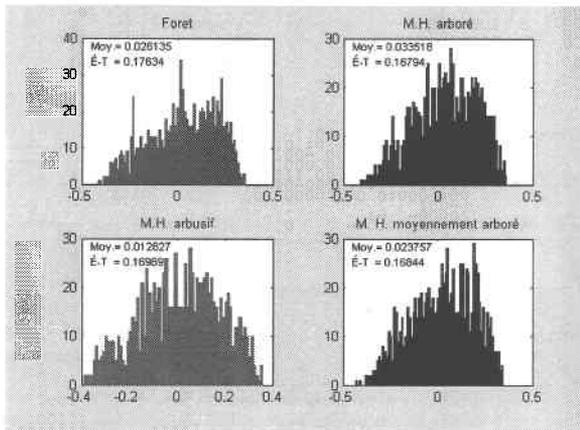
### Texture Écart Type (image 5)



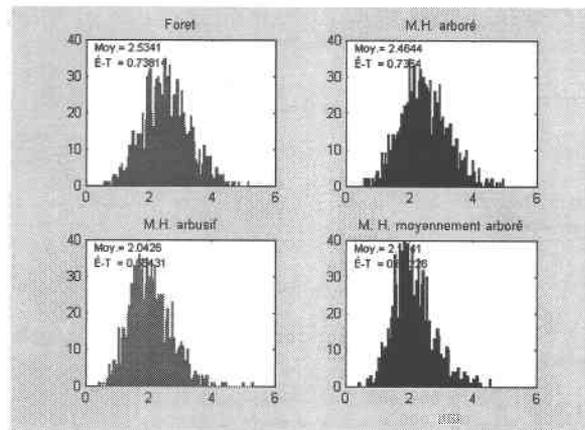
### Texture Entropie (image 5)



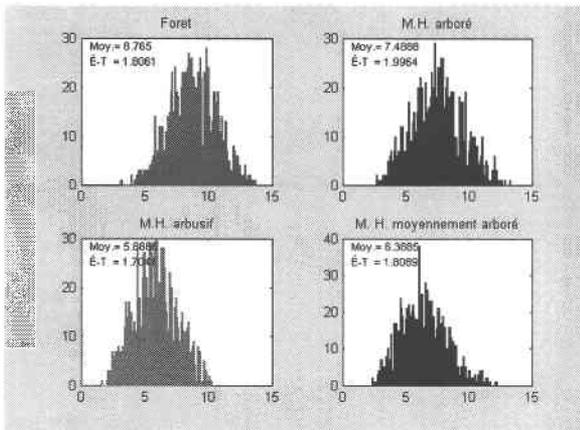
**Texture Corrélation (image 5)**



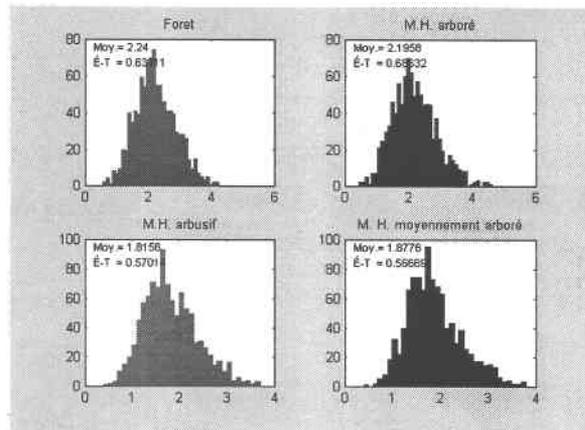
**Texture Dissemblance (image 6)**



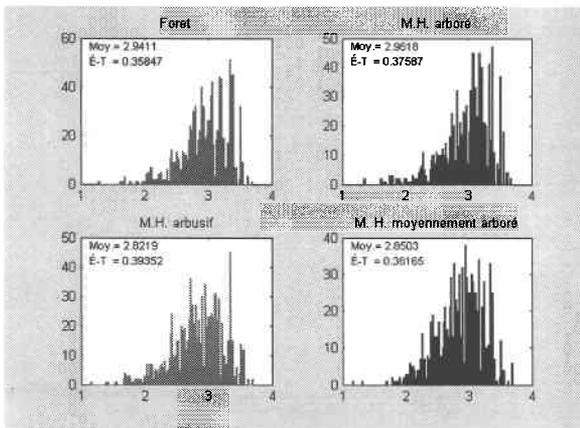
**Texture Moyenne (image 6)**



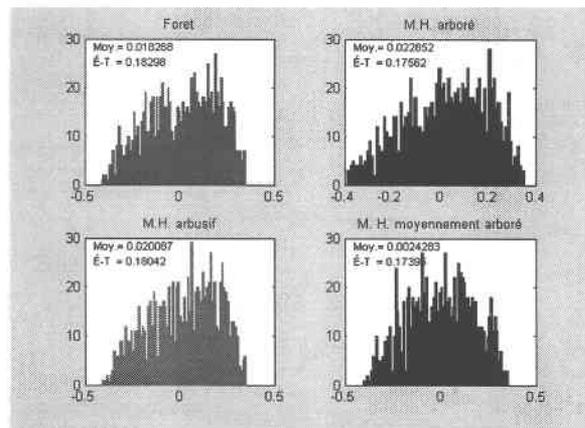
**Texture Écart Type (image 6)**



**Texture Entropie (image 6)**

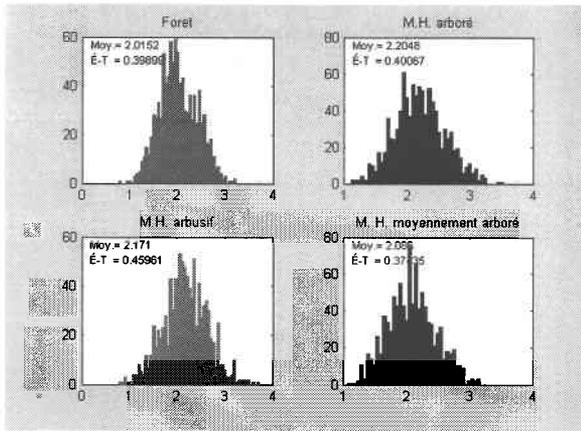


**Texture Corrélation (image 6)**

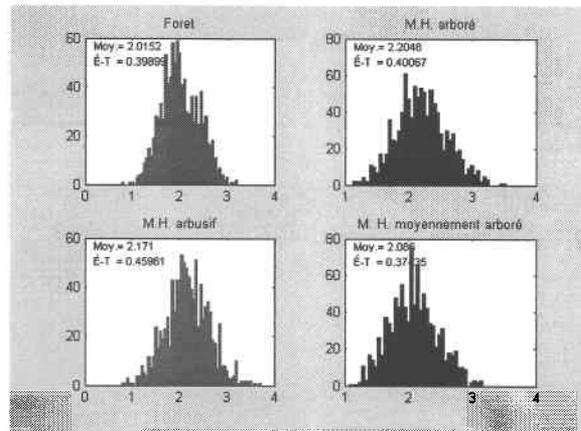


## Textures : Fenêtre (5 x 5)

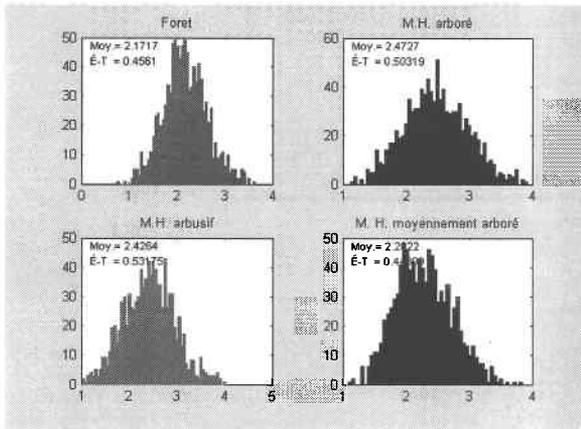
Texture Dissemblance (image 1)



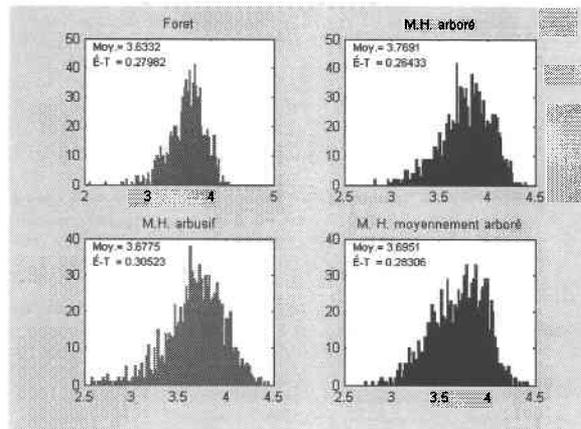
Texture Moyenne (image 1)



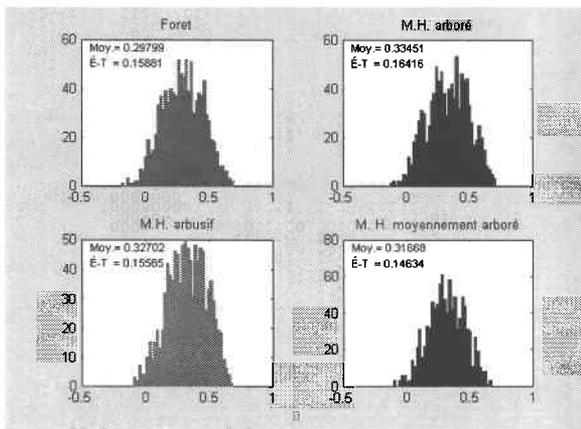
Texture Écart Type (image 1)



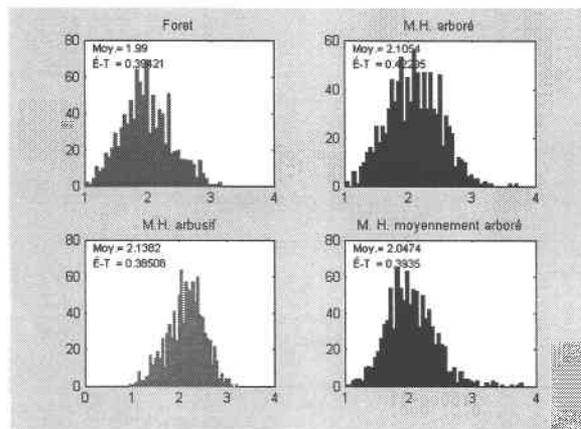
Texture Entropie (image 1)



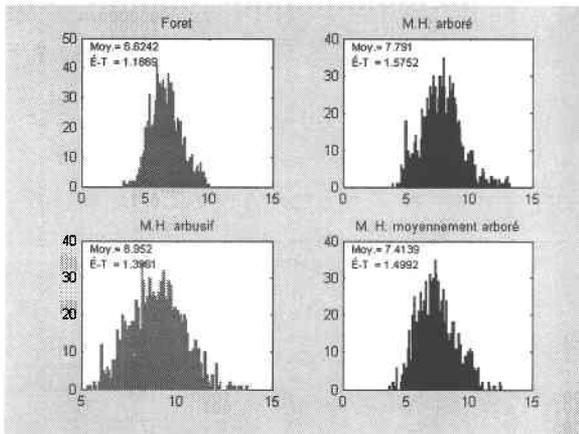
Texture Corrélation (image 1)



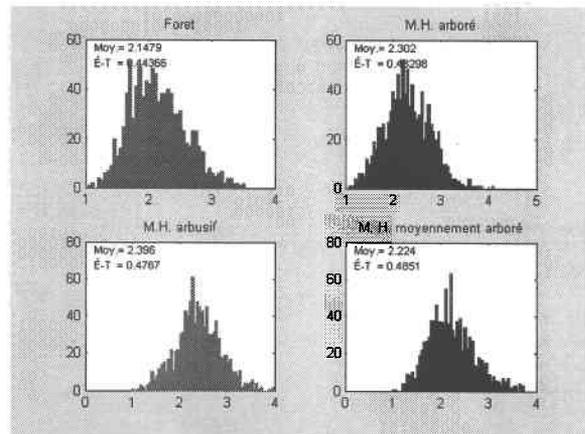
Texture Dissemblance (image 2)



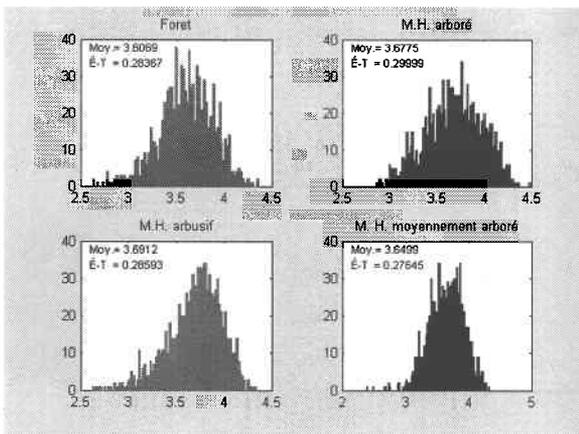
**Texture Moyenne (image 2)**



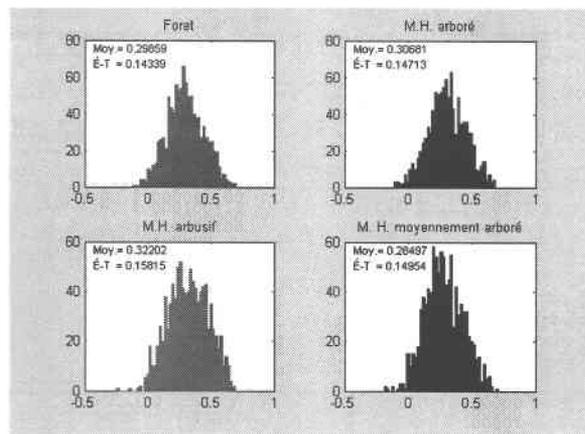
**Texture Écart Type (image 2)**



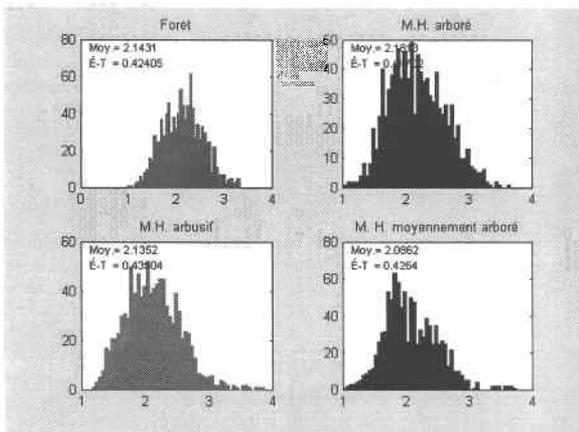
**Texture Entropie (image 2)**



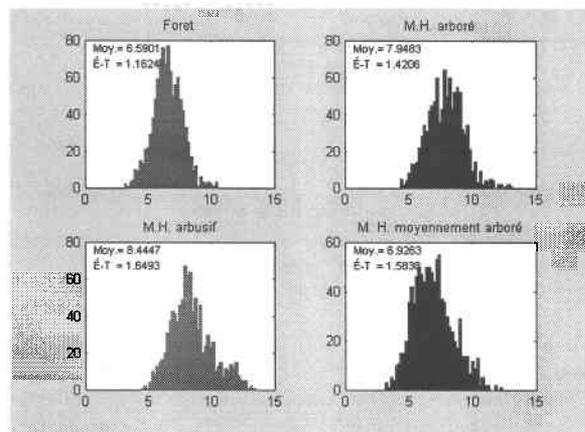
**Texture Corrélation (image 2)**



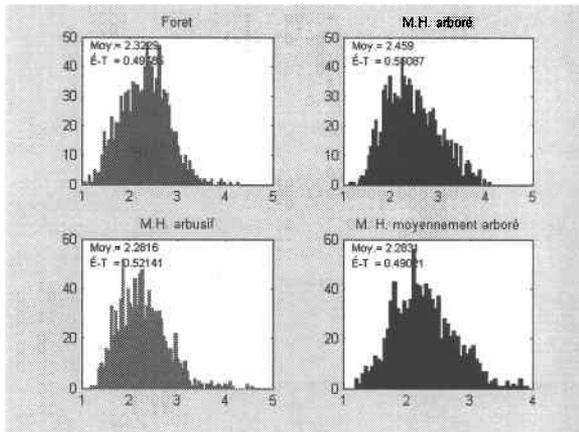
**Texture Dissemblance (image 3)**



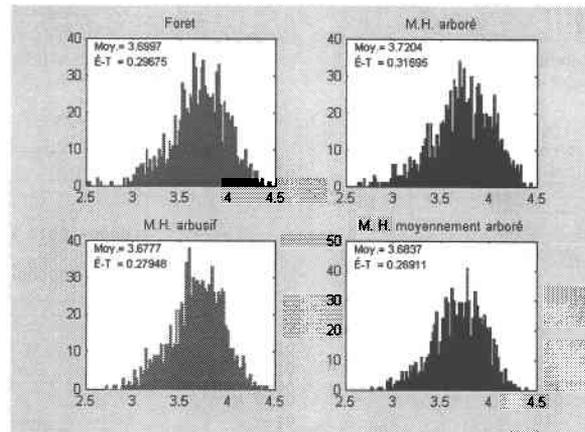
**Texture Moyenne (image 3)**



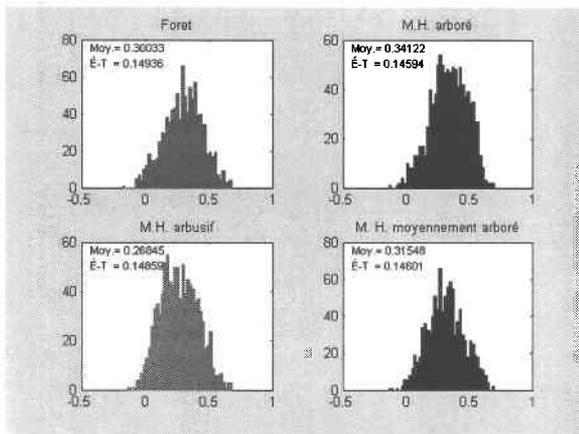
**Texture Écart Type (image 3)**



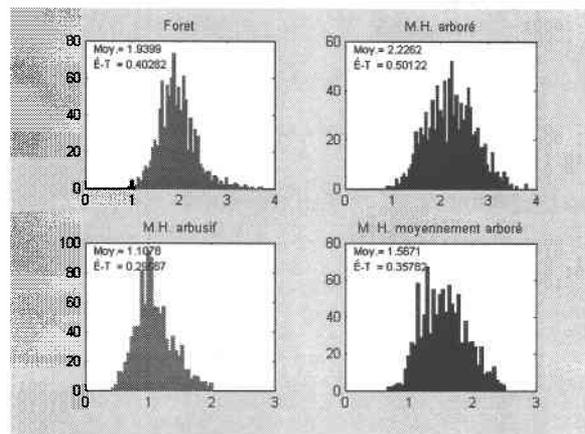
**Texture Entropie (image 3)**



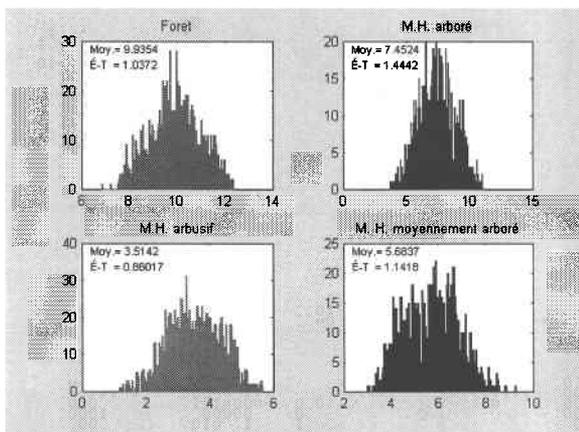
**Texture Corrélation (image 3)**



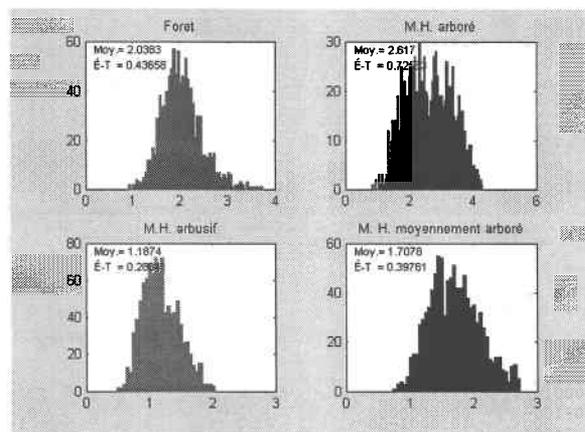
**Texture Dissemblance (image 4)**



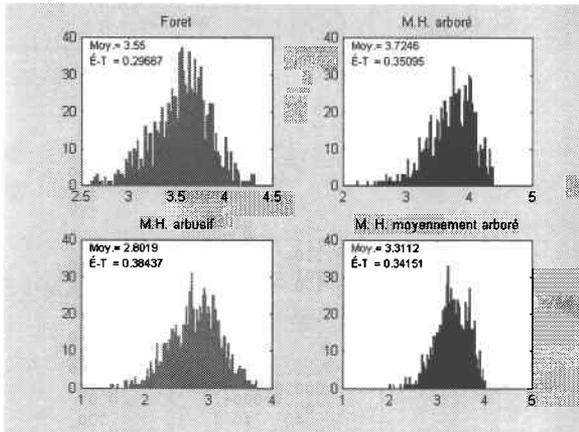
**Texture Moyenne (image 4)**



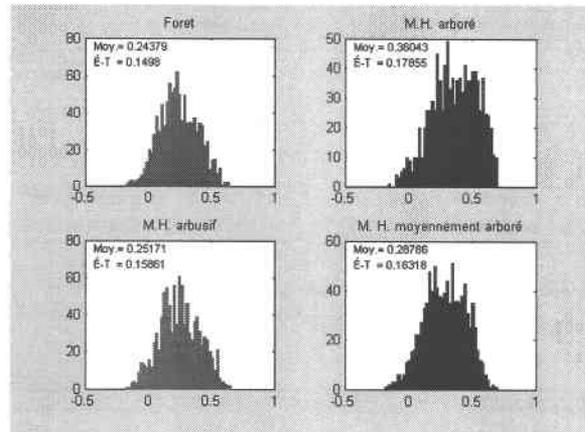
**Texture Écart Type (image 4)**



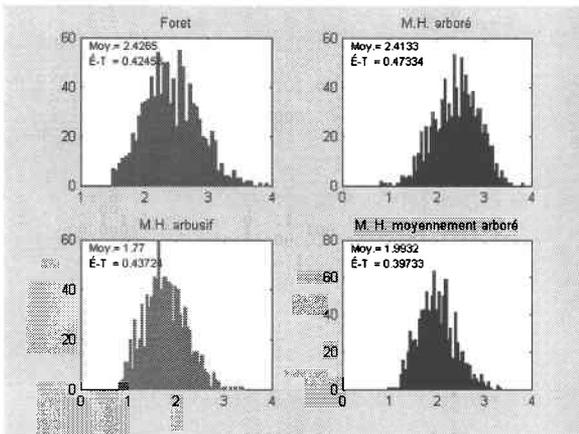
**Texture Entropie (image 4)**



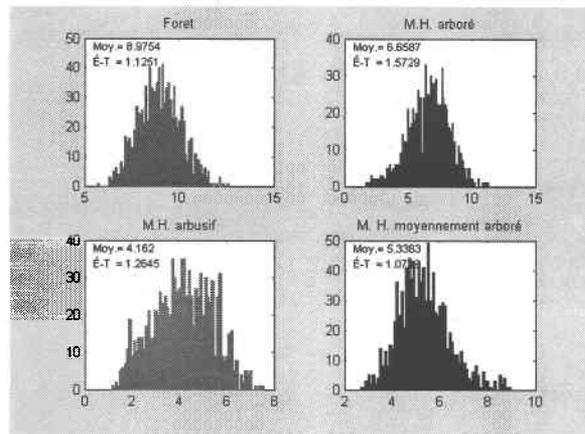
**Texture Corrélation (image 4)**



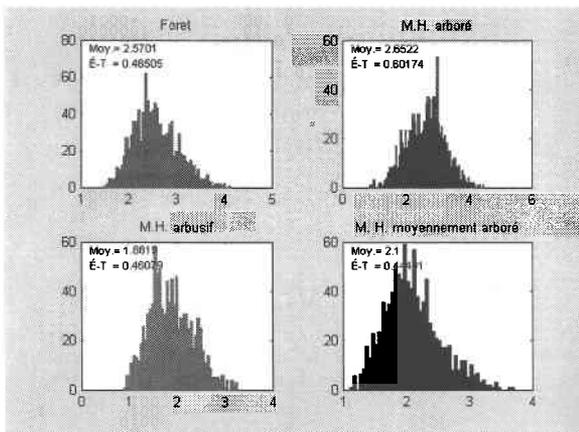
**Texture Dissemblance (image 5)**



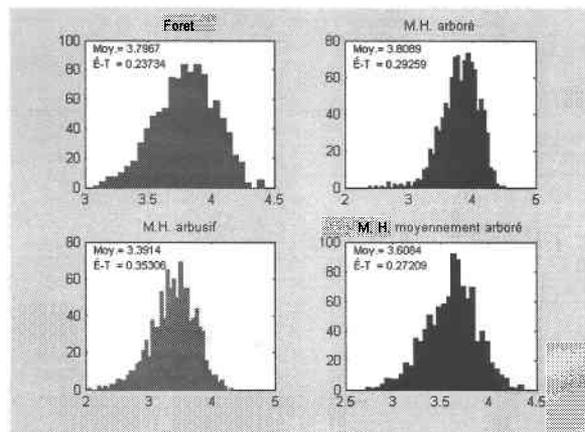
**Texture Moyenne (image 5)**



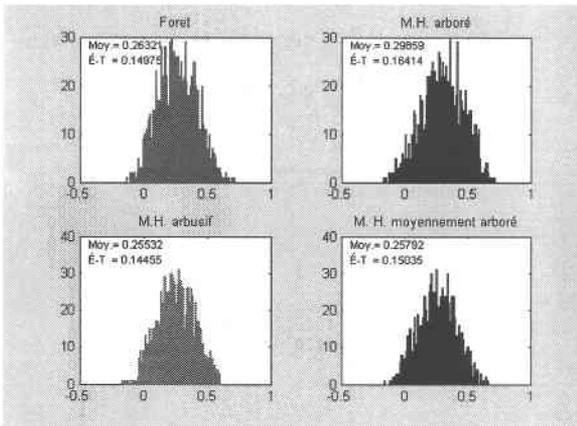
**Texture Écart Type (image 5)**



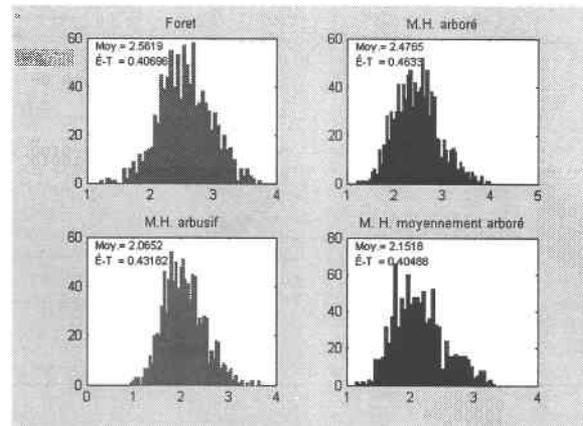
**Texture Entropie (image 5)**



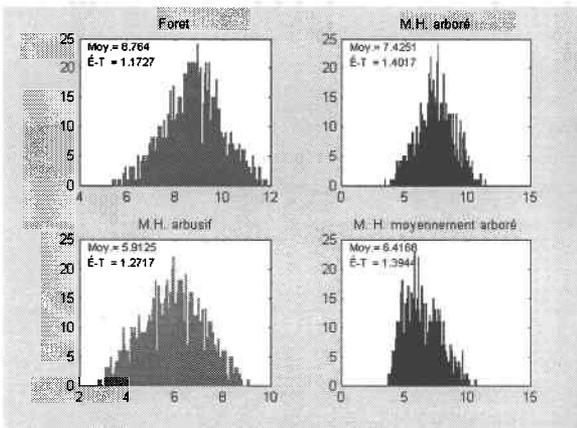
**Texture Corrélation (image 5)**



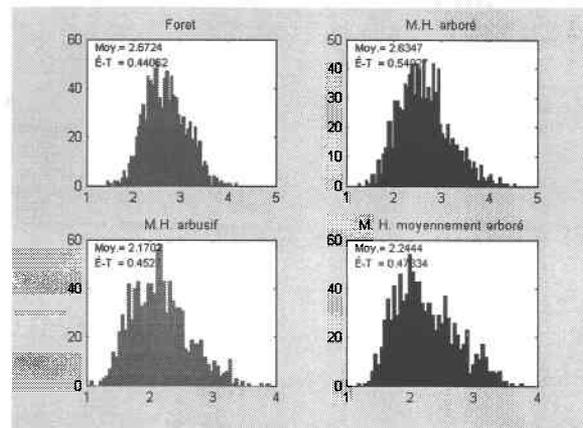
**Texture Dissemblance (image 6)**



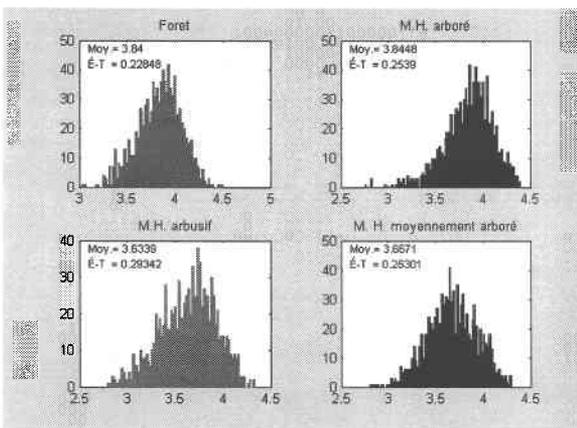
**Texture Moyenne (image 6)**



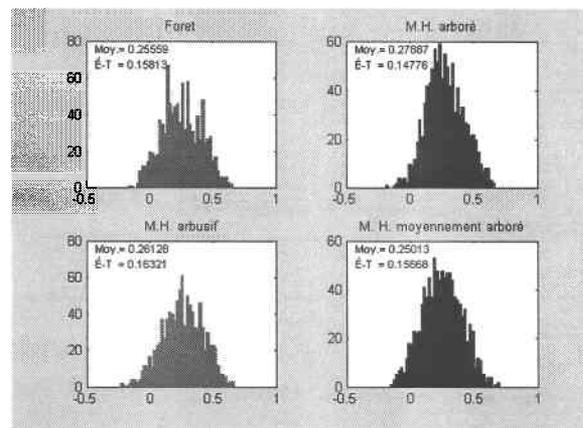
**Texture Écart Type (image 6)**



**Texture Entropie (image 6)**

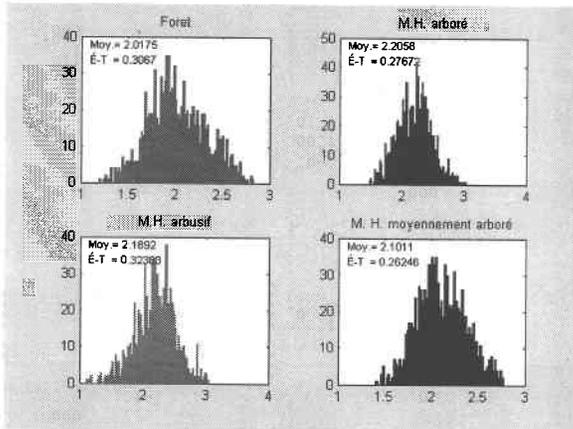


**Texture Corrélation (image 6)**

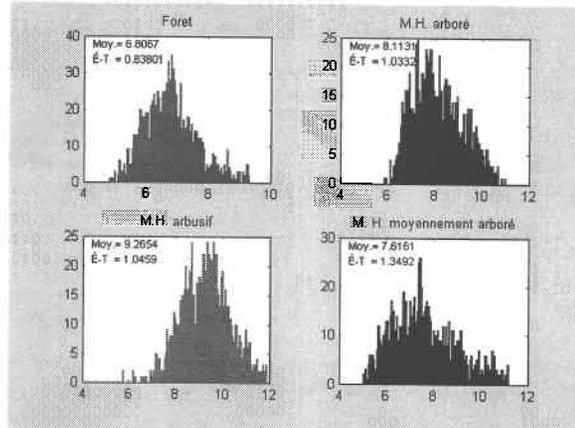


## Textures : Fenêtre (7 x 7)

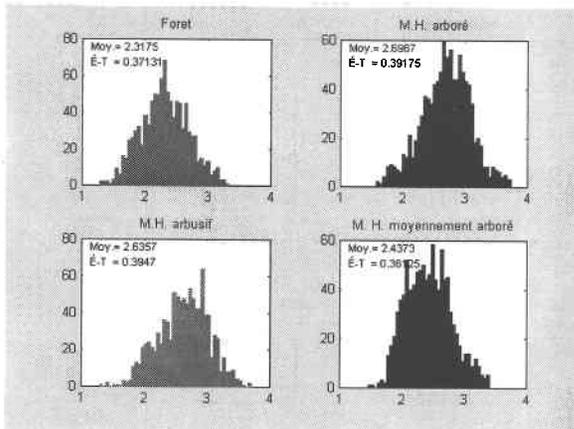
### Texture Dissemblance (image 1)



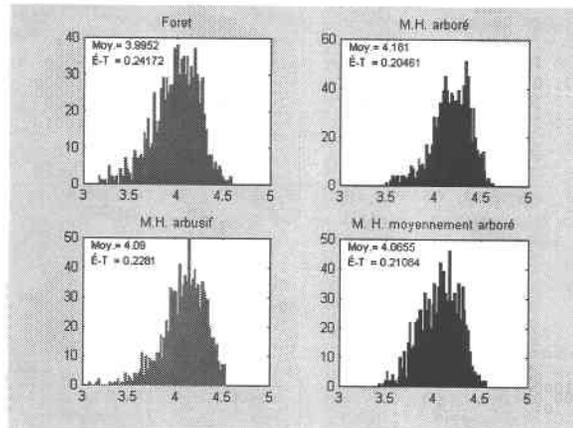
### Texture Moyenne (image 1)



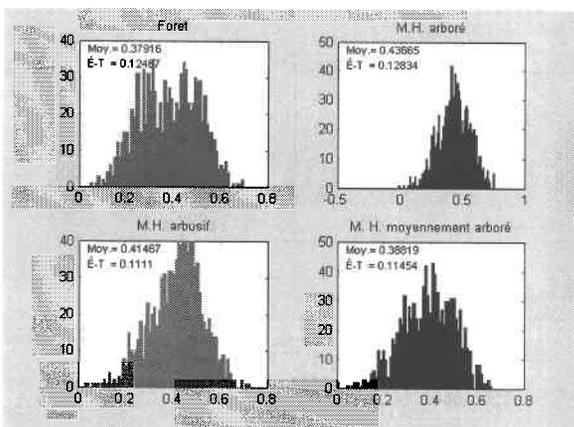
### Texture Écart Type (image 1)



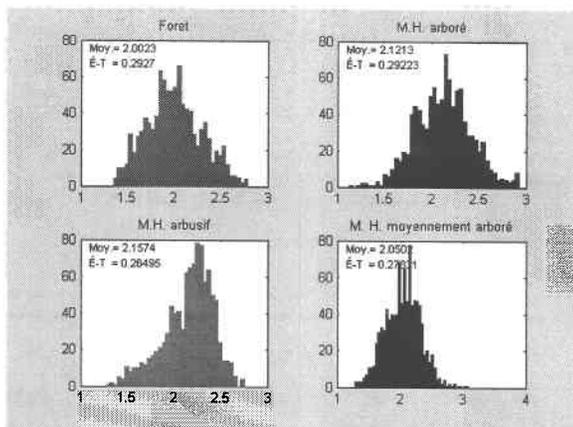
### Texture Entropie (image 1)



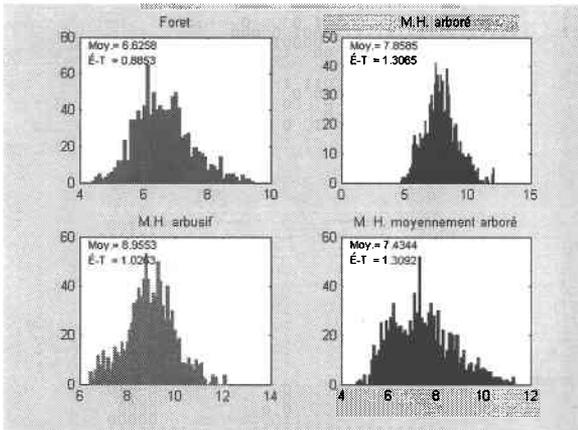
### Texture Corrélation (image 1)



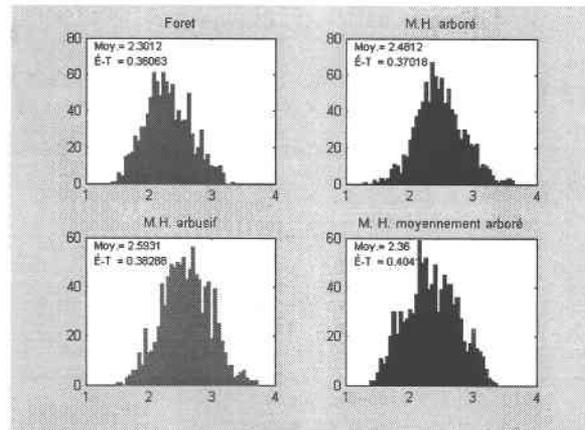
### Texture Dissemblance (image 2)



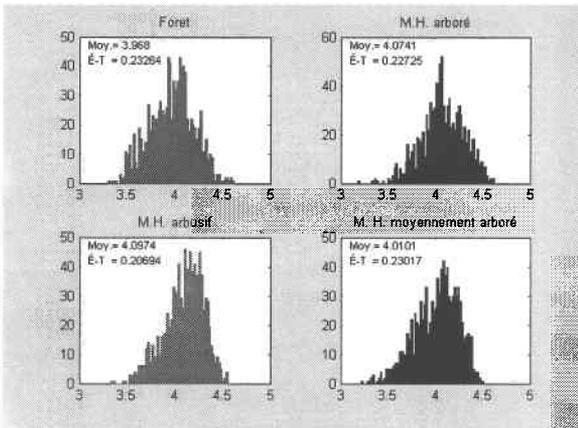
### Texture Moyenne (image 2)



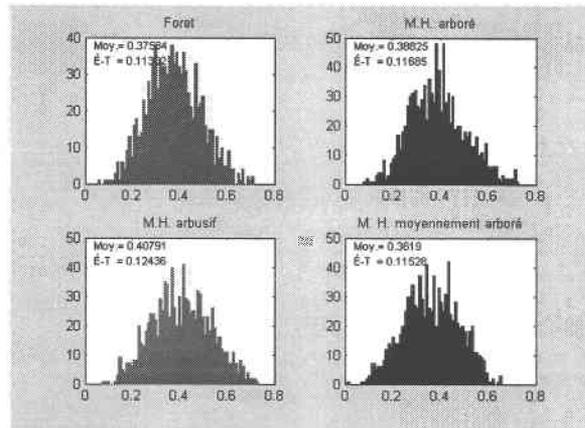
### Texture Écart Type (image 2)



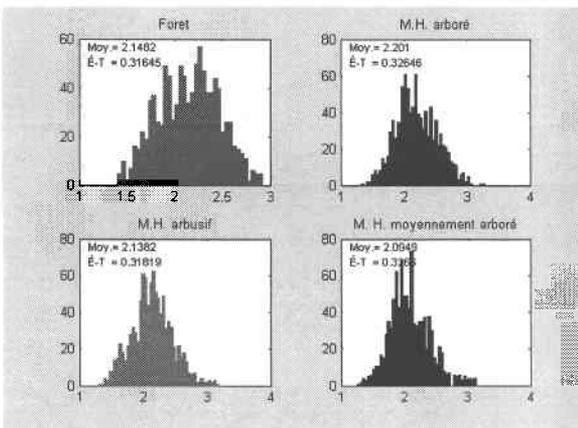
### Texture Entropie (image 2)



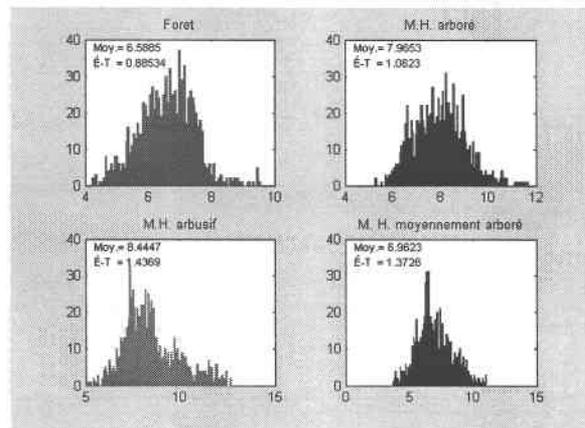
### Texture Corrélation (image 2)



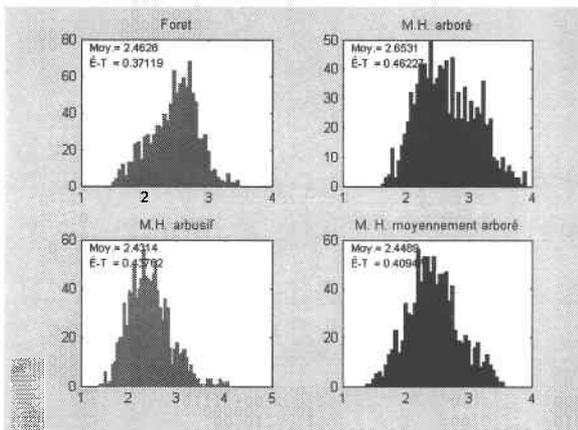
### Texture Dissemblance (image 3)



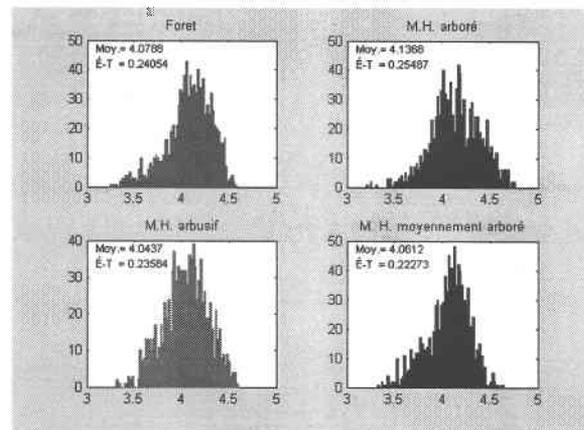
### Texture Moyenne (image 3)



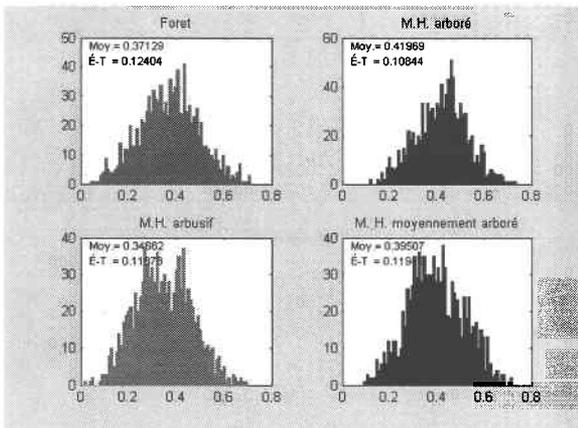
**Texture Écart Type (image 3)**



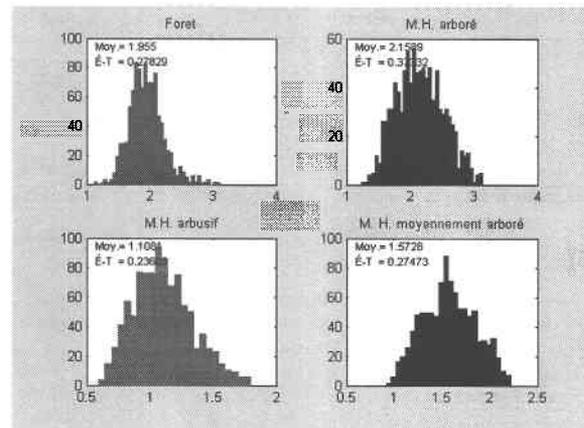
**Texture Entropie (image 3)**



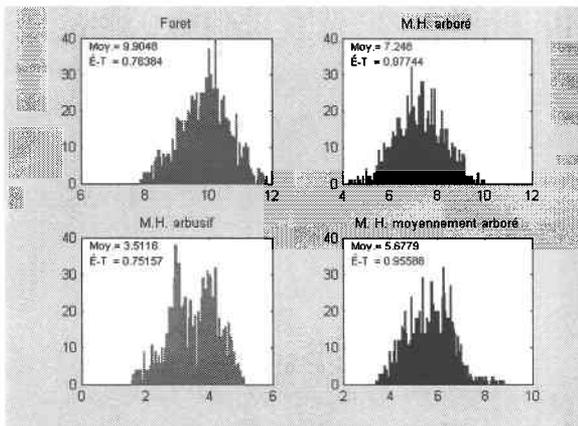
**Texture Corrélation (image 3)**



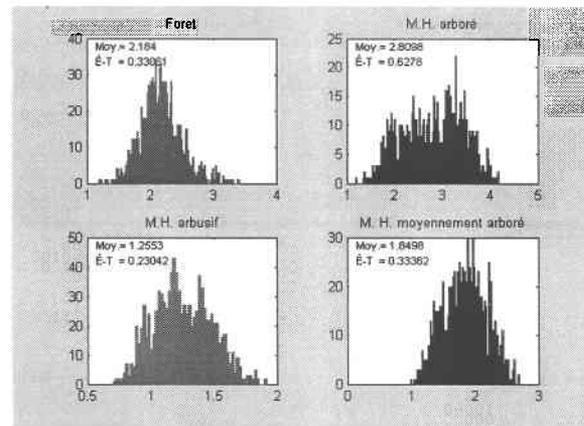
**Texture Dissemblance (image 4)**



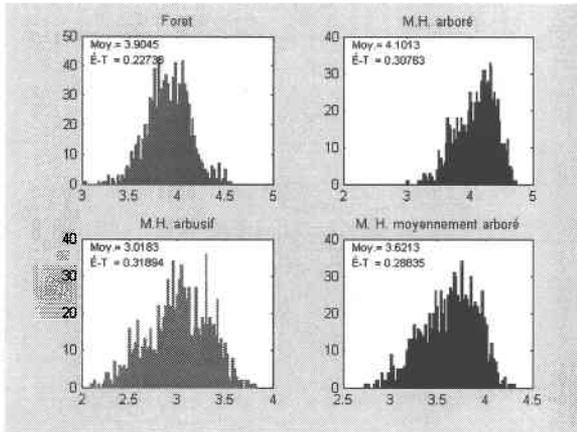
**Texture Moyenne (image 4)**



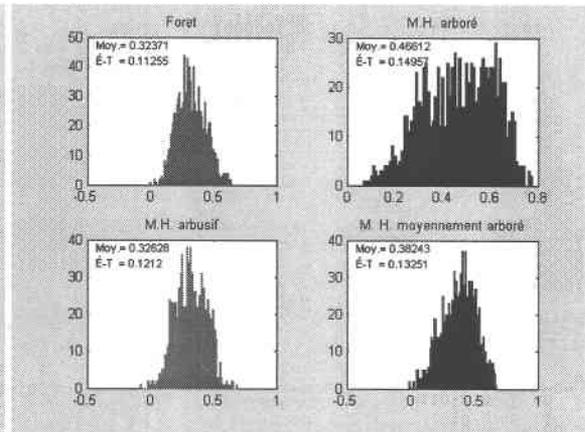
**Texture Écart Type (image 4)**



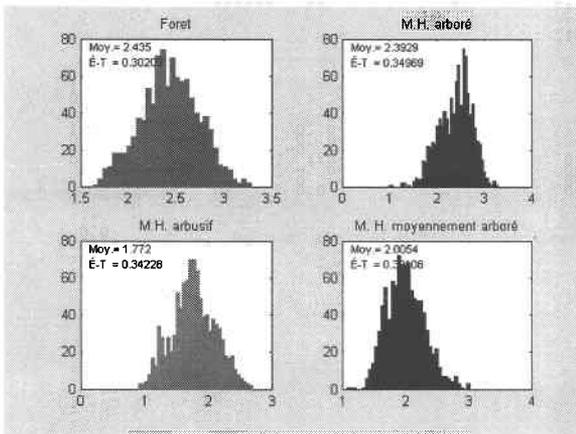
### Texture Entropie (image 4)



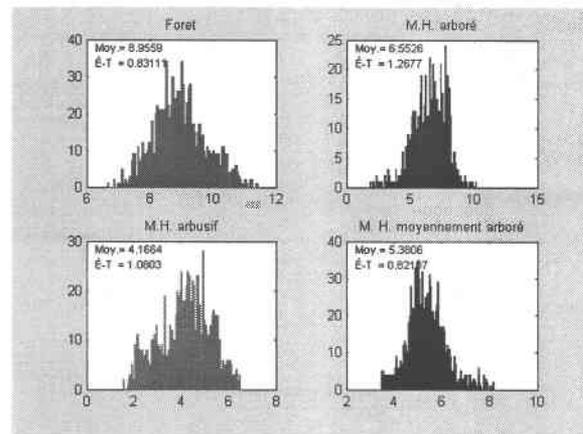
### Texture Corrélation (image 4)



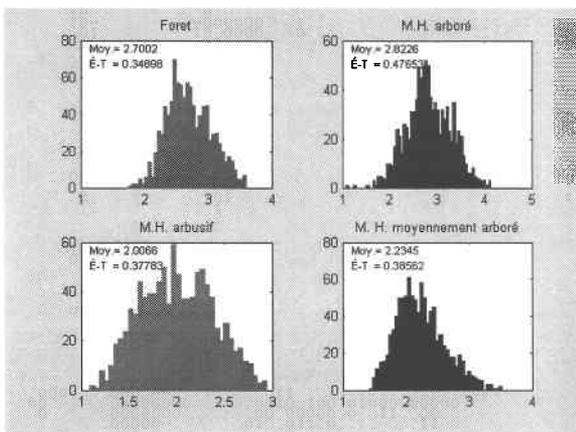
### Texture Dissemblance (image 5)



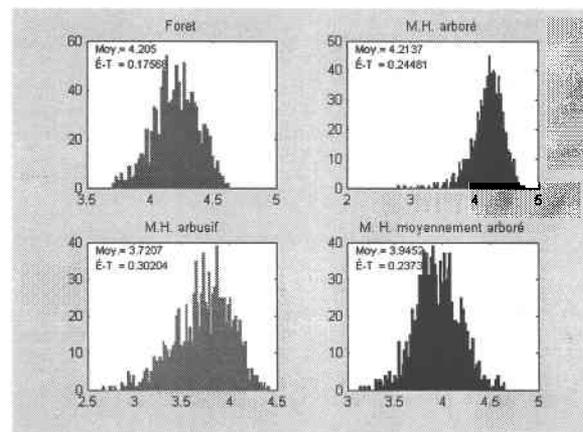
### Texture Moyenne (image 5)



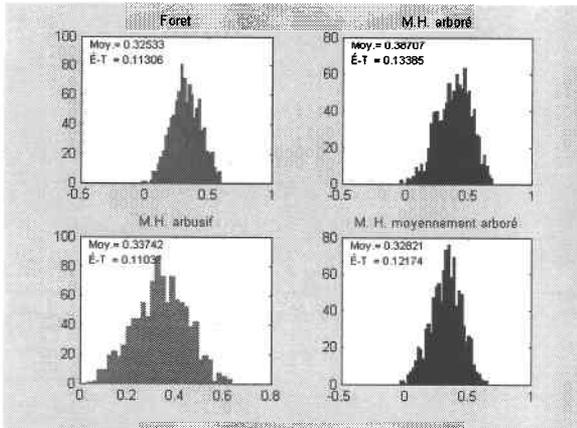
### Texture Écart Type (image 5)



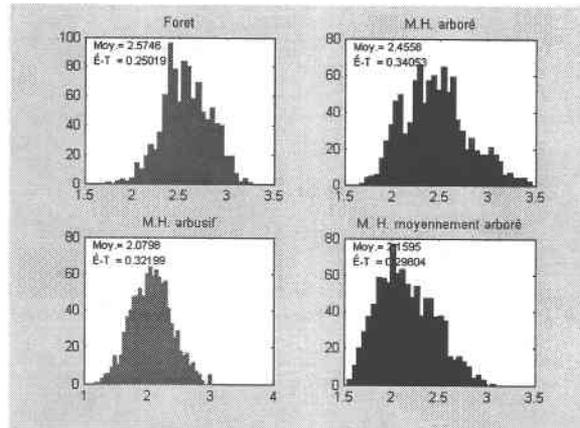
### Texture Entropie (image 5)



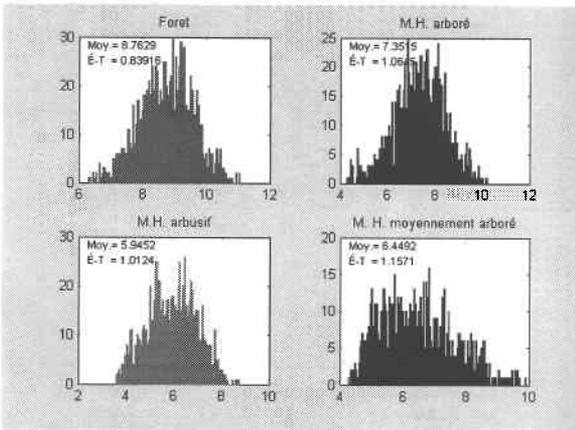
**Texture Corrélation (image 5)**



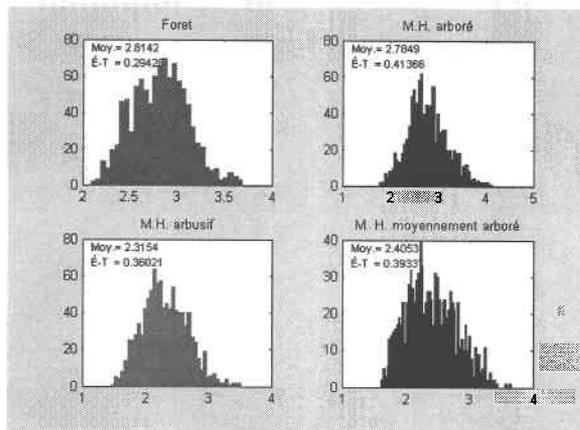
**Texture Dissemblance (image 6)**



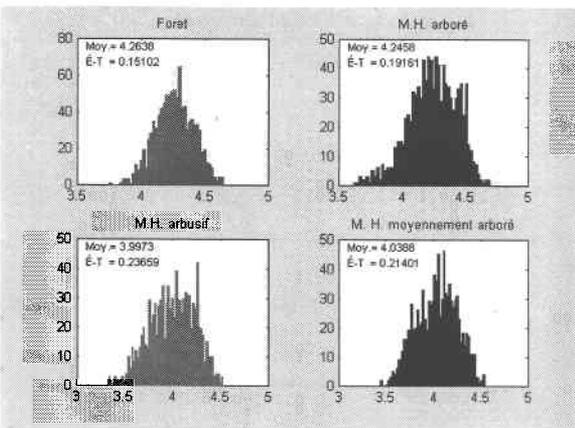
**Texture Moyenne (image 6)**



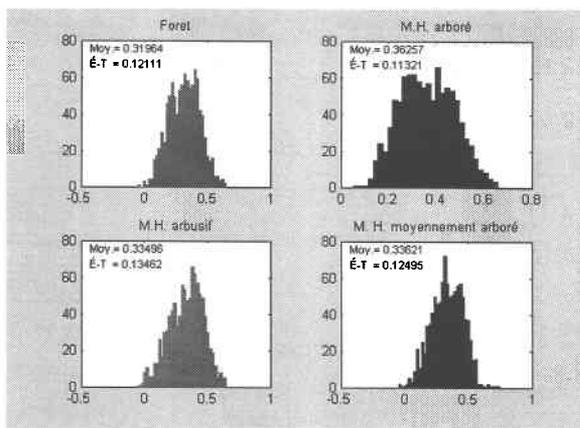
**Texture Écart Type (image 6)**



**Texture Entropie (image 6)**



**Texture Corrélation (image 6)**



# ANNEXE B

## Planches

**Image 1: S1 (03/08/1998)**

**Image 2: S1 (14/10/1998)**

**Image 3: S1 (11/06/1999)**

**Image 4: S7 (04/02/1999)**

**Image 5: S7 (13/04/1999)**

**Image 6: S7 (31/05/1999)**

Image S1 du 03 août 1998

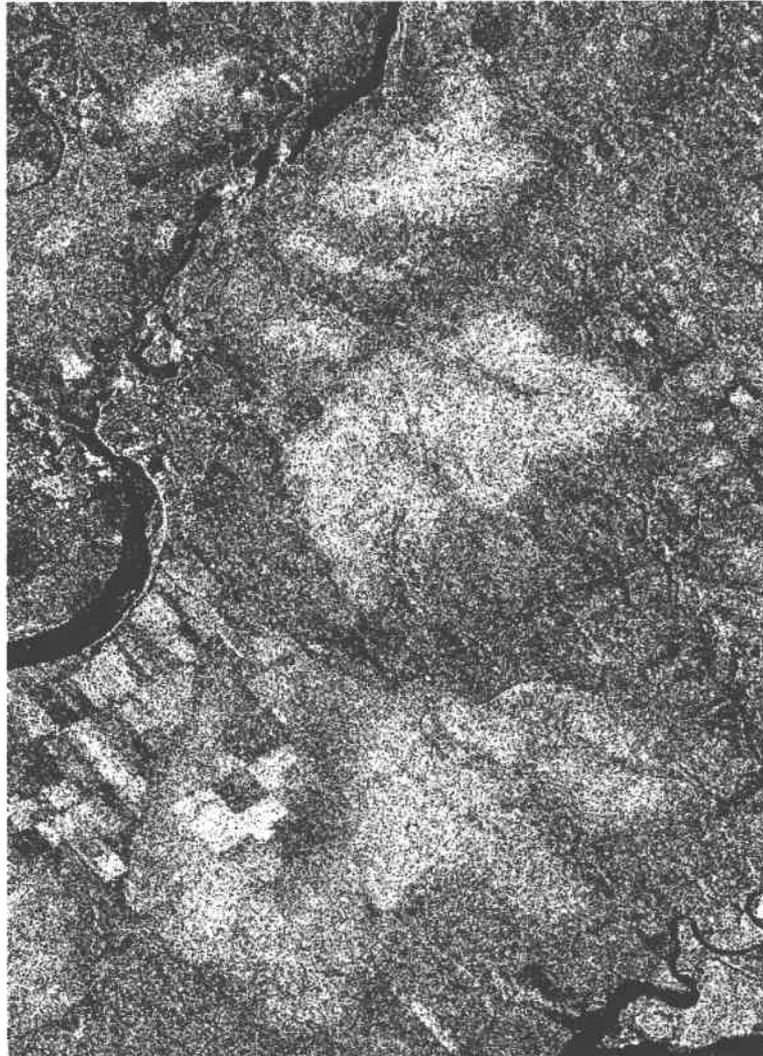


Image S1 du 11 juin 1999

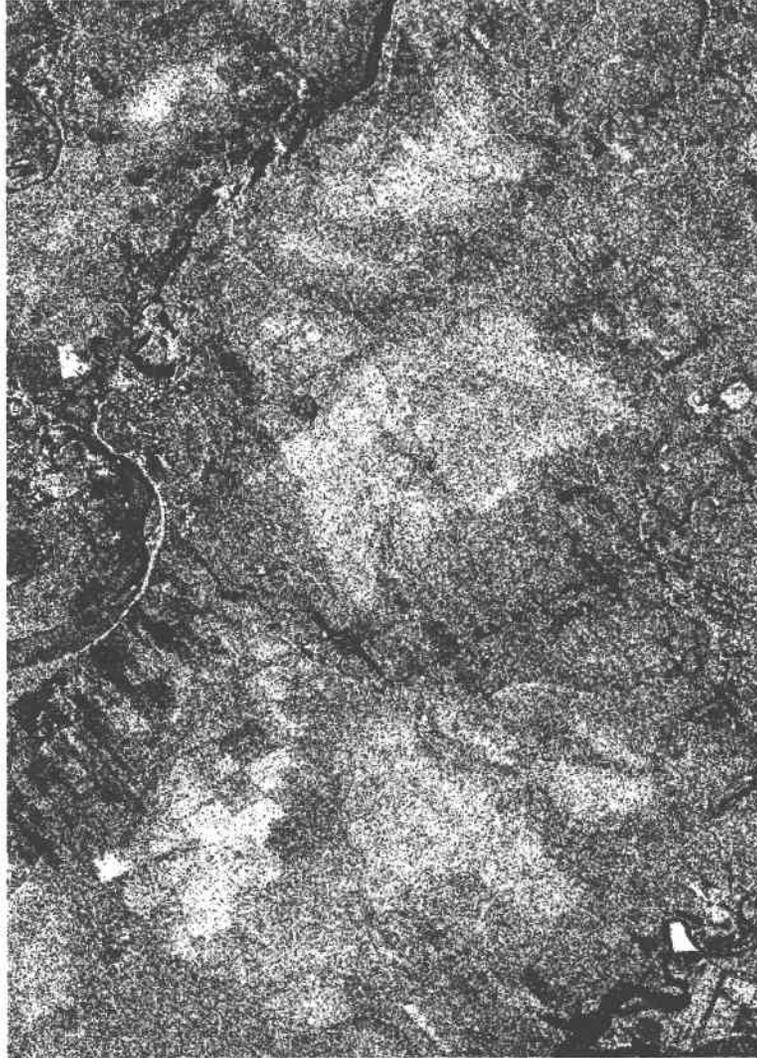


Image S1 du 14 octobre 1998

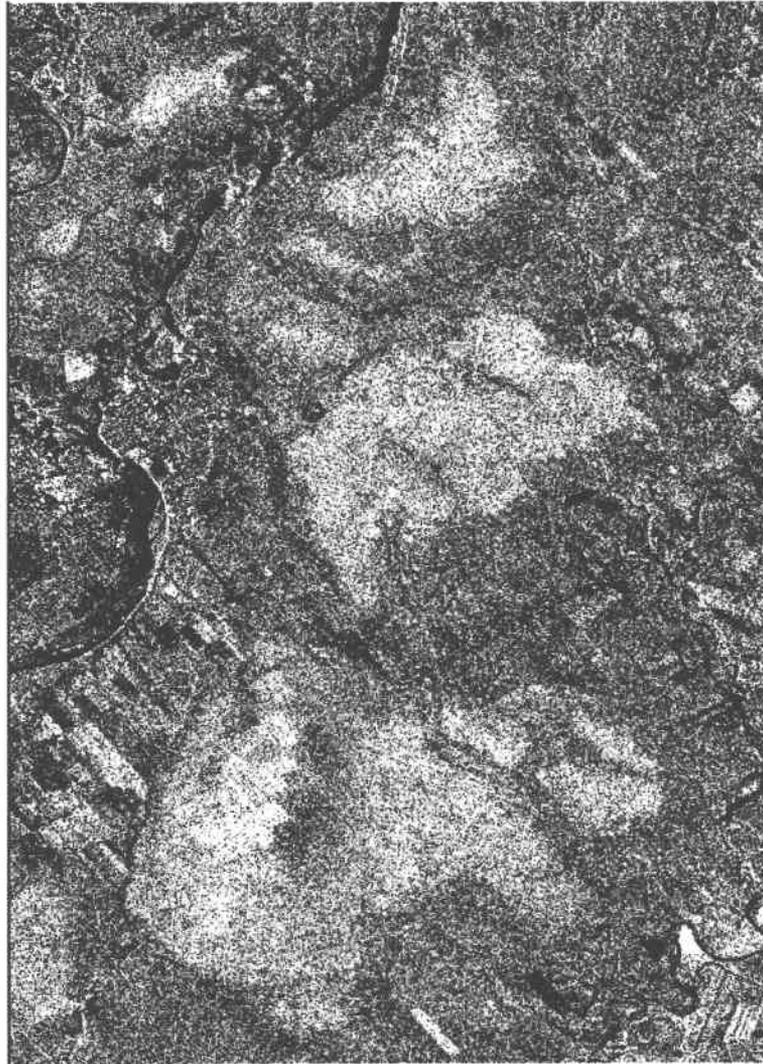


Image S1 du 1<sup>er</sup> décembre 1998

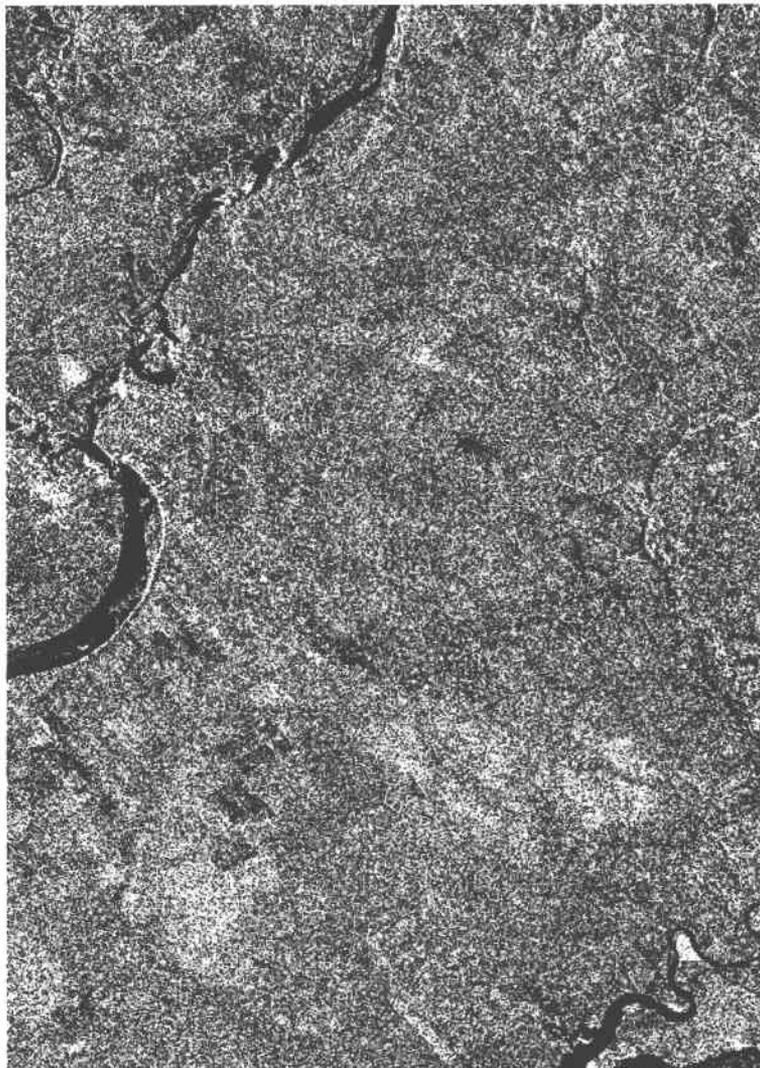


Image S1 du 24 avril 1999

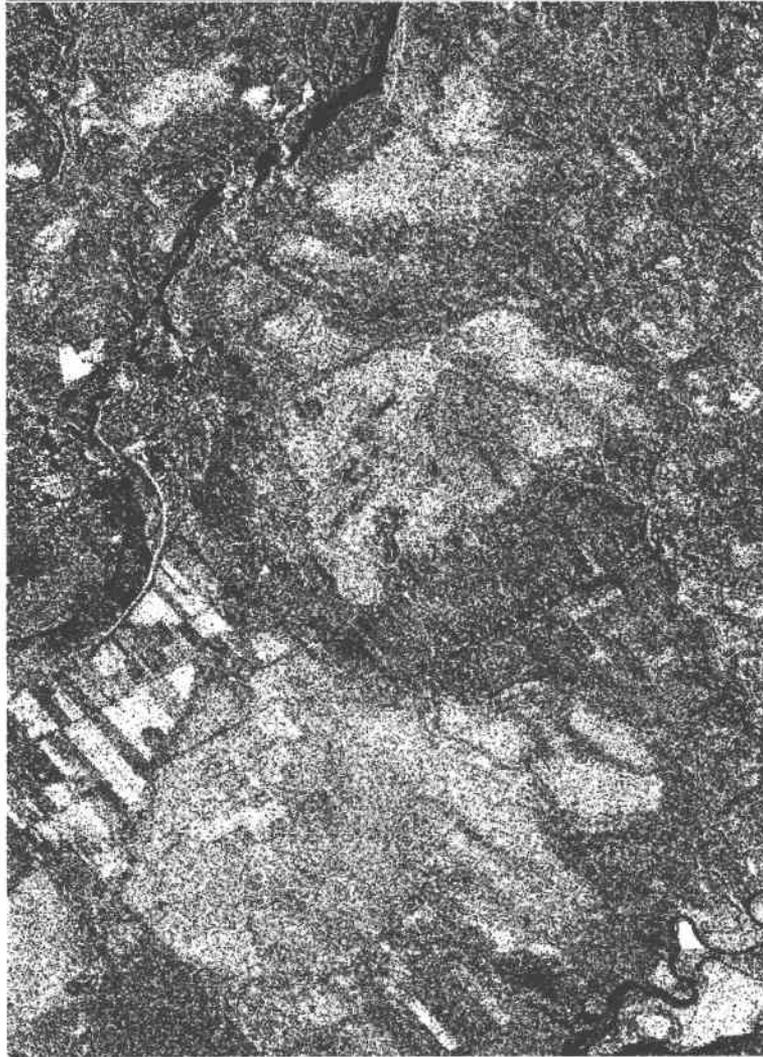


Image S7 du 04 février 1999

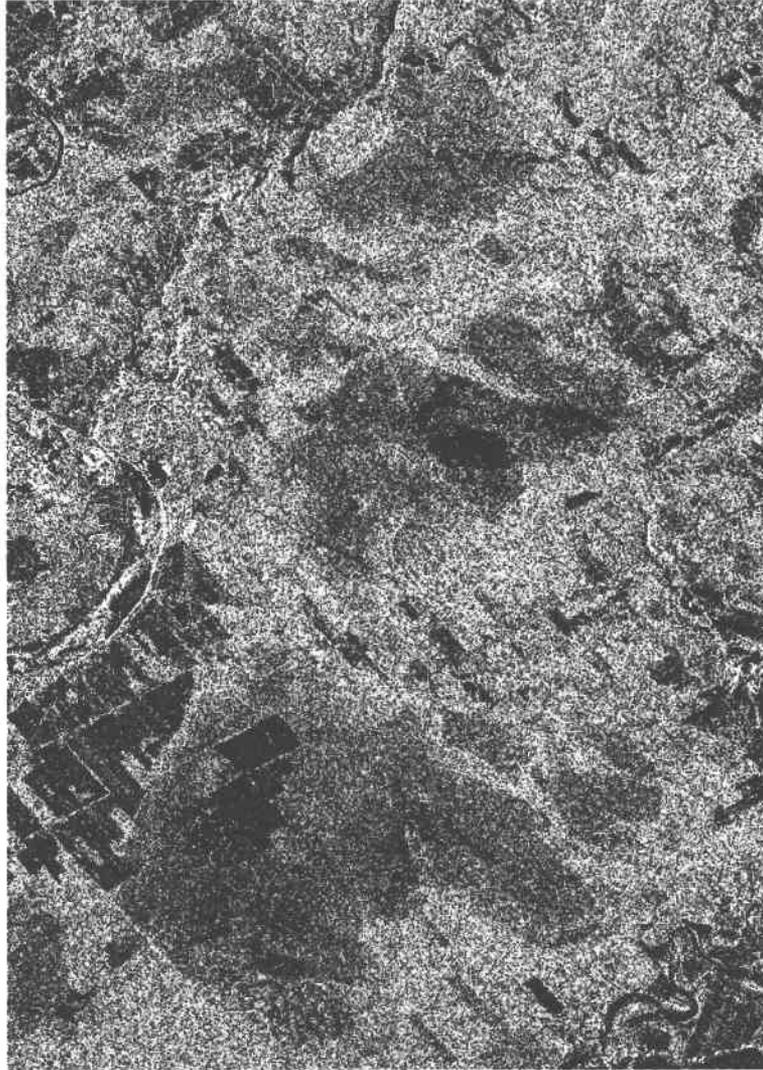


Image S7 du 13 avril 1999

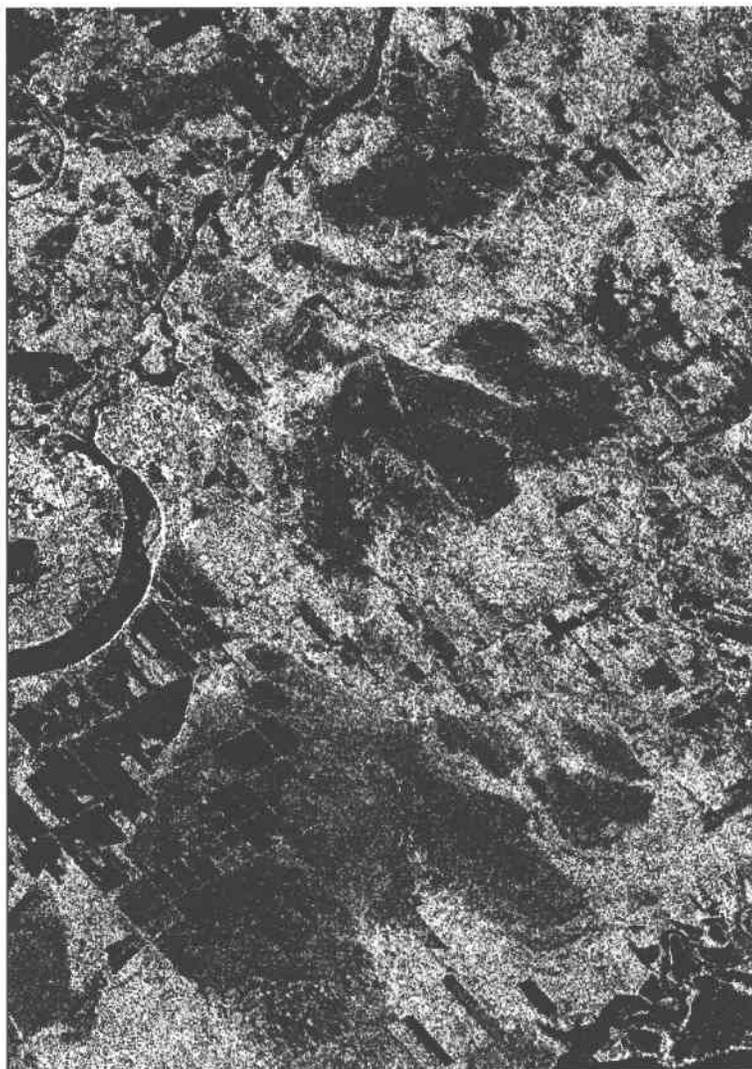


Image S7 du 31 mai 1999

