


RÉPUBLIQUE ALGÉRIENNE DÉMOCRATIQUE ET POPULAIRE
Ministère de l'Enseignement Supérieur et de la Recherche Scientifique



Université des Sciences et de la Technologie
HOUARI BOUMEDIENE
Faculté d'Électronique et d'Informatique

THESE

*Présentée pour l'obtention du Diplôme de Magister
en électronique*

Spécialité : Rayonnement Atmosphérique

Par : Kemouche Mohamed Sadek

THEME

**CONCEPTION D'UN SYSTEME DE
POURSUITE RADAR MULTICIBLES
DANS UN ENVIRONNEMENT DE CLUTTER,
BASE SUR LES RESEAUX DE NEURONES**

Soutenue le 26-06-2001. Devant le Jury composé de:

Mr M. MAAFI,	Professeur,	USTHB.	<i>Président</i>
Mr M. BENAHCENE,	Professeur,	DRD/ FDAT/MDN.	<i>Dteur de thèse</i>
Mr A. ADANE,	Docteur d'Etat,	USTHB.	<i>Examineur</i>
Mr M. GUESSOUM,	Professeur,	Univ/Blida.	<i>Examineur</i>
Mr K. BOUKHETALA,	Maître de conférences,	USTHB.	<i>Examineur</i>
Mr M. TADJINE,	Docteur d'Etat,	ENP.	<i>Examineur</i>

REMERCIEMENTS

Le travail présenté dans ce mémoire a été effectué sous la direction de Monsieur **Benahcene Madani**, qu'il trouve ici le témoignage de ma profonde gratitude pour la confiance qu'il m'a accordé et les conseils fructueux qu'il n'a cessé de me prodiguer tout au long de ce travail.

Mes remerciements vont aussi à monsieur **A, Maafi** Professeur à l'USTHB, pour avoir accepté de présider le jury de soutenance.

Je remercie également : Monsieur **A, Adane** Professeur à l'USTHB, Monsieur **M, Guessoum** Professeur à l'Université de Blida, Monsieur **M, Boukhetala** Maître de Conférence à l'USTHB, Monsieur **M, Tadjine** Enseignant à l'Ecole Polytechnique (ENP), pour avoir accepté de participer au jury de soutenance.

Enfin que tout ceux qui m'ont aidé, de près ou de loin, tout au long du déroulement de ce travail trouvent ici mes sincères remerciements.

PREFACE

Dans ce mémoire, nous présentons le travail effectué dans le cadre de la thèse de Magister dont le thème s'intitule « **Conception d'un système de poursuite radar multicibles dans un environnement de clutter, basé sur les réseaux de neurones** ». L'environnement radar est caractérisé par des cibles multiples et un taux élevé de fausses alarmes. Il devient alors difficile de décider quel sont les plots générés par les cibles en poursuite. Depuis que la poursuite est incorporée dans la chaîne de traitement de données radar, plusieurs méthodes sont développées pour résoudre le problème d'association plots/pistes dans le clutter. Mais toutes ces méthodes sont restées inefficaces dans des situations de clutter denses et le nombre croissants des cibles. Dans les années 1980, l'application des réseaux de neurones à l'association de données dans un algorithme de poursuite radar est abordée par certains chercheurs. La plupart des solutions proposées sont basées sur les réseaux de Hopfield. Certains chercheurs ont approché l'association de données radar à un problème du voyageur de commerce.

L'objet de ce travail est de présenter l'étude d'une méthode d'association de données radar dans un algorithme de poursuite appliqué aux systèmes radar TWS, basée sur les réseaux de neurones. La méthode préposée est basée sur un réseau de Hopfield.

LISTE DES ABREVIATIONS ET DES SYMBOLES

TWS	poursuite en balayage panoramique
PDA	association probabilistique de données
JPDA	association probabilistique conjointe de données
RDP	traitement de données radar
t_0	temps écoulé entre l'émission et la réception d'une impulsion
R	distance entre le radar et l'objectif
c	vitesse de propagation des ondes dans l'atmosphère
ρ, θ	coordonnées polaires, distance et azimut
ρ_m, θ_m	mesures radar, distance et azimut
ρ, θ	distance et azimut réelles
$\Delta\rho, \Delta\theta$	erreur de mesure radar de la distance et de l'azimut
$\sigma_\rho^2, \sigma_\theta^2$	variances des erreurs de mesure radar de la distance et de l'azimut
τ	durée des impulsions d'émission
B_θ	ouverture du faisceau d'antenne
X, Y	coordonnées cartésiennes dans le plan
$\Delta x, \Delta y$	erreurs de mesure radar en coordonnées cartésiennes
$\sigma_x^2, \sigma_y^2, \sigma_{xy}$	variances des erreurs de mesure en coordonnées cartésiennes
X_k	vecteur d'état des cibles
F_k	matrice de transition du modèle d'état
Z_k	vecteur mesure
H_k	matrice d'observation du modèle d'état
w_k, v_k	vecteurs bruit affectant respectivement le modèle d'état du mouvement et de mesure
Q_k, R_k	matrices de covariance des vecteurs bruit w_k et v_k
δ_{ij}	symbole de kronecker
X_{00}	vecteur d'état initial des cibles
P_{00}	matrice de covariance du vecteur d'état initial
Z_k	ensemble des mesures validées au k ^{ème} tour
Z^k	historique des mesures validées sur k balayages d'antenne

$\underline{S}_{k/k-1}$	vecteur d'état de prédiction
$\underline{P}_{k/k-1}$	matrice de covariance des erreurs de prédiction
$\underline{v}_{k,i}$	innovation de la mesure j
$\underline{\theta}_k$	matrice de covariance de l'innovation.
y_k	variable quadratique de Chi-deux
S_v	le seuil de décision du test de Chi-deux
P_d	probabilité de détection
β	densité des faux plots
V_s	volume de la fenêtre de validation
$P_{cc/d}$	probabilité de correcte corrélation sachant qu'il y a détection
P_{ne-}	probabilité qu'aucun faux plot n'appartient à la fenêtre de validation
P_{FA}	probabilité de fausse alarme
N_E	nombre des faux plots reçus dans le volume de couverture radar
P_{cc}	probabilité de correcte corrélation,
P_v	probabilité de validation
P_{fc}	probabilité de fausse corrélation
$\chi_{k,i}$	événement d'associer une mesure $z_{k,i}$
$\chi_{k,0}$	événement qu'aucune mesure n'est associée
$\beta_{k,i}$	probabilité d'association d'une mesure $z_{k,i}$
$\beta_{k,0}$	probabilité qu'aucune mesure n'est associée
w_{ij}	poids synaptique d'un neurone
V_i	sortie d'un neurone
$u_i.$	fonction de base d'un neurone
$F(.)$	fonction d'activation d'un neurone
$E(k)$	calculée a l'instant k
A	paramètre de la fonction Energie d'un réseau de Hopfield
B	paramètre de la fonction Energie d'un réseau de Hopfield
C	paramètre de la fonction Energie d'un réseau de Hopfield
D	paramètre de la fonction Energie d'un réseau de Hopfield
E	paramètre de la fonction Energie d'un réseau de Hopfield

LISTE DES TABLEAUX

TABLEAU 2-1 EXPRESSION DE LA PROBABILITE DE VALIDATION DES MESURES EN FONCTION DE LA DIMENSION M.	
$gc(x) = \frac{1}{\sqrt{2\pi}} \int_0^x \exp(-u^2/2) du$	24
TABLEAU 2-2 EXPRESSION DES PARAMETRES STATISTIQUES DANS LE CAS BIDIMENSIONNEL, M=2.....	26
TABLEAU 5-1 POSITIONS ET VITESSES INITIALES DES TRAJECTOIRES DANS LE PREMIER SCENARIO.....	86
TABLEAU 5-2 POSITIONS INITIALES, VITESSES INITIALES, ET MANŒUVRES DES TRAJECTOIRES DANS LE DEUXIEME SCENARIO	86
TABLEAU 5-3A PROBABILITES D'ASSOCIATION DES PLOTS DANS LA PREMIERE SITUATION, CAS DE QUATRE PISTES ET SIX PLOTS.....	92
TABLEAU 5-3B PLOTS ASSOCIES AUX PISTES EN FONCTION DU PARAMETRE A DU RESEAU : B=150, C=100, D=10, E=5	92
TABLEAU 5-3C PLOTS ASSOCIES AUX PISTES EN FONCTION DU PARAMETRE B DU RESEAU : A=250, C=100, D=10, E=5	93
TABLEAU 5-3D PLOTS ASSOCIES AUX PISTES EN FONCTION DU PARAMETRE C DU RESEAU : A=250, B=80, D=10, E=5	93
TABLEAU 5-3E PLOTS ASSOCIES AUX PISTES EN FONCTION DU PARAMETRE D DU RESEAU : A=250, B=80, C=100, E=5	93
TABLEAU 5-3F PLOTS ASSOCIES AUX PISTES EN FONCTION DU PARAMETRE E DU RESEAU : A=250, B=80, C=100, D=10.....	93
TABLEAU 5-4A PROBABILITES D'ASSOCIATION DES PLOTS DANS LA DEUXIEME SITUATION, CAS DE QUATRE PISTES ET ONZE PLOTS.....	97
TABLEAU 5-4B PLOTS ASSOCIES AUX PISTES EN FONCTION DU PARAMETRE A DU RESEAU : B=150, C=100, D=10, E=5	98
TABLEAU 5-4C PLOTS ASSOCIES AUX PISTES EN FONCTION DU PARAMETRE B DU RESEAU : A=130, C=100, D=10, E=7	98
TABLEAU 5-4D PLOTS ASSOCIES AUX PISTES EN FONCTION DU PARAMETRE C DU RESEAU : A=250, B=80, D=10, E=5	98
TABLEAU 5-4E PLOTS ASSOCIES AUX PISTES EN FONCTION DU PARAMETRE D DU RESEAU : A=250, B=80, C=100, E=5	98
TABLEAU 5-4F PLOTS ASSOCIES AUX PISTES EN FONCTION DU PARAMETRE E DU RESEAU : A=250, B=80, C=100, D=10.....	98
TABLEAU 5-5A PROBABILITES D'ASSOCIATION DES PLOTS DANS LA TROISIEME SITUATION, CAS DE SEPT PISTES ET QUINZE PLOTS.....	102
TABLEAU 5-5B PLOTS ASSOCIES AUX PISTES EN FONCTION DU PARAMETRE A DU RESEAU B=150, C=100, D=10, E=5	103
TABLEAU 5-5C PLOTS ASSOCIES AUX PISTES EN FONCTION DU PARAMETRE B DU RESEAU A=250, C=100, D=10, E=5	103
TABLEAU 5-5D PLOTS ASSOCIES AUX PISTES EN FONCTION DU PARAMETRE C DU RESEAU A=130, B=15, D=10, E=5	103
TABLEAU 5-5E PLOTS ASSOCIES AUX PISTES EN FONCTION DU PARAMETRE D DU RESEAU A=250, B=80, C=100, E=5	103
TABLEAU 5-5F PLOTS ASSOCIES AUX PISTES EN FONCTION DU PARAMETRE E DU RESEAU A=250, B=80, C=100, D=10	103

LISTE DES FIGURES

FIGURE 1-1 EXEMPLE D'UN SCENARIO RADAR.....	3
FIGURE 1-2 SCHEMA SIMPLIFIE D'UN RADAR CLASSIQUE.....	4
FIGURE 1-3 MODULATION DE FREQUENCE.....	5
FIGURE 1-4 TRAIN D'IMPULSIONS A L'EMISSION.....	5
FIGURE 2-1 SCHEMAS FONCTIONNELS SIMPLIFIES D'UN RADAR MODERNE.....	11
FIGURE 2-2 ORGANIGRAMME SIMPLIFIE D'UN ALGORITHME DE POURSUITE.....	13
FIGURE 2-3 SCHEMA BLOC D'UN FILTRE DE POURSUITE.....	15
FIGURE 2-4A EXEMPLE DE CORRELATION D'UN SEUL PLOT AVEC DEUX PISTES.....	17
FIGURE 2-4B EXEMPLE DE CORRELATION DE PLUSIEURS PLOTS AVEC UNE SEULE PISTE.....	17
FIGURE 2-5 SYSTEMES DE COORDONNEES POLAIRES ET CARTESIENNES.....	19
FIGURE 2-6 VARIATION DE LA PROBABILITE DE DETECTION EN FONCTION DU RAPPORT SIGNAL SUR BRUIT ET DE LA PROBABILITE DE FAUSSE ALARME.....	27
FIGURE 2-7 VARIATION DU SEUIL DE VALIDATION EN FONCTION DU RAPPORT SIGNAL SUR BRUIT ET DE LA PROBABILITE DE FAUSSE ALARME.....	27
FIGURE 2-8 VARIATION DE LA PROBABILITE DE VALIDATION EN FONCTION DU SEUIL DE VALIDATION.....	28
FIGURE 2-9 VARIATION DE LA PROBABILITE DE CORRECTE CORRELATION EN FONCTION DU RAPPORT SIGNAL SUR BRUIT ET DE LA PROBABILITE DE FAUSSE ALARME.....	28
FIGURE 2-10 VARIATION DE LA PROBABILITE DE FAUSSE CORRELATION EN FONCTION DU RAPPORT SIGNAL SUR BRUIT ET DE LA PROBABILITE DE FAUSSE ALARME.....	29
FIGURE 2-11 VARIATION DE LA PROBABILITE D'UNE CORRECTE DECISION EN FONCTION DU RAPPORT SIGNAL SUR BRUIT ET DE LA PROBABILITE DE FAUSSE ALARME.....	29
FIGURE 3-1 EXEMPLE DE CORRELATION PLOTS/PISTES. M1, M2, M3, M4 ET M5 SONT LES PLOTS ET P1, P2 ET P3 SONT LES POSITIONS PREDITES DES PISTES.....	33
FIGURE (4-1) FORME GENERALE D'UN MODELE DE NEURONE ARTIFICIEL.....	56
FIGURE 4-2 STRUCTURE DU RESEAU DE HOPFIELD.....	73
FIGURE 5-1 STRUCTURE DU RESEAU DE HOPFIELD UTILISE DE DIMENSION NXM NEURONES, AVEC N NOMBRE DE PISTES ET M NOMBRE DE COLONNES.....	81
FIGURE 5-2 ORGANIGRAMME DE L'ALGORITHME DE GENERATION DE TRAJECTOIRES DES CIBLES.....	87
FIGURE 5-3 ORGANIGRAMME DE L'ALGORITHME DE GENERATION DE MESURES RADAR.....	88
FIGURE 5-4 TRAJECTOIRES GENEREES AVEC DES PLOTS DE CLUTTER DANS LE PREMIER SCENARIO.....	89
FIGURE 5-5 TRAJECTOIRES GENEREES AVEC DES PLOTS DE CLUTTER DANS LE DEUXIEME SCENARIO.....	89
FIGURE 5-6 DISPOSITION DES PISTES ET DES PLOTS DE LA PREMIERE SITUATION DANS L'ESPACE DE COUVERTURE RADAR.....	92
FIGURE 5-7 VARIATION DU NOMBRE D'ITERATIONS EN FONCTION DU PARAMETRE A POUR DIFFERENTES VALEURS DE B, C, D, ET E. (1) B=80 C=100 D=10 E=5, (2) B=150 C=100 D=10 E=5, (3) B=80 C=300 D=10 E=5, (4) B=80 C=100 D=15 E=5, (5) B=80 C=100 D=10 E=7.....	93
FIGURE 5-8 VARIATION DU NOMBRE D'ITERATIONS EN FONCTION DU PARAMETRE B POUR DIFFERENTES VALEURS DE A, C, D, ET E. (1) A=130 C=100 D=10 E=5, (2) A=250 C=100 D=10 E=5, (3) A=130 C=300 D=10 E=5, (4) A=130 C=100 D=15 E=5, (5) A=130 C=100 D=10 E=7.....	94
FIGURE 5-9 VARIATION DU NOMBRE D'ITERATIONS EN FONCTION DU PARAMETRE C POUR DIFFERENTES VALEURS DE A, B, D, ET E. (1) A=130 B=80 D=10 E=5, (2) A=250 B=80 D=10 E=5, (3) A=130 B=150 D=10 E=5, (4) A=130 B=80 D=15 E=5, (5) A=130 B=80 D=10 E=7.....	94
FIGURE 5-10 VARIATION DU NOMBRE D'ITERATIONS EN FONCTION DU PARAMETRE D POUR DIFFERENTES VALEURS DE A, B, C, ET E. (1) A=130 B=80 C=100 E=5, (2) A=250 B=80 C=100 E=5, (3) A=130 B=150 C=100 E=5, (4) A=130 B=80 C=300 E=5, (5) A=130 B=80 C=100 E=7.....	95
FIGURE 5-11 VARIATION DU NOMBRE D'ITERATIONS EN FONCTION DU PARAMETRE E POUR DIFFERENTES VALEURS DE A, B, C, ET D. (1) A=130 B=80 C=100 D=10, (2) A=250 B=80 C=100 D=10, (3) A=130 B=150 C=100 D=10, (4) A=130 B=80 C=300 D=10, (5) A=130 B=80 C=100 D=15.....	95
FIGURE 5-12 DISPOSITION DES PISTES ET DES PLOTS DE LA DEUXIEME SITUATION DANS L'ESPACE DE COUVERTURE RADAR.....	97

FIGURE 5-13 VARIATION DU NOMBRE D'ITERATIONS EN FONCTION DU PARAMETRE A POUR DIFFERENTES VALEURS DE B, C, D, ET E. (1) B=80 C=100 D=10 E=5, (2) B=150 C=100 D=10 E=5, (3) B=80 C=300 D=10 E=5, (4) B=80 C=100 D=15 E=5, (5) B=80 C=100 D=10 E=7.....	98
FIGURE 5-14 VARIATION DU NOMBRE D'ITERATIONS EN FONCTION DU PARAMETRE B POUR DIFFERENTES VALEURS DE A, C, D, ET E. (1) A=130 C=100 D=10 E=5, (2) A=250 C=100 D=10 E=5, (3) A=130 C=300 D=10 E=5, (4) A=130 C=100 D=15 E=5, (5) A=130 C=100 D=10 E=7.....	99
FIGURE 5-15 VARIATION DU NOMBRE D'ITERATIONS EN FONCTION DU PARAMETRE C POUR DIFFERENTES VALEURS DE A, B, D, ET E. (1) A=130 B=80 D=10 E=5, (2) A=250 B=80 D=10 E=5, (3) A=130 B=150 D=10 E=5, (4) A=130 B=80 D=15 E=5, (5) A=130 B=80 D=10 E=7.....	99
FIGURE 5-16 VARIATION DU NOMBRE D'ITERATIONS EN FONCTION DU PARAMETRE D POUR DIFFERENTES VALEURS DE A, B, C, ET E. (1) A=130 B=80 C=100 E=5, (2) A=250 B=80 C=100 E=5, (3) A=130 B=150 C=100 E=5, (4) A=130 B=80 C=300 E=5, (5) A=130 B=80 C=100 E=7.....	100
FIGURE 5-17 VARIATION DU NOMBRE D'ITERATIONS EN FONCTION DU PARAMETRE E POUR DIFFERENTES VALEURS DE A, B, C, ET D. (1) A=130 B=80 C=100 D=10, (2) A=250 B=80 C=100 D=10, (3) A=130 B=150 C=100 D=10, (4) A=130 B=80 C=300 D=10, (5) A=130 B=80 C=100 D=15.....	100
FIGURE 5-18 DISPOSITION DES PISTES ET DES PLOTS DE LA TROISIEME SITUATION DANS L'ESPACE DE COUVERTURE RADAR.....	102
FIGURE 5-19 VARIATION DU NOMBRE D'ITERATIONS EN FONCTION DU PARAMETRE A POUR DIFFERENTES VALEURS DE B, C, D, ET E. (1) B=80 C=100 D=10 E=5, (2) B=150 C=100 D=10 E=5, (3) B=80 C=300 D=10 E=5, (4) B=80 C=100 D=15 E=5, (5) B=80 C=100 D=10 E=7.....	104
FIGURE 5-20 VARIATION DU NOMBRE D'ITERATIONS EN FONCTION DU PARAMETRE B POUR DIFFERENTES VALEURS DE A, C, D, ET E. (1) A=130 C=100 D=10 E=5, (2) A=250 C=100 D=10 E=5, (3) A=130 C=300 D=10 E=5, (4) A=130 C=100 D=15 E=5, (5) A=130 C=100 D=10 E=7.....	104
FIGURE 5-21 VARIATION DU NOMBRE D'ITERATIONS EN FONCTION DU PARAMETRE C POUR DIFFERENTES VALEURS DE A, B, D, ET E. (1) A=130 B=80 D=10 E=5, (2) A=250 B=80 D=10 E=5, (3) A=130 B=150 D=10 E=5, (4) A=130 B=80 D=15 E=5, (5) A=130 B=80 D=10 E=7.....	105
FIGURE 5-22 VARIATION DU NOMBRE D'ITERATIONS EN FONCTION DU PARAMETRE D POUR DIFFERENTES VALEURS DE A, B, C, ET E. (1) A=130 B=80 C=100 E=5, (2) A=250 B=80 C=100 E=5, (3) A=130 B=150 C=100 E=5, (4) A=130 B=80 C=300 E=5, (5) A=130 B=80 C=100 E=7.....	105
FIGURE 5-23 VARIATION DU NOMBRE D'ITERATIONS EN FONCTION DU PARAMETRE E POUR DIFFERENTES VALEURS DE A, B, C, ET D. (1) A=130 B=80 C=100 D=10, (2) A=250 B=80 C=100 D=10, (3) A=130 B=150 C=100 D=10, (4) A=130 B=80 C=300 D=10, (5) A=130 B=80 C=100 D=15.....	106
FIGURE 5-24 EVOLUTION DES PROBABILITES D'ASSOCIATION DES PLOTS AVEC LES PISTES DE LA PREMIERE SITUATION EN FONCTION DU NOMBRE D'ITERATIONS DU RESEAU DE HOPFIELD : (A) PISTE 1, (B) PISTE 2, (C) PISTE 3, (D) PISTE 4. (PLOT 0 SIGNIFIE AUCUNE ASSOCIATION).....	109
FIGURE 5-25 EVOLUTION DES PROBABILITE D'ASSOCIATION DES PLOTS AVEC LES PISTES DE LA DEUXIEME SITUATION EN FONCTION DU NOMBRE.....	110
D'ITERATIONS DU RESEAU DE HOPFIELD : (A) PISTE 1, (B) PISTE 2, (C) PISTE 3, (D) PISTE 4. (PLOT 0 SIGNIFIE AUCUNE ASSOCIATION).....	110
FIGURE 5-26 EVOLUTION DES PROBABILITES D'ASSOCIATION DES PLOTS AVEC LES PISTES DE LA TROISIEME SITUATION EN FONCTION DU NOMBRE D'ITERATIONS DU RESEAU DE HOPFIELD : (A) PISTE 1, (B) PISTE 2, (C) PISTE 3, (D) PISTE 4, (E) PISTE 5, (F) PISTE 6, (G) PISTE 7. (PLOT 0 SIGNIFIE AUCUNE ASSOCIATION).....	112
FIGURE 5-27 VARIATION DE LA FONCTION ENERGIE NORMALISEE DANS LA PREMIERE SITUATION EN FONCTION DU NOMBRE D'ITERATIONS.....	113
FIGURE 5-28 VARIATION DE LA FONCTION ENERGIE NORMALISEE DANS LA DEUXIEME.....	114
SITUATION EN FONCTION DU NOMBRE D'ITERATIONS.....	114
FIGURE 5-29 VARIATION DE LA FONCTION ENERGIE NORMALISEE DANS LA TROISIEME.....	114
SITUATION EN FONCTION DU NOMBRE D'ITERATIONS.....	114
FIGURE 5-30 POURSUITE DU PREMIER SCENARIO PAR LE RESEAU DE HOPFIELD OBTENU.....	116
FIGURE 5-31 POURSUITE DU PREMIER SCENARIO PAR LA METHODE JPDA.....	116
FIGURE 5-32 POURSUITE DU DEUXIEME SCENARIO PAR LE RESEAU DE HOPFIELD OBTENU.....	117
FIGURE 5-33 POURSUITE DU DEUXIEME SCENARIO PAR LA METHODE JPDA.....	117

TABLE DES MATIERES

REMERCIEMENTS	I
PREFACE.....	II
LISTES DES ABREVIATIONS ET SYMBOLES	III
LISTE DES TABLEAUX.....	V
LISTE DES FIGURES	VI
TABLE DES MATIERES	VIII
CHAPITRE I : INTRODUCTION GENERALE.....	1
I.1. HISTORIQUE.....	2
I.2. PRINCIPES DU RADAR.....	2
I.3. CONSTRUCTION D'UN RADAR CLASSIQUE	3
I.4. CLASSIFICATION DES RADARS.....	5
I.5. EVOLUTION DES RADARS	6
CHAPITRE II : PRINCIPES DE TRAITEMENT DE DONNEES RADAR.....	9
II.1. INTRODUCTION	10
II.2. ORGANISATION D'UN SYSTEME RADAR TWS	10
II.3. DESCRIPTION D'UN SYSTEME DE POURSUITE	12
II.3.1. Organisation des Pistes et des Plots.....	14
II.3.2. Filtre de Poursuite	14
II.3.3. Association plots/pistes	16
II.3.4. Initialisation de Pistes	16
II.3.5. Abandon de Pistes.....	18
II.4. MODELES DU MOUVEMENT DE CIBLES ET DE MESURE	18
II.5. VALIDATION DES PLOTS	21
II.5. CONCLUSION	30
CHAPITRE III : TECHNIQUES D'ASSOCIATION DE DONNEES RADAR.....	31
III.1. INTRODUCTION.....	32
III.2. METHODE DU PLUS PROCHE VOISIN.....	32
III.3. METHODE DE PARTAGE DE PISTES (TRACK SPLITTING).....	34
III.4. METHODE BASEE SUR LE MAXIMUM DE VRAISEMBLANCE	37
III.5. METHODE D'ASSOCIATION PROBABILISTIQUE DE DONNEES (PDA).....	40
III.6. METHODE MODIFIEE D'ASSOCIATION PROBABILISTIQUE DE DONNEES	42
III.7. METHODE ADAPTATIVE D'ASSOCIATION PROBABILISTIQUE DE DONNEES.....	45
III.8. METHODE D'ASSOCIATION PROBABILISTIQUE CONJOINTE DE DONNEES.....	46
III.9. METHODE D'ASSOCIATION BASEE SUR LES MODELES DE MARKOV CACHES (HMM).....	48
III.9.1. Présentation des modèles de Markov cachés.....	48
III.9.2. Application à la Poursuite	49
III.9.3. Algorithme de Viterbi.....	50

III.10. CONCLUSION	51
CHAPITRE IV :GENERALITES SUR LES RESEAUX DE NEURONES	53
IV.1. HISTORIQUE.....	54
IV.2. INTRODUCTION.....	55
IV.3. MODELE BIOLOGIQUE.....	55
IV.4. MODELE DE NEURONES ARTIFICIELLES.....	56
IV.4.1. Fonction de base.....	57
IV.4.2. Fonction d'activation.....	57
IV.5. STRUCTURE DES RESEAUX DE NEURONES	58
IV.5.1. topologie des connexions.....	58
IV.5.2. Décomposition des réseaux de neurones.....	59
IV.6. RESEAUX A MEMOIRE ASSOCIATIVE	59
IV.6.1. Etape d'apprentissage	59
IV.6.2. Etape de rappel.....	60
IV.6.3. Réseau direct.....	60
IV.6.4. Réseaux récurrents	62
IV.7. RESEAU DE HOPFIELD.....	63
IV.8. RESOLUTION DU PROBLEME DU VOYAGEUR DE COMMERCE PAR UN RESEAU DE HOPFIELD	64
IV.8.1. Méthode de rétro-propagation du gradient d'erreur	66
IV.9. POURSUITE RADAR PAR LES RESEAUX DE NEURONES.....	71
IV.9.1. Par Mesure de Divergence	71
IV.9.2. Par Optimisation.....	72
IV.9.3. Par Reconnaissance de Trajectoires.....	72
IV.10. EXEMPLE D'ASSOCIATION PLOTS/PISTES PAR MESURE DE DIVERGENCE	72
IV.11. EXEMPLE D'ASSOCIATION PLOTS/PISTES PAR OPTIMISATION.....	74
IV.12. ASSOCIATION PLOTS/PISTES PAR UN RESEAU DE HOPFIELD MODIFIE	76
IV.13. CONCLUSION	77
CHAPITRE V : METHODE D'ASSOCIATION DE DONNEES RADAR PAR UN RESEAU DE HOPFIELD.....	78
V.1. INTRODUCTION.....	79
V.2. DESCRIPTION DE LA METHODE	80
V.3. ANALYSE DES PERFORMANCES.....	83
V.4. DESCRIPTION DES ALGORITHMES DE SIMULATION	84
V.4.1. Génération de trajectoires	84
V.4.2. Génération de mesures radar.....	85
V.4.3. Algorithme de Poursuite	85
V.5. GENERATION DE SITUATIONS AERIENNES	86
V.6. CHOIX DES PARAMETRES DE SIMULATION.....	90
V.7. SIMULATION ET ANALYSE.....	91
V.7.1. Première Situation.....	91
V.7.2. Deuxième Situation.....	96
V.7.3. Troisième Situation.....	101
V.8. DISCUSSION SUR LES RESULTATS	107
V.9. TEST DU RESEAU OBTENU	115
V.10. CONCLUSION	118
CONCLUSION GENERALE.....	119
BIBLIOGRAPHIE	122



**CHAPITRE I
INTRODUCTION GENERALE**

CONTENU :

I.1. HISTORIQUE.....	ERREUR ! SIGNET NON DEFINI
I.2. PRINCIPES DU RADAR.....	ERREUR ! SIGNET NON DEFINI
I.3. CONSTRUCTION D'UN RADAR CLASSIQUE	ERREUR ! SIGNET NON DEFINI
I.4. CLASSIFICATION DES RADARS.....	ERREUR ! SIGNET NON DEFINI
I.5. EVOLUTION DES RADARS	ERREUR ! SIGNET NON DEFINI

I.1. HISTORIQUE

Les principes physiques de bases sur les radars ont été développés il y a un siècle. En 1886, Heinrich Hertz a déjà démontré la réflexion des ondes électromagnétiques sur des obstacles. Et en 1925, G. Breit et M. Tuve ont observé les premiers échos d'impulsions courtes réfléchies sur la couche ionosphérique, sur un tube cathodique à l'université de John Hopkins. L'an 1929 a été marqué par l'observation de la première photo d'échos réfléchis sur des aéronefs. Une année après, la première démonstration de la mesure de la distance a eu lieu par les Anglais et les Allemand. En 1937, le premier radar opérationnel (Chain Home) a vu le jour chez les Anglais. Il a été utilisé durant la deuxième guerre mondiale comme moyen de détection et de riposte contre les raids aériens allemands.

I.2. PRINCIPES DU RADAR

Le radar est un dispositif qui permet de détecter et de localiser un objet auquel on s'intéresse. Le mot radar est l'abréviation de l'expression «**Radio Détection And Ranging**». Son fonctionnement est basé sur le principe suivant : si on émet un signal électromagnétique par une antenne dans la direction où se trouve l'objet qui nous intéresse, une partie de l'énergie émise est réfléchi par cet objet, et captée par une antenne de réception (ou souvent la même antenne). Le signal ainsi capté, et qu'on appelle «écho», va signaler la présence de l'objectif (détection), et fournir des informations concernant sa position et sa vitesse. En d'autres termes, le retard du signal reçu fournit l'information sur la distance de l'objectif, et le décalage en fréquence (fréquence Doppler) est porteur d'information sur sa vitesse. Tandis que la direction du faisceau d'antenne dans laquelle le signal est reçu détermine l'azimut et/ou l'élévation de l'objectif. Cependant, n'importe quel obstacle qui se trouve dans la direction de l'objectif qui nous intéresse peut réfléchir l'onde émise. Les échos de ces obstacles, et que nous qualifions d'indésirables, rendent la tâche de la détection difficile. Les échos indésirables, appelés conventionnellement 'clutter', influent de deux façons sur la performance du radar. Si sa surface est large, l'objectif peut être masqué donnant une faible qualité de détection. Tandis que la surface faible ou ponctuelle de l'obstacle peut être une source de fausses alarmes.




Figure 1-1 Exemple d'un scénario radar

I.3. CONSTRUCTION D'UN RADAR CLASSIQUE

Un schéma simplifié d'un système radar classique est illustré par la Figure 1-1. Il est constitué des blocs suivants.

Emetteur : Un dispositif de génération d'ondes électromagnétiques. Il est caractérisé par la fréquence d'émission, le type de modulation utilisé et la puissance des ondes électromagnétiques émises.

Antenne : Les radars utilisent souvent la même antenne pour l'émission et la réception. Elle permet de déterminer la forme et la direction du faisceau transmis et réfléchi.

Duplexeur : Si le radar utilise la même antenne pour l'émission et la réception, le duplexeur est nécessaire. C'est un interrupteur qui transporte, toute l'énergie à partir de l'émetteur vers l'antenne pendant la phase de transmission, et l'énergie recueillie par l'antenne vers le récepteur durant la phase de réception.

Récepteur : Son rôle principal est l'interception des échos et la rejection d'interférence, et l'amplification du signal reçu à un niveau convenable à l'exploitation.

Indicateur panoramique : C'est un moyen d'interfaçage entre le radar et l'opérateur. Il permet également de détecter la cible et déterminer sa position. Il est aussi un dispositif de visualisation de la situation aérienne.

Bloc de synchronisation : pour déterminer la position de la cible (distance et azimuth), la synchronisation entre le temps d'émission et de réception est nécessaire.

La détermination de la distance de l'objectif nécessite la modulation du signal émis par des impulsions de courte durée répétées à des intervalles constants. Le bloc de synchronisation permet de déterminer le temps t_0 écoulé entre l'émission d'une impulsion et la réception de l'écho réfléchi sur l'objectif, durant lequel cette impulsion a parcouru deux fois (aller et retour) la distance R entre le radar et l'objectif. En connaissant la vitesse c de propagation des ondes dans l'atmosphère, on peut déterminer la distance R comme suit

$$t_0 = \frac{2R}{c} \quad (1-1)$$

et inversement

$$R = \frac{c}{2} t_0 \quad (1-2)$$

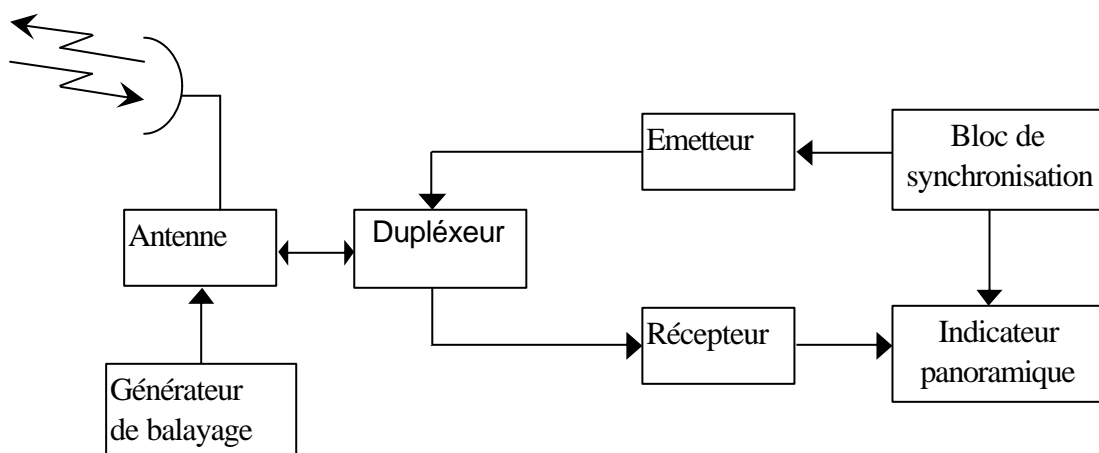


Figure 1-2 schéma simplifié d'un radar classique

I.4. CLASSIFICATION DES RADARS

Selon leur mode de fonctionnement, les radars sont classés en deux catégories :

1. **Radars à onde continue** : La mesure de la distance de la cible nécessite une modulation qui est le plus souvent une modulation de fréquence (voir figure 3).
2. **Radars à impulsions** : Ils sont équipés d'un émetteur envoyant des impulsions brusques (voir figure 4) de durée τ , avec une période de répétition T_R .




Figure 1-3 modulation de fréquence




Figure 1-4 train d'impulsions à l'émission

Les radars sont aussi classés, selon leurs missions, en différentes catégories :

Radar de surveillance : Il permet de localiser une cible à l'intérieur d'une zone de l'espace donné.

Radar de surveillance secondaire : C'est un radar de veille et d'identification des cibles au moyen d'une technique d'interrogation réponse.

Radar de poursuite et de guidage : Il estime les paramètres de la cible avec une bonne précision et il permet de prédire la position future pour pouvoir conduire un tir.

I.5. EVOLUTION DES RADARS

Au cours des dernières décennies, les efforts consentis dans le domaine du traitement automatique des informations radars qui, appliqué en premier lieu au domaine militaire puis élargi au contrôle du trafic aérien civil, ont abouti à la naissance de la théorie de la poursuite radar. Au début, la procédure de poursuite radar s'effectuait manuellement par un opérateur humain, qui marquait au stylo sur un tableau les coordonnées des cibles à chaque détection. Cette procédure est simple mais elle est peu précise et ne permet pas le traitement simultané de plusieurs cibles, ceci a poussé les concepteurs à développer un organe sophistiqué qui est le processeur de données radar (***Radar Data Processing, RDP***). Ce dernier remplace l'opérateur humain et effectue donc la poursuite avec plus de précision et de flexibilité en faisant appel aux techniques modernes de l'électronique, de l'informatique et de l'automatique.

Le radar à balayage panoramique (***Track While Scan, TWS***) est un exemple des systèmes de surveillance aérienne. L'espace de surveillance est balayé régulièrement par le faisceau d'antenne et les données sont reçues à des intervalles réguliers. Par conséquent, la surveillance et la poursuite sont effectuées simultanément.

On distingue deux tâches principales dans un algorithme de poursuite radar, le filtrage des pistes et l'association de données. La tâche de filtrage est un processus séquentiel qui estime le vecteur d'état des cibles et corrige ses paramètres à travers les mesures radar qu'on reçoit

périodiquement. La tâche d'association de données est un processus combinatoire optimal qui assigne les nouvelles mesures aux cibles qui leurs conviennent. Depuis que la fonction de poursuite automatique est incorporée dans la chaîne de traitement radar, plusieurs méthodes se sont développées pour résoudre le problème d'association de plots avec les pistes, afin de répondre aux exigences opérationnelles en terme de performance de poursuite et de simplicité d'implémentation [6-17]. La performance de poursuite est directement liée à l'environnement du radar et l'efficacité des techniques utilisées. La complexité d'implémentation est liée à l'algorithme utilisé et au processeur sur lequel il est implanté.

Parmi les méthodes qui se sont déjà utilisées en pratique, nous citons en particulier la méthode du plus proche voisin et la méthode d'association probabilistique conjointe de données (*Joint probabilistic Data Association, JPDA*). La première méthode consiste à sélectionner, parmi les plots reçus celui le plus proche à la piste pour lui être associé. Tandis que la deuxième méthode consiste à calculer, pour chaque cible, les probabilités conjointes d'association de tous les plots, et les utiliser ensuite comme facteurs de pondération pour déterminer une mesure moyenne. C'est cette dernière qui est utilisée pour la mise à jour des pistes. D'autres méthodes se sont aussi développées. Malgré la diversité des techniques développées pour résoudre le problème d'association plots/pistes, et la complexité croissante des algorithmes qui en dérivent, les approches classiques appliquées à cette tâche sont restées inefficaces dans des situations de clutter dense et complexes en terme de calcul.

Les réseaux de neurones constituent une catégorie de filtres non linéaires adaptatifs et caractérisés par une structure parallèle. L'architecture de chaque filtre est constituée de plusieurs cellules élémentaires (neurones) interconnectées entre elles pour former un réseau. Le choix des réseaux de neurones dans divers domaines est motivé par la simplicité de la mise en œuvre des cellules, le parallélisme du traitement et leur forte capacité d'adaptation. Les différentes architectures mises en œuvre se distinguent entre elles par la nature du traitement cellulaire, la topologie des connexions des neurones, et le principe d'adaptation (algorithme d'apprentissage). Les méthodes d'association de données radar à base de réseaux de neurones se sont développées pour remédier aux insuffisances des méthodes classiques. Ainsi le mécanisme d'application des réseaux de Hopfield à la perception du mouvement humain est adopté dans les algorithmes d'association de données radar.

L'objet de ce travail est de présenter une étude d'application des réseaux de neurones à la résolution du problème d'association de données dans un radar à balayage panoramique (*Track While Scan, TWS*). Nous supposons que l'environnement du radar est caractérisé par des

cibles multiples et un taux de fausses alarmes élevé. Nous avons utilisé un réseau de Hopfield pour déterminer les plots qui vont être associés aux pistes existantes. Ce type de réseaux a été déjà appliqué au problème du voyageur de commerce qui se formule comme suit (Voir §3.8). Un commerçant voyageur doit visiter un certain nombre de villes et revenir à la ville de départ à la fin du parcours. Il s'agit donc de déterminer la séquence de toutes les villes à visiter en minimisant la distance totale parcourue, et ne visiter chaque ville qu'une seule fois. La similarité remarquable entre le problème du voyageur de commerce et celui de l'association de données radar nous a permis de considérer l'association comme un problème d'optimisation dont les contraintes sont choisies à partir des propriétés de la méthode d'association probabilistique conjointe de données (JPDA) et de la méthode du plus proche voisin. Nous avons utilisé les probabilités d'association des plots calculées par le filtre JPDA pour initialiser la mise à jour des états des neurones. Le choix d'un réseau de Hopfield dépend des cinq paramètres A, B, C, D et E qui apparaissent dans la fonction Energie. Les valeurs de ces paramètres sont sélectionnées en analysant les propriétés des méthodes classiques comme la méthode JPDA et la méthode du plus proche voisin, de sorte que l'association plots/pistes se simplifie à un seul plot pour chaque piste. Pour ce faire, nous avons simulé plusieurs scénarios afin de prendre en considération toutes les situations aériennes possibles. Finalement, la comparaison entre l'association plots/pistes par le réseau de Hopfield obtenu et l'association par la méthode du filtre JPDA d'un côté, et par la méthode du plus proche voisin d'autre côté, a démontré la supériorité de la performance de l'association par le réseau de Hopfield sur les deux autres méthodes.

Ainsi nous organisons ce mémoire comme suit. Nous présentons dans le deuxième chapitre les principes de traitement de données radar et dans le troisième chapitre les différentes méthodes classiques d'association plots/pistes. Le quatrième chapitre est consacré aux réseaux de neurones. Dans le cinquième chapitre nous présentons les résultats de simulation et l'analyse de performance de poursuite par un réseau de Hopfield. Ce chapitre portera aussi sur la comparaison de l'associateur neuronal avec celui basée sur la méthode d'association probabilistique conjointe de données (JPDA). On terminera par une conclusion générale.

CHAPITRE II

PRINCIPES DE TRAITEMENT DE DONNEES RADAR

CONTENU :

II.1. INTRODUCTION	10
II.2. ORGANISATION D'UN SYSTEME RADAR TWS	10
II.3. DESCRIPTION D'UN SYSTEME DE POURSUITE	12
<i>II.3.1. Organisation des Pistes et des Plots</i>	14
<i>II.3.2. Filtre de Poursuite</i>	14
<i>II.3.3. Association plots/pistes</i>	16
<i>II.3.4. Initialisation de Pistes</i>	16
<i>II.3.5. Abandon de Pistes</i>	18
II.4. MODELES DU MOUVEMENT DE CIBLES ET DE MESURE	18
II.5. VALIDATION DES PLOTS	21
II.5. CONCLUSION	30

II.1. INTRODUCTION

La situation aérienne est généralement caractérisée par une forte densité de cibles et un taux de fausses alarmes élevé. Ceci rend difficile la conception d'un système de poursuite multicibles. Certains de chercheurs ont concentré leurs efforts pour développer un organe sophistiqué qui est le processeur de données radar (*Radar Data Processor*, RDP) capable d'effectuer la poursuite, dans ces conditions difficiles, avec plus de précision et de flexibilité [2]. Dans ce chapitre, nous allons décrire l'organisation générale d'un système TWS (*Track While Scan*, TWS). Ensuite, nous présenterons un algorithme de poursuite automatique dont les différentes fonctions seront brièvement décrites. Nous terminerons enfin avec une conclusion.

II.2. ORGANISATION D'UN SYSTEME RADAR TWS

Les systèmes radars de poursuite en balayage, TWS, sont destinés à la surveillance aérienne [1][2][3]. Ils sont caractérisés par une période de balayage d'antenne variant entre 4 et 12 secondes, une faible probabilité de détection, une faible précision des mesures fournies, une forte densité de cibles, et un taux de fausses alarmes élevé. Un schéma fonctionnel simplifié d'un radar TWS moderne est illustré par la Figure (2-1). Il comprend les blocs fonctionnels suivants : une antenne, un émetteur, un duplexeur, un récepteur, un processeur de signal, un processeur de données, et un système de visualisation.

Le processeur du signal est un dispositif de traitement du signal radar issu du récepteur. Il détermine la présence ou l'absence des cibles en rejetant les signaux parasites dus aux clutter, aux interférences des fréquences radio et aux sources de brouillage actif. Il permet également d'extraire les données cinématiques des cibles et de les envoyer vers le processeur de données radar sous forme de plots. Un plot est défini comme étant l'ensemble des informations acquises sur les cibles et qui sont la distance, l'azimut, l'altitude, la vitesse radiale, la réflectivité (nature des cibles),... Ces informations sont généralement affectées de bruit indépendant d'un type à l'autre et corrélé dans le temps, dont les caractéristiques statistiques sont déterminés en fonction des paramètres du radar.

Le processeur de données est le bloc le plus important d'un système radar moderne, il contient tous les algorithmes de traitement et donne une description détaillée de la situation aérienne, parmi les fonctions de ce bloc on compte la poursuite. Le nombre de plots issus du processeur de signal est souvent considérable et risque de saturer le processeur de données.

Ces plots, qui sont répartis d'une façon contiguë représentent, en plus des cibles réelles, des fausses alarmes dont l'origine peut être le trafic routier, le clutter du sol et le clutter atmosphérique qui peut occuper un grand espace. Pour cela, le module de poursuite est souvent précédé d'une fonction de corrélation/interpolation qui minimise le nombre de faux plots.

La poursuite constitue une étape essentielle en vue de faciliter l'exploitation de l'espace aérien. La dynamique des cibles est généralement représentée par la technique de l'espace d'état. L'état d'une cible est généralement la position, la vitesse et quelques fois l'accélération. L'environnement radar est généralement caractérisé par la présence du clutter qui génère des fausses alarmes et la cible peut ne pas être détectée. Cette situation se manifeste par l'obtention d'un grand nombre de plots au même tour d'antenne et qui constituent des ambiguïtés d'association avec les pistes en cours de poursuite, ce qui rend difficile de décider lesquels, parmi ces plots, ceux qui sont générés par des cibles réelles. Quelque fois, le plot sélectionné peut être faux et par conséquent la cible en poursuite peut être perdue.

La situation aérienne, est envoyée vers la visualisation pour l'exploitation locale ou transmise vers un centre pour une éventuelle corrélation avec des informations en provenance d'autres radars.

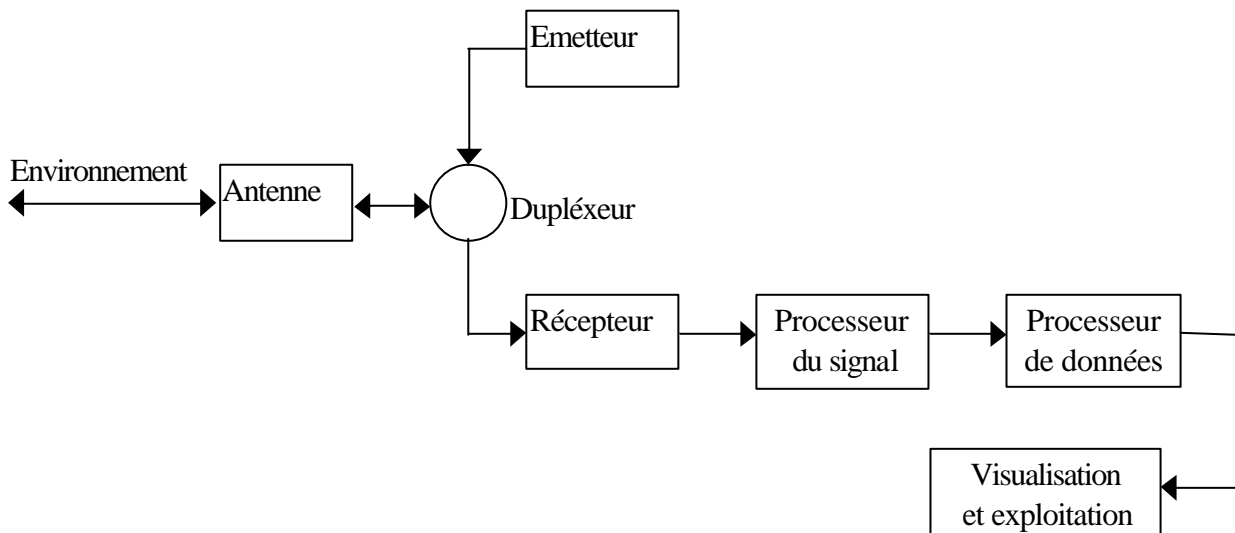


Figure 2-1 schémas fonctionnels simplifiés d'un radar moderne

II.3. DESCRIPTION D'UN SYSTEME DE POURSUITE

L'objectif de la poursuite est la répartition des données radar sous forme de pistes. Chaque piste représente les données en provenance d'une même cible. Le principe de la poursuite a été utilisé pour la première fois en 1955 par Wax [4]. Au début les pistes sont formées manuellement par un opérateur qui marquait les positions des cibles avec un stylo sur un tableau (Plan Position Indicator, PPI). Wax a remarqué une grande similarité entre le problème de poursuite radar et le problème de physique nucléaire qui consiste à identifier la trajectoire des vraies particules dans un milieu bruité. Il a donc postulé que les éléments suivant d'une piste : l'initiation, le maintien et l'abandon sont communs pour tous les types de poursuite multicibles. Kalman a développé en 1960 [5] une technique de filtrage destinée à l'estimation récursive d'état des cibles. La formulation Bayésienne développée par Sittler [6] en 1964 a constitué une base pour les développements qui ont suivi. Dès 1970, la théorie de poursuite multicibles est devenue un important domaine de recherches. Parmi ceux qui ont participé à son développement [2][3], nous citons comme exemple Y. Bar-Shalom, E. Tse, R. A. Singer, A. J. Jaffer, J.J. Stein,...

Nous définissons la poursuite radar comme étant l'estimation des trajectoires des objectifs évoluant dans l'espace de couverture radar, en se basant sur les plots issus du processeur du signal. Elle consiste à associer à chaque cible détectée dans le champ de couverture radar, parmi les plots reçus, celui qui lui correspond, filtrer les bruits de mesure, et supprimer les faux plots correspondant au clutter et qui ont échappé à la fonction de Corrélation & Interpolation. Les plots sont alors regroupés sous forme de pistes, où chaque piste est attribuée à une cible. Il est nécessaire d'assurer la poursuite même dans des situations difficiles tel que la présence de cibles manœuvrantes, la présence de plusieurs cibles proches et le croisement de pistes. Pour se faire, la fonction de poursuite comprendra les opérations d'initiation de pistes, d'association de plots avec les pistes, de filtrage et prédiction, et d'abandon de pistes. La Figure 1-2 montre l'organigramme de l'algorithme de poursuite qu'on va présenter dans ce chapitre [2]. Nous avons développé cet algorithme afin de permettre le test et l'évaluation de la méthode d'association plots/pistes à base de réseaux de Hoppfield que nous avons proposée.

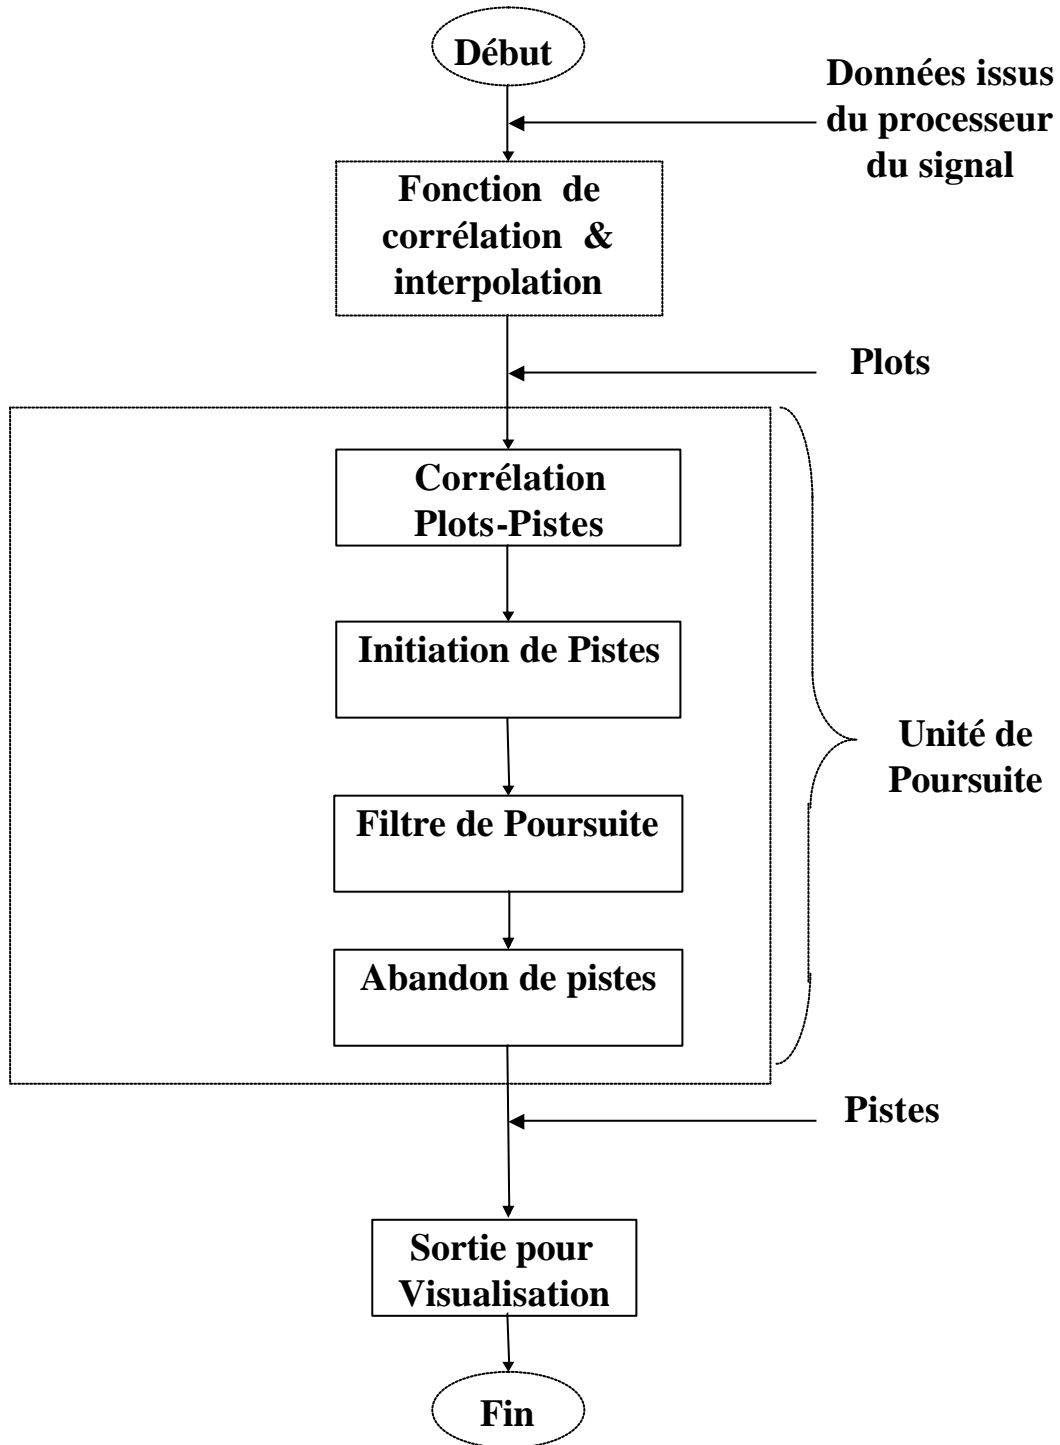


Figure 2-2 Organigramme simplifié d'un algorithme de poursuite

II.3.1. Organisation des Pistes et des Plots

Dans un système TWS, l'algorithme de poursuite est exécuté à la base de secteurs azimutaux [2][3]. Par conséquent, l'espace de couverture radar est divisé en secteurs plots et en secteurs pistes. Un secteur est une zone de l'espace délimitée en azimut à laquelle sont attribués deux espaces mémoires. L'un est réservé pour le stockage des plots provenant de l'unité de Corrélation & Interpolation et l'autre pour le stockage des pistes de tous types. Une piste est dans un secteur, si sa position prédite y est. La dimension de ces secteurs est sélectionnée de façon à assurer deux compromis. Nous choisissons une dimension du secteur petite pour limiter le nombre de plots et de pistes dans le processus d'association de données d'une part, et d'autre part nous désirons que cette dimension soit assez large de façon que l'écart entre la position prédite et la position mesurée soit inférieur à la dimension de ce secteur.

Les paramètres principaux des plots qui sont la distance, l'azimut, la vitesse, et un facteur de qualité doivent être stockés dans la mémoire. Le facteur de qualité est un paramètre lié au groupe ayant donné le plot. Il contribuerait à éliminer éventuellement les plots du clutter. Les pistes obtenues après le traitement sont classifiées en trois types : pistes confirmées, pistes stationnaires, et tentatives de pistes. On associe à chaque piste confirmée un code qui est souvent un numéro. Ce code est nécessaire pour identifier la piste et distinguer ses paramètres dans la mémoire. Les données mémorisées d'une piste sont la position filtrée, la position prédite, les paramètres du filtre de poursuite (gain, covariances), la dimension de la porte de validation de plots, l'état de la piste (confirmée, tentative ou stationnaire), un facteur de qualité, ...

II.3.2. Filtre de Poursuite

Le filtre de poursuite sert à estimer les paramètres cinématiques présents et futures des cibles. Ces paramètres sont souvent la position, la vitesse et l'accélération [7][8]. Deux types de filtres sont utilisés dans les systèmes de poursuite multicibles, les filtres à coefficients constants dont le filtre $\alpha\beta$ est un exemple et les filtres à coefficients variables (adaptatifs) dans le temps tel que le filtre de Kalman. Le filtre de poursuite remplit deux fonctions qui sont l'estimation au tour k basée sur les données reçues sur les k tours précédents appelée filtrage, et l'estimation au tour $k+1$ basée sur les données des k tours précédents dite prédiction. Les filtres à coefficients constants ont l'avantage de l'implémentation simple contrairement aux filtres adaptatifs qui ont une meilleure précision de poursuite et un volume de calcul important.

Cependant, avec la croissance de la performance des calculateurs, les systèmes de poursuite multicibles d'aujourd'hui adoptent les techniques du filtrage de Kalman. Ce filtre a l'avantage de fournir des estimations d'états des cibles avec plus de précision. De plus, la séquence du gain est calculée automatiquement en fonction des manœuvres et des modèles des bruits de mesure.

Le filtre de poursuite est généralement caractérisé par un modèle du mouvement des cibles. Si leur dynamique diffère du modèle considéré pour le filtre, des erreurs de poursuite vont surgir. Cette situation se produit si la cible débute une manœuvre brusque qui se traduit par un changement de l'accélération. Pour cela, le filtre de poursuite est souvent couplé avec un détecteur de manœuvres qui détermine le temps de début et de fin d'une manœuvre. Ceci permet d'assurer l'adaptation du modèle du mouvement aux différentes formes de trajectoires.

La performance du filtre, en plus du modèle du mouvement, dépend étroitement du système de coordonnées utilisé. Bien que les mesures radar soient fournies en coordonnées polaires et les erreurs de mesure soient stationnaires et indépendantes, nous choisissons le repère cartésien pour son avantage de linéarité après quelques approximations. Les bruits de mesure et l'accélération affectant le mouvement de la cible sont supposés stationnaires, indépendants, et de distribution Gaussienne.

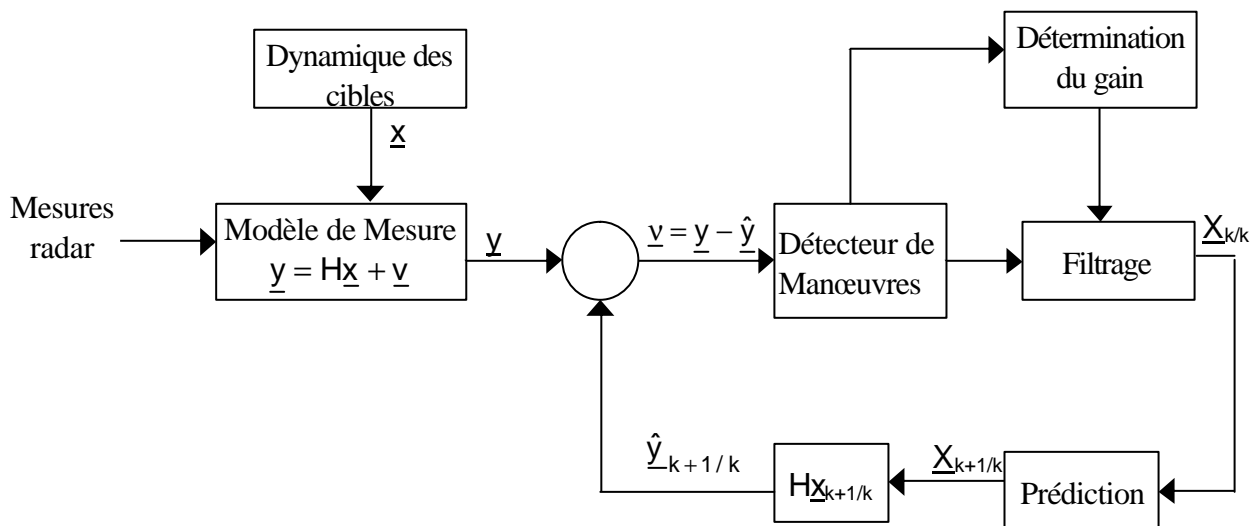


Figure 2-3 Schéma bloc d'un filtre de poursuite

II.3.3. Association plots/pistes

C'est une fonction essentielle dans un algorithme de poursuite destiné aux systèmes de surveillance opérant dans un environnement multicibles et caractérisé par un taux de fausses alarmes important. Elle consiste à sélectionner, parmi les plots reçus, celui généré par la cible en cours de poursuite pour lui être associée. Cependant, des ambiguïtés d'association sont inévitables. Un plot reçu peut être corrélé avec plusieurs pistes, comme c'est le cas de cibles rapprochées ou de trajectoires concourantes comme c'est indiqué dans la Figure 2-4(a). Deux ou plusieurs plots d'un même balayage peuvent être corrélés avec une seule piste, c'est le cas de présence de clutter comme c'est représenté dans la Figure 2-4(b).

Pour enlever ces ambiguïtés, l'opération d'association est précédée d'une fonction de validation de plots (Voir §2.5). Pour effectuer cette opération, une zone d'espace (fenêtre de validation) centrée autour de la position prédite est délimitée. La forme et la dimension de cette fenêtre sont liées aux paramètres dynamiques de la cible et aux caractéristiques du filtre de poursuite. En plus, la forme dépend du système de coordonnées (Polaires, cartésiennes...). La dimension d'une fenêtre est choisie de façon à offrir une grande probabilité pour que le plot reçu soit situé à l'intérieur (de la fenêtre) d'une part, et ne permettre qu'un faible nombre de plots d'y appartenir d'autre part. Nous sélectionnons les plots situés dans la fenêtre de validation, puis nous choisissons parmi les plots sélectionnés celui qui est le plus probable d'appartenir à la même cible. Si une piste a reçu un plot, elle est mise à jour et ensuite filtrée avant d'être envoyée au bloc de visualisation pour exploitation. Si aucun plot n'est associé à la piste, elle subira le test d'abandon. Les plots non-associés sont utilisés pour l'initiation de nouvelles pistes.

II.3.4. Initialisation de Pistes

L'objectif de l'opération d'initialisation est de confirmer la détection d'une cible nouvellement rentrant dans le champ de couverture radar et de distinguer cette détection des plots provenant du clutter [2]. Pour qu'une piste soit initialisée, il est nécessaire d'avoir un nombre de plots consécutifs suffisant provenant de la même cible. Elle est effectuée à la base des paramètres dynamiques de son mouvement. En pratique, dans les systèmes opérationnels, généralement la règle adoptée est que trois plots successifs soient acquis. Cependant, et en fonction de la probabilité de détection des plots, d'autres règles ont été proposées. Pour un radar à balayage panoramique, TWS, la méthode de la fenêtre glissante est la plus fréquente [5][3].

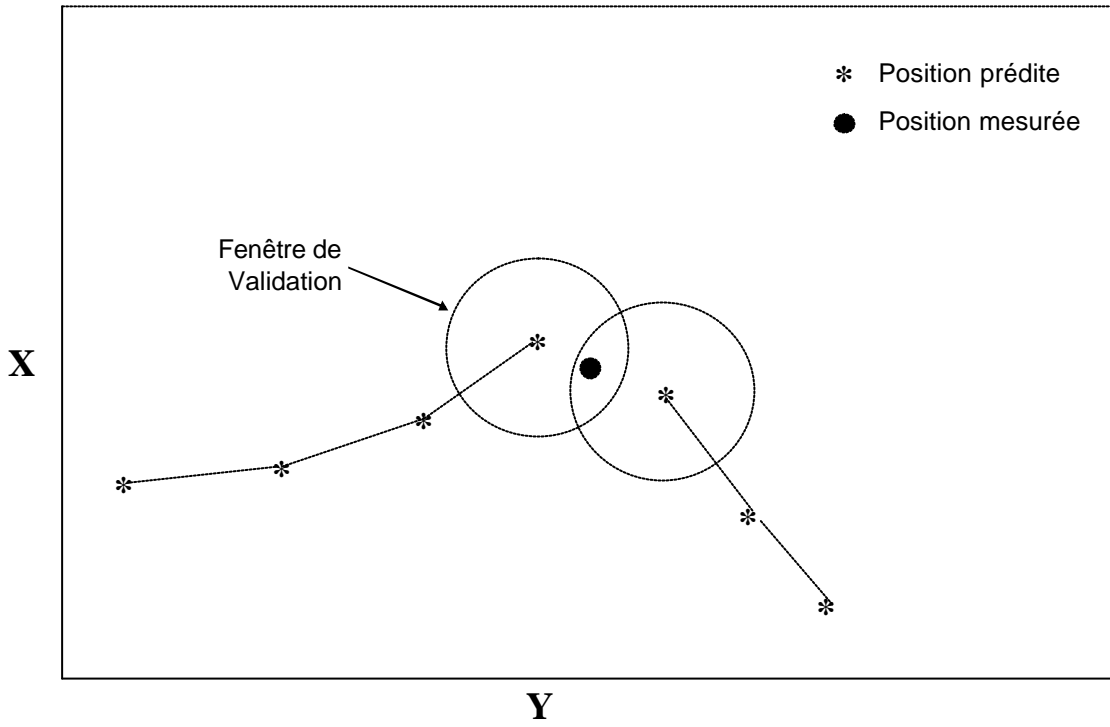


Figure 2-4a Exemple de corrélation d'un seul plot avec deux pistes

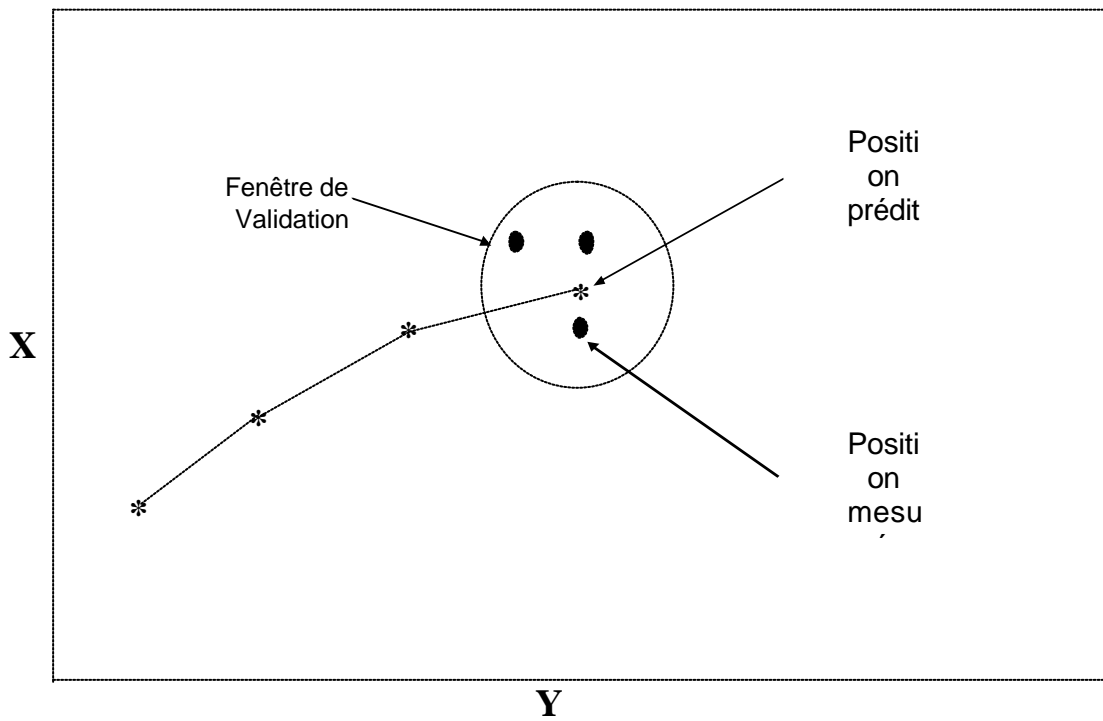


Figure 2-4b Exemple de corrélation de plusieurs plots avec une seule piste

Elle est effectuée selon une règle de M plots reçus au bout de N balayages. Par exemple, M=2 et N=3, M=3 et N=3 ; M=3 et N=4,...

On distingue deux types d'approches d'initiation de pistes, les approches séquentielles et les approches batch [30]. Les approches séquentielles sont utilisées dans des situations dégagées tel que l'approche heuristique basée sur le test de la vitesse et de l'accélération et l'approche logique basée sur la prédiction et une fenêtre glissante. Les approches batch sont utilisées avec des taux de fausses alarmes élevés dont la technique de la transformation de hough est un exemple (Voir [3] chapitre 6).

II.3.5. Abandon de Pistes

Il arrive souvent que le processeur de poursuite ne reçoive pas de plot d'une cible pendant un ou plusieurs balayages sans que la cible soit réellement sortie du champ de couverture radar. Dans ce cas, la piste n'est pas immédiatement abandonnée. Une piste ne peut être éliminée que si le processeur de poursuite ne reçoive pas de plots pendant un certain nombre de balayages successifs [3]. La fonction d'abandon doit offrir la possibilité de prolonger les pistes qui n'ont pas reçu de plots pendant ces balayages d'antenne avant d'être éliminées (confirmation de la sortie des cibles du champ de couverture radar).

II.4. MODELES DU MOUVEMENT DE CIBLES ET DE MESURE

Le choix d'un algorithme de poursuite dépend étroitement du système de coordonnées de référence, des mesures fournies par le radar, et du modèle du mouvement de la cible [2]. A la sortie de l'extracteur de plots, les mesures radar sont données en coordonnées polaires. Les erreurs de mesure sont supposées stationnaires et indépendantes. Ce système de coordonnées polaires présente la difficulté de non-linéarité du filtre correspondant parce que l'accélération en distance et en azimuth apparaît dans les équations du mouvement même pour une trajectoire rectiligne. Pour cela, il est préférable d'utiliser le système cartésien. Cependant, les erreurs de mesure ne sont pas stationnaires et sont corrélées, mais le modèle du filtre correspondant est linéaire.

Il s'avère qu'en supposant que les bruits de mesure sont stationnaires et indépendants, la performance du filtre de poursuite n'est pas affectée et le développement mathématique se simplifie considérablement. Nous considérons que l'accélération qui affecte le mouvement des

cibles est un bruit stationnaire, indépendant, et de distribution Gaussienne [2]. Les plots, qui sont présentés à la sortie de l'extracteur en coordonnées polaires (ρ, θ), sont affectés d'erreurs de mesure donnant,

$$\rho_m = \rho + \Delta\rho \quad (2-1)$$

et

$$\theta_m = \theta + \Delta\theta \quad (2-2)$$

où ρ_m et θ_m sont respectivement la distance et l'azimut mesurées, ρ et θ sont les coordonnées réelles de la cible, et $\Delta\rho$ et $\Delta\theta$ sont des bruits stationnaires, indépendants et Gaussiens de moyennes nulles et de variances respectivement σ_ρ^2 et σ_θ^2 . Ces variances sont exprimées en fonction de la dimension des cellules d'intégration du radar, qui est généralement liée à la résolution en distance et en azimut du faisceau d'antenne. Par conséquent, les variances σ_ρ^2 et σ_θ^2 sont données par les expressions suivantes

$$\sigma_\rho^2 = 0.1 \left(\frac{c\tau}{2} \right)^2 \quad (2-3)$$

et

$$\sigma_\theta^2 = 0.1 (B_\theta)^2 \quad (2-4)$$




Figure 2-5 Systèmes de coordonnées polaires et cartésiennes

Avec c est la vitesse de propagation des ondes dans l'atmosphère, τ est la durée des impulsions d'émission, et B_θ est l'ouverture du faisceau d'antenne. En coordonnées cartésiennes, les mesures (dans un plan XY) sont formées à travers les équations suivantes

$$x = \rho \cos \theta \quad (2-5)$$

et

$$y = \rho \sin \theta \quad (2-6)$$

Par conséquent, les erreurs de mesure deviennent

$$\Delta x = \Delta \rho \cos \theta - \Delta \theta \rho \sin \theta \quad (2-7)$$

et

$$\Delta y = \Delta \rho \sin \theta + \Delta \theta \rho \cos \theta \quad (2-8)$$

Où Δx et Δy sont des bruits non stationnaires et corrélés, de moyenne nulle et de variances respectives σ_x^2 , σ_y^2 et σ_{xy} exprimées par

$$\sigma_x^2 = \sigma_\rho^2 \cos^2 \theta + \rho^2 \sigma_\theta^2 \sin^2 \theta, \quad (2-9)$$

$$\sigma_y^2 = \sigma_\rho^2 \sin^2 \theta + \rho^2 \sigma_\theta^2 \cos^2 \theta \quad (2-10)$$

et

$$\sigma_{xy} = (\sigma_\rho^2 - \rho^2 \sigma_\theta^2) \sin \theta \cos \theta \quad (2-11)$$

Si nous considérons que les erreurs des mesures précédentes sont stationnaires, indépendantes et de même variance, nous aurons donc $\sigma_{xy} = 0$ et $\sigma_x^2 = \sigma_y^2$. Nous formulons les modèles respectifs de la dynamique du mouvement des cibles et de mesure par les expressions suivantes [2][9] :

$$X_{k+1} = F_k X_k + w_k \quad (2-12)$$

$$z_k = H_k X_k + v_k \quad (2-13)$$

ou X_k est le vecteur d'état de dimension n , F_k est la matrice de transition de dimension $n \times n$, z_k est le vecteur mesure de dimension d , H_k est la matrice d'observation de dimension $d \times n$, w_k et v_k sont les vecteurs bruit de dimension d , qui affectent respectivement le mouvement de cibles et les mesures radar. Ces vecteurs bruits sont supposés indépendants l'un de l'autre, et normalement distribués avec moyennes nulles et matrices de covariance Q_k et R_k définies comme suit

$$\begin{aligned} E[w_k w_j^T] &= Q_k \delta_{kj} \\ E[v_k v_j^T] &= R_k \delta_{kj} \end{aligned} \quad (2-14)$$

où δ_{kj} est le symbole de Kronecker. Le vecteur d'état initial X_0 est supposé une variable aléatoire indépendante des bruits w_k et v_k et normalement distribuée avec une moyenne \hat{X}_{00} et une matrice de covariance P_{00} . On note par $Z_k = \{z_{k,j}\}_{j=1}^{m_k}$ l'ensemble des mesures validées au k ème tour, et par $Z^k = \{Z_j\}_{j=1}^k$ l'histoire des mesures validées sur k balayages d'antenne.

II.5. VALIDATION DES PLOTS

En pratique, le flux des mesures radar peut être grand, et le nombre de pistes en poursuite peut être important. Ceci se traduit par un nombre excessif d'hypothèses d'association plots/pistes. La fonction de validation de plots permet de réduire le nombre de plots qui vont être candidats à l'association plots/pistes [2][3]. Elle consiste à sélectionner parmi les plots reçus, celui qui est plus proche de la piste. Pour cela, nous déterminons une zone d'espace centrée autour de la position prédite, appelée fenêtre de corrélation. La forme et la dimension de cette fenêtre sont liées aux paramètres dynamiques du mouvement des cibles d'un côté, et d'autre côté, aux caractéristiques du filtre de poursuite utilisé. De plus, sa forme dépend du système de coordonnées (Polaire, cartésiennes...). La dimension d'une fenêtre est choisie de façon à offrir une meilleure chance au vrai plot de se situer à l'intérieur d'une part, et d'autre part, diminuer le nombre des faux plots d'y appartenir. Nous supposons qu'on reçoit une mesure $z_{k,i}$ au balayage k , et que le filtre de poursuite fournit le vecteur de prédiction $\underline{S}_{k/k-1}$. Nous définissons l'innovation $\underline{v}_{k,i}$, la distance entre la position mesurée et la position prédite, par l'expression suivante

$$\underline{v}_{k,i} = z_{k,i} - \underline{H}_k \underline{S}_{k/k-1} \quad (2-15)$$

Où \underline{H}_k est la matrice d'observation du modèle du filtre de poursuite. L'innovation $\underline{v}_{k,i}$ est considérée une variable aléatoire de distribution Gaussienne avec la moyenne nulle et la matrice de covariance exprimée comme suit

$$\underline{\theta}_k = \underline{H}_k \underline{P}_{k/k-1} \underline{H}_k^T + \underline{R}_k \quad (2-16)$$

Où $\underline{P}_{k/k-1}$ est la matrice de covariance des erreurs de prédiction, et \underline{R}_k est la matrice de covariance des erreurs de mesure. La fonction densité de probabilité de l'innovation est donnée par

$$f(\underline{v}_{k,i}) = \frac{1}{(2\pi)^{M/2} \sqrt{|\underline{\theta}_k|}} \exp\left[-\frac{\underline{v}_{k,i}^T \underline{\theta}_k^{-1} \underline{v}_{k,i}}{2}\right] \quad (2-17)$$

La validation de plots est un test effectué entre l'hypothèse H_1 que le plot reçu et la piste appartiennent à la même cible et l'hypothèse H_0 que le plot reçu et la piste appartiennent à deux cibles différentes. Nous définissons $p_0(\underline{v}_{k,i})$, la probabilité de décider l'hypothèse H_0 vrai, et $p_1(\underline{v}_{k,i})$, la probabilité de décider H_1 vrai. Ce test (most powerful test) est le suivant

$$\frac{p_1(\underline{v}_{k,i})}{p_0(\underline{v}_{k,i})} \underset{H_0}{\overset{H_1}{>}} \lambda \quad (2-18)$$

où λ , un paramètre non nul, est le seuil de décision. Le test de validation est basé sur le traitement de l'innovation \underline{v}_k . Pour l'hypothèse H_0 , puisque l'information sur la distribution des faux plots dans l'espace n'est pas connue, la probabilité $p_0(\underline{v}_{k,i})$ est considérée constante et le test de corrélation devient

$$y_k = \underline{v}_k^T \underline{\theta}_k^{-1} \underline{v}_k \leq S_v \quad (2-19)$$

où y_k est une variable quadratique de Chi-deux de degré de liberté M . S_v , le seuil de validation, est un paramètre déterminant de la dimension de la fenêtre de validation [3], et est donné par

$$S_v = 2 \log \left[\frac{P_d}{(1 - P_d) \beta (2\pi)^{\frac{M}{2}} \sqrt{|\theta_k|}} \right] \quad (2-20)$$

P_d est la probabilité de détection et β est la densité des plots dans l'espace de couverture radar, répartis selon la distribution de Poisson. $|\theta_k|$ est le déterminant de la matrice de covariance θ_k de l'innovation. Nous associons à chaque seuil S_v une probabilité $P_v(M)$ de validation des plots par une piste quelconque. Elle est exprimée en fonction du seuil de validation comme suit [3]

$$P_v(M) = \int_{V_s} \dots \int f(v_k) dv_{k,1} \dots dv_{k,M} \quad (2-21)$$

où M est la dimension des mesures, et V_s est le volume de la fenêtre de validation donné par l'expression suivante [3]

$$V_s = C_M \sqrt{|\theta_k|} S_v^{M/2} \quad (2-22)$$

où S_v est le seuil de corrélation donné par l'équation (2-20), $|\theta_k|$ le déterminant de la matrice de covariance de l'innovation, et C_M , paramètre lié à la dimension de l'innovation M , est défini par

$$C_M = \begin{cases} \frac{\pi^{M/2}}{(M/2)!}, & \text{si } M \text{ paire} \\ \frac{2^{M+1} \left(\frac{M+1}{2}\right) \pi^{\frac{M-1}{2}}}{(M+1)!}, & \text{si } M \text{ impaire} \end{cases} \quad (2-23)$$

Le développement de l'équation (2-21) permet d'obtenir les expressions de la probabilité de validation en fonction de la dimension M des mesures de 1 à 3 comme s'est montré dans le tableau 2-1 [3]. Puisque les plots sont répartis selon la distribution de Poisson dans l'espace de couverture radar, la probabilité $p(n)$ de recevoir n plots pendant un tour d'antenne dans le volume de la fenêtre de validation V_s est donnée par

M	$P_v(M)$
1	$2gc(\sqrt{V_s})$
2	$1 - \exp(-\frac{V_s}{2})$
3	$2gc(\sqrt{V_s}) - \sqrt{\frac{2V_s}{\pi}} \exp(-\frac{V_s}{2})$

Tableau 2-1 Expression de la probabilité de validation des mesures en

fonction de la dimension M. $gc(x) = \frac{1}{\sqrt{2\pi}} \int_0^x \exp(-u^2/2) du$

$$p(n) = \frac{(\beta V_s)^n}{n!} \exp(-\beta V_s) \quad (2-24)$$

Nous associons à chaque plot validé dans la fenêtre de validation de volume V_s , une probabilité de correcte corrélation sachant que ce plot est détecté avec une probabilité P_d . Elle est exprimée comme suit

$$p_{cc/d} = \int_{V_s} \dots \int_{V_s} e^{-\beta V_s} f(v) dv_x dv_y \dots \quad (2-25)$$

Cependant, comme le clutter est souvent présent dans le champ de couverture radar, des faux plots sont toujours reçus par l'unité de poursuite dans la fenêtre de validation. Ces plots sont répartis dans l'espace de surveillance selon la distribution de poisson. Nous définissons la probabilité qu'aucun faux plot n'appartienne à la fenêtre de validation par P_{ne} que nous exprimons comme suit

$$p_{ne} = e^{-\beta V_c} \quad (2-26)$$

où β est la densité des faux plots dans l'espace exprimée en fonction du volume de mesure V_M , la probabilité de fausse alarme P_{FA} , et le nombre des faux plots N_E reçus dans le volume de couverture radar V_c . β est donc exprimé par

$$\beta = \frac{P_{FA}}{V_M} + \frac{N_E}{V_s} \quad (2-27)$$

En substituant les équations (2-25) et (2-26) dans l'équation (2-23), et après le développement mathématique, la probabilité d'une correcte corrélation d'un vrai plot sachant qu'il est détecté s'écrit sous la forme

$$P_{cc/d} = P_v(M) - \frac{\beta C_M \sqrt{|\theta_k|}}{2^{M/2} \Gamma(M/2)} I(M, S_v) \quad (2-28)$$

Où

$$\Gamma(M, G) = 2^M (M-1)! - e^{S_v/2} \left[\sum_{i=1}^M 2^i S_v^{M+1-i} \prod_{j=0}^{i-1} (M-1-j) \right] \quad (2-29)$$

La probabilité de correcte corrélation, P_{cc} , est donnée en fonction de la probabilité de détection, P_d , et de la probabilité d'une correcte corrélation d'un plot à une piste sachant qu'il y a détection, $P_{cc/d}$. P_{cc} est donc

$$P_{cc} = P_d P_{cc/d} \quad (2-30)$$

Finalement, nous définissons la probabilité d'une correcte décision, P_{cd} ,

$$P_{cd} = P_{cc} + (1 - P_d) P_{NE} \quad (2-31)$$

P_{NE} est la probabilité qu'aucune autre cible n'est dans la fenêtre de validation (aucune vraie mesure n'est dans la fenêtre de validation). La probabilité de correcte corrélation sachant que la cible est détectée est donnée par le produit de la probabilité de validation P_v et la probabilité qu'aucune autre vraie mesure n'est validée P_E ,

$$P_{cc/d} = P_v (1 - P_E) \quad (2-32)$$

Finalement, la probabilité de fausse corrélation P_{fc} est la somme des termes des probabilités de fausse corrélation sachant que la vraie mesure est validée et elle ne l'est pas.

$$\begin{aligned} P_{fc} &= P_d P_v P_E + (1 - P_d P_v) (1 - P_{NE}) \\ &= P_d (P_v - P_{cc/d}) + (1 - P_v P_d) (1 - P_{NE}) \end{aligned} \quad (2-33)$$

Pour l'évaluation des systèmes de poursuite multicibles, Les quantités P_{cc} , P_{fc} , et P_{cd} , sont examinées en utilisant la simulation de Monte Carlo.

Les systèmes de poursuite sont souvent vérifiés en fin de compte par l'analyse des résultats statistiques obtenus à partir des simulations de Monte Carlo. Pour cela, les quantités suivantes : la probabilité de correcte corrélation P_{cc} , la probabilité de fausse corrélation P_{fc} , et la probabilité de correcte décision P_{cd} sont évaluées (Voir Tableau 2-2). En pratique, la probabilité de détection P_d et le rapport signal sur bruit SNR sont inconnus. Par conséquent, nous fixons la probabilité de fausse alarme P_{fa} , et nous faisons varier le rapport signal/bruit SNR. Ensuite, nous calculons la probabilité de détection P_d , le seuil de validation S_v , et la probabilité de validation P_v . Finalement, nous obtenons les variations des quantités P_{cc} , P_{fc} et P_{cd} en fonction du rapport signal/bruit SNR et de la probabilité de fausse alarme P_{FA} (Voir les Figures 2-6 à 2-11).

<i>M</i>	<i>expression</i>
Probabilité de validation :	$P_v = 1 - \exp\left(-\frac{S_v}{2}\right)$
Seuil de validation :	$S_v = 2 \log\left[\frac{P_d}{(1 - P_d)} \beta (2\pi) \sqrt{ \theta_k }\right]$
Volume de la fenêtre de validation :	$V_s = \pi \sqrt{ \theta_k } S_v$
Probabilité de correcte corrélation sachant qu'un plot est détecté :	$P_{cc/d} = P_v - \frac{\pi \beta \sqrt{ \theta_k }}{2} \left[4 - e^{-S_v/2} (2S_v + 4)\right]$
Probabilité de correcte corrélation	$P_{cc} = P_d P_{cc/d}$
Probabilité de correcte décision	$P_{cd} = P_{cc} + (1 - P_d) P_{NE}$
Probabilité de fausse corrélation	$P_{fc} = P_d (P_v - P_{cc/d}) + (1 - P_v P_d) (1 - P_{NE})$

Tableau 2-2 expression des paramètres statistiques dans le cas bidimensionnel, $M=2$




Figure 2-6 variation de la probabilité de détection en fonction du rapport Signal sur bruit et de la probabilité de fausse alarme




Figure 2-7 variations du seuil de validation en fonction du rapport Signal sur bruit et de la probabilité de fausse alarme




Figure 2-8 variations de la probabilité de validation en fonction du seuil de validation




Figure 2-9 variations de la probabilité de correcte corrélation en fonction du rapport Signal sur bruit et de la probabilité de fausse alarme




Figure 2-10 variations de la probabilité de fausse corrélation en fonction du rapport signal sur bruit et de la probabilité de fausse alarme




Figure 2-11 variations de la probabilité d'une correcte décision en fonction du rapport signal sur bruit et de la probabilité de fausse alarme

II.5. CONCLUSION

La situation aérienne se caractérise en général par un taux élevé de fausses alarmes générées par le clutter et de fortes manœuvres générées par des cibles réelles. Le nombre excessif de plots reçus sur un tour d'antenne constitue une ambiguïté de leur association avec les pistes. Cette situation a poussé beaucoup de concepteurs de radars à concentrer leurs efforts autour du développement et du perfectionnement des algorithmes de traitement automatique de données radar qui se déroulent généralement sous de fortes contraintes de temps réel et de précision, afin de répondre aux exigences de la surveillance aérienne moderne civile et militaire.

Nous avons présenté, dans ce chapitre, une description générale des différents blocs d'un système radar TWS moderne. Nous avons décrit aussi les différentes fonctions d'un algorithme de poursuite. Cette fonction est souvent précédée par une opération de validation qui réduit le nombre de plots candidats à l'association avec les pistes. Le modèle de poursuite est souvent présenté dans un système de coordonnées cartésiennes. Pour l'évaluation des systèmes de poursuite multicibles, Les quantités P_{cc} , P_{fc} , et P_{cd} , sont examinées en utilisant la simulation de Monte Carlo.

CHAPITRE III TECHNIQUES D'ASSOCIATION DE DONNEES RADAR

CONTENU :

III.1. INTRODUCTION.....	32
III.2. METHODE DU PLUS PROCHE VOISIN.....	32
III.3. METHODE DE PARTAGE DE PISTES (TRACK SPLITTING).....	34
III.4. METHODE BASEE SUR LE MAXIMUM DE VRAISEMBLANCE	37
III.5. METHODE D' ASSOCIATION PROBABILISTIQUE DE DONNEES (PDA).....	40
III.6. METHODE MODIFIEE D' ASSOCIATION PROBABILISTIQUE DE DONNEES	42
III.7. METHODE ADAPTATIVE D' ASSOCIATION PROBABILISTIQUE DE DONNEES.....	45
III.8. METHODE D' ASSOCIATION PROBABILISTIQUE CONJOINTE DE DONNEES	46
III.9. METHODE D' ASSOCIATION BASEE SUR LES MODELES DE MARKOV CACHES (HMM).....	48
III.9.1. Présentation des modèles de Markov cachés.....	48
III.9.2. Application à la Poursuite	49
III.9.3. Algorithme de Viterbi.....	50
III.10. CONCLUSION	51

III.1. INTRODUCTION

Depuis que la fonction de poursuite automatique est incorporée dans la chaîne de traitement radar, plusieurs approches [6-17] se sont développées pour résoudre le problème d'association de plots avec les pistes, afin de répondre aux exigences en terme de performance de poursuite et de complexité d'implémentation. Ces approches sont classées en trois catégories [11][13][16] : Les approches dites orientées cible, les approches dites orientées mesure, et les approches dites orientées piste. Dans le cas des méthodes basées sur les pistes, les mesures sont supposées vraies ou de fausses alarmes. Une seule mesure au maximum choisie au voisinage de la piste peut être générée par la cible correspondante. Les pistes sont indépendantes et par conséquent ne peuvent concourir les mêmes mesures. Les méthodes Bayésiennes font partie de cette catégorie dont la méthode JPDA est un exemple.

Dans le cas des méthodes basées sur les mesures, chacune d'elles est supposée soit générée par une cible déjà existante, soit c'est la première détection d'une nouvelle cible, soit c'est une fausse alarme. Les hypothèses concernant l'historique de détection des cibles déjà existantes sont déduites des hypothèses des mesures validées. Cette catégorie rassemble toutes les approches non-Bayésiennes tel que l'approche du maximum de vraisemblance. Leur principe est basé sur la prise de décision d'accepter ou de rejeter une piste en se servant de sa fonction de vraisemblance et de l'estimation d'état. Tandis que les approches orientées cibles sont basées sur le principe que chaque cible est supposée non détectée, abandonnée, ou elle débute une manœuvre.

Dans ce qui suit, on présente une description théorique de quelques méthodes d'association qui sont pratiquement utilisées dans la poursuite radar ou qui sont au stade de développement. Parmi ces méthodes on cite la méthode du plus proche voisin [2], la méthode de partage de pistes [8], la méthode d'association probabilistique de données [9], méthode basée sur le maximum de vraisemblance [10], ...

III.2. METHODE DU PLUS PROCHE VOISIN

Les ambiguïtés d'association apparaissent quand un ou plusieurs plots sont présents dans la même fenêtre de validation, ou quand un plot est présent dans plusieurs fenêtres de validation. Le principe de la méthode du plus proche voisin [2][3] consiste à sélectionner, parmi les plots validés, le plot le plus proche de la position prédite pour mettre à jour la piste de la cible.

Il s'agit donc de minimiser la distance totale entre les pistes et les plots avec lesquelles elles sont mises à jour. Pour illustrer cette méthode, nous prenons l'exemple de la Figure 3-1. Le plot M3 est associé à la piste P1 parce que c'est le seul plot dans la fenêtre de validation de P1, malgré qu'il soit plus proche à la piste P2. Le plot M2 est associé à la piste P2 parce qu'il est plus proche que le plot M1. La piste P3 n'a aucun plot dans sa fenêtre de validation. Les plots M1, M4 et M5 vont initier de nouvelles pistes.

Nous formulons cette méthode comme suit :

1. Détermination de la matrice de validation dont les lignes correspondent aux pistes et les colonnes correspondent aux plots. Les éléments de cette matrice représentent la distance quadratique entre les plots et les pistes.
2. Les plots qui ne sont validés qu'avec une seule piste sont automatiquement associés à ces pistes. Les autres plots validés avec ces pistes sont ignorés.




Figure 3-1 Exemple de corrélation plots/pistes. M1, M2, M3, M4 et M5 sont les plots et P1, P2 et P3 sont les positions prédites des pistes.

3. Les pistes qui n'ont validé qu'un seul plot on leurs associe automatiquement ces plots même s'ils sont validés avec d'autres pistes.
4. Pour chaque piste, nous sélectionnons le plot le plus proche et nous déterminons la piste la plus proche à ce plot. Nous associons ce plot à la plus proche des deux pistes.

Cette méthode n'est pas optimale même si le modèle de la dynamique des cibles est linéaire et les bruits sont gaussiens. La mesure sélectionnée peut être une fausse alarme, car la vraie mesure n'est pas forcément la plus proche à la piste. Par conséquent, la qualité de la poursuite basée sur cette méthode est généralement dégradée.

III.3. METHODE DE PARTAGE DE PISTES (TRACK SPLITTING)

Quand plus d'un plot sont présents dans la fenêtre de validation, il est difficile de choisir parmi ces plots celui qui va mettre à jour la piste en poursuite. Ce problème devient plus grave quand cette piste effectue des manœuvres. La méthode de partage de pistes [8] est basée sur le principe de prendre en compte l'information de la manœuvrabilité des cibles dans toute prise de décision d'association d'une mesure quelconque. Pour permettre ceci, on constitue deux séries d'hypothèses, l'une sur l'association des mesures et l'autre sur la manœuvrabilité des cibles. La prise de décision d'associer une mesure est retardée un certain nombre de tours et ces hypothèses sont prolongées sous forme de branches. On associe à chaque branche une probabilité de vraisemblance et une estimation d'état. Les branches qui sont constituées de la même séquence de mesures pendant les derniers N tours et ont la même séquence de manœuvres pendant M tours sont combinées dans une seule branche, d'où l'appellation filtre à (N, M) tours. Il a été démontré que la trajectoire d'un aéronef est constituée de segments rectilignes séparés par des virages [2]. Par conséquent, nous pouvons considérer que l'historique de l'accélération $\{U_k\}$ est une séquence discrète dont les valeurs sont $\{\alpha_1, \alpha_2, \dots, \alpha_m\}$, et peut être modélisée par un modèle Markovien. La matrice des probabilités de transition A_{ij} est supposée connue et indépendante du nombre de tours d'antenne.

$$A_{ij} = P\{U_k = \alpha_i / U_{k-1} = \alpha_j\} \quad (3-1)$$

On suppose qu'on a reçu m_{k-1} mesures au $(k-1)^{\text{ème}}$ tour d'antenne. On définit par χ_{k-1}^i l'hypothèse d'associer une mesure i à la cible qui l'a générée et qui correspond à un historique

d'accélération. On indique par $\{\chi_{k-1}^i\}_{i=1}^{m_{k-1}}$ l'ensemble des hypothèses d'association possibles à cette même piste. On associe à chaque hypothèse χ_{k-1}^i une branche de piste caractérisée par un vecteur de l'estimation d'état \hat{x}_{k-1}^i , une matrice de covariance \hat{P}_{k-1}^i et une probabilité β_{k-1}^i que l'hypothèse d'association qui l'a générée est correcte, et qu'on définit comme suit

$$\beta_{k-1}^i = p(\chi_{k-1}^i | Z^{k-1}, M^{k-1}, H_T^{k-1}) \quad (3-2)$$

ou $Z^{k-1} = \{Z_j\}_{j=1}^{k-1}$ est l'ensemble des mesures cumulées sur $k-1$ tours et $Z_j = \{z_{ij}\}_{i=1}^{m_{j-1}}$ est l'ensemble des mesures reçues au (j) ème tour avec $j=1, 2, \dots, k-1$, $M^{k-1} = [m_1, m_2, \dots, m_{k-1}]$ est le vecteur des nombres de mesures reçues chaque tour, et H_T^{k-1} est l'hypothèse que la cible est présente pendant les $(k-1)$ tours. On définit l'hypothèse ψ_k^j que la j ème mesure du k ème tour est générée par la cible en cours de poursuite. L'indice $j=0$ indique qu'aucune des mesures n'est générée par cette cible. On définit aussi l'hypothèse Γ_k^ℓ que la variable Markovienne d'entrée U_k prend la valeur α_ℓ . On suppose qu'au $(k-1)$ ème tour, on a un nombre limité de mesures m_{k-1} à associer à la piste. Chacune de ces mesures forme une branche au k ème tour et constitue une ambiguïté d'association avec une valeur d'entrée de manœuvre. L'ensemble des hypothèses du tour k est défini comme suit

$$\{\chi_k^s\}_{s=1}^{n_k} = \{\chi_{k-1}^i \cup \psi_k^j \cup \Gamma_k^l\}_{i=1}^{m_{k-1}} \quad M_k \quad m_k \quad (3-3)$$

La probabilité de chaque branche $s(i, j, l)$ qu'elle est correcte peut être écrite sous la forme suivante

$$\beta_k^{s(i,j,l)} = P(\chi_k^{s(i,j,l)} | Z^k, M^k, H_T^k) \quad (3-4)$$

Après le traitement des mesures en cours, il peut en résulter un nombre excessif de branches. Parmi ces branches il y aura celles qui vont être combinées pour donner une seule branche et celles qui vont être supprimées. Les branches combinées sont associées avec les mêmes mesures durant les derniers N tours et ont le même historique d'accélération durant les derniers M tours. Dans le cas de non-association, les branches qui ne sont associées à aucune mesure durant $L (>N)$ tours et qui présentent la même séquence d'accélération pendant les

derniers M tours sont combinées dans une seule branche. Ainsi on formule le critère de combinaison comme suit : On combine les branches qui ont des historiques identiques d'association (ou de non-association) pendant J tours et des historiques d'accélération identiques pour les derniers M tours si et seulement si

$$\sum_{j=0}^J W_{k-J+j} \geq 1 \quad (3-5)$$

ou

$$W_i = \begin{cases} 1/N & \text{si la branche a une association au tour } i \\ 1/L & \text{sinon} \end{cases} \quad (3-6)$$

Après la combinaison des branches, on détermine les paramètres de la nouvelle branche composite. Si on définit pour chaque branche primaire i l'hypothèse χ_k^i , le vecteur d'état $x_{k/k}^i$, la matrice de covariance $P_{k/k}^i$, et la probabilité β_k^i , les paramètres de la branche composite sont exprimés comme suit

hypothèse

$$\chi_k = \bigcup_{i \in I} \chi_k^i \quad (3-7)$$

vecteur d'état

$$x_{k/k} = \sum_{i \in I} \beta_k^i x_{k/k}^i \quad (3-8)$$

matrice de covariance

$$P_{k/k} = \sum_{i \in I} \beta_k^i \left(P_{k/k}^i + x_{k/k}^i (x_{k/k}^i)^T \right) - x_{k/k} (x_{k/k})^T \quad (3-9)$$

probabilité

$$\beta_k = \sum_{i \in I} \beta_k^i \quad (3-10)$$

Une piste est donnée par la combinaison de toutes ses branches. La probabilité d'une piste moyenne est généralement égale à l'unité. Les équations (3-8) et (3-9) sont utilisées pour déterminer le vecteur d'état et la matrice de covariance de la piste moyenne. C'est cette dernière qui est envoyée à la visualisation pour l'exploitation.

III.4. METHODE BASEE SUR LE MAXIMUM DE VRAISEMBLANCE

La plupart des travaux qui sont menés pour résoudre le problème d'association plots/pistes sont basés sur l'aspect théorique, et les idées qui sont orientées vers l'aspect pratique sont restées vagues. L'approche basée sur le maximum de vraisemblance [10], qu'on va présenter dans ce paragraphe, entraîne des améliorations considérables de la qualité de poursuite. Sa forme séquentielle proche de l'optimum facilite son implémentation sur un ordinateur numérique. Elle rassemble toutes les phases de poursuite à savoir l'initiation, la confirmation et l'abandon. Cette méthode trouve son application surtout dans les systèmes de surveillance opérant dans un environnement de cibles multiples et en présence de fausses alarmes. Les mesures sont reçues périodiquement à des intervalles réguliers avec une probabilité de détection P_d . Dans cette méthode, aucune référence n'est faite aux cibles non détectées, et elle ne fait pas de distinction entre les vraies mesures et les fausses alarmes. Le principe de la méthode consiste à associer une fonction 'score' à chaque cible. Pour l'abandon de piste, une deuxième fenêtre de validation est utilisée autour de la position prédite.

On suppose que le nombre de plots reçus par tour d'antenne est m . On définit par β la densité des cibles réelles et par λ la densité des fausses alarmes par unité d'espace Δ . La densité des nouvelles mesures par tour d'antenne est donc $\beta' = \beta + \lambda$ [10]. La probabilité P_0 que n cibles surgissent durant k tours d'antenne dans l'espace de surveillance de volume S est donnée par la loi de Poisson comme suit

$$P_0 = \frac{(\beta' \Delta)^n}{n!} \exp(-k\beta'S) \quad (3-11)$$

On suppose que la durée de vie τ de la piste d'une cible, exprimée en seconde, est une variable aléatoire de moyenne τ_0 et de distribution exponentielle définie comme suit

$$p(\tau) = \frac{1}{\tau_0} \exp\left(-\frac{\tau}{\tau_0}\right) \quad (3-12)$$

On définit D_i la longueur d'une piste exprimée en nombre de tours, et D_E est la longueur moyenne. On pose $\tau_0 = D_E T$, où T est la période de balayage d'antenne radar. La probabilité

d'une source i détectée durant D_i tours durant $(k-1)$ tours, et non détectée au $k^{\text{ème}}$ tour, est définie comme suit

$$P_{TL1}(D_i) = \begin{cases} C_1 + C_2 C_{D_E}; & D_i = 0 \\ C_2 C_{D_E} \exp\left(-\frac{D_i}{D_E}\right); & D_i \geq 1 \end{cases} \quad (3-13)$$

avec $C_1 = \lambda_N/\beta'$, $C_2 = \beta/\beta'$, et $C_{D_E} = 1 - \exp(-1/D_E)$. Tandis que la probabilité d'une source détectée durant D_i tours depuis la première détection jusqu'au $k^{\text{ème}}$ tour, est écrite sous la forme suivante

$$P_{TL2}(D_i) = C_2 \exp\left(-\frac{D_i}{D_E}\right) \quad (3-14)$$

On considère que P_d est la probabilité de détection, et m_i est le nombre total de détections d'une cible y compris la première détection. On définit $m_i' = m_i - 1$, et n_k est le nombre de pistes formées par les données reçues au $k^{\text{ème}}$ tour. La probabilité de l'historique de détection de la $i^{\text{ème}}$ piste de durée de vie de D_i tours, s'écrit sous la forme

$$P_{DTi} = P_d^{m_i'} (1 - P_d)^{(D_i - m_i')} \quad (3-15)$$

La probabilité de mise à jour de la piste de la $i^{\text{ème}}$ source est déterminée par la combinaison des équations (3-13), (3-14) et (3-15). Pour l'ensemble des sources, l'expression de cette probabilité est

$$P_u = \prod_{i=1}^{n_k} P_{TL}(D_i) P_d^{m_i'} (1 - P_d)^{(D_i - m_i')} \quad (3-16)$$

Avec $P_{TL}(D_i) = \begin{cases} P_{TL1}(D_i); & \text{Source non détectée au tour } k \\ P_{TL2}(D_i); & \text{Source détectée au tour } k \end{cases}$

On considère que X_k est le vecteur d'état de dimension n et Y_{i1} est le vecteur de mesure de dimension d . Le vecteur X_i représente l'état de la $i^{\text{ème}}$ cible lorsque la $i^{\text{ème}}$ mesure est reçue.

Dans ce qui suit, on indique le nombre de pistes par i et le nombre de mesures, générées par la cible correspondant à cette piste, par l .

Le problème d'association consiste à sélectionner parmi les mesures reçues au même tour celle qui permet d'aboutir à une estimation optimale de l'état de la cible \hat{X}_{il} . On associe à cette estimation une erreur v_{il} (innovation) considérée comme un processus aléatoire de distribution Gaussienne avec moyenne nulle et matrice de covariance S_i . On détermine la probabilité qu'une piste i ayant reçu m_i' plots, dans une fenêtre de validation de volume Δ , par l'expression suivante

$$P_{ER_i} = \Delta^{m_i'} \prod_{l=2}^{m_i'} f(v_{il}) \quad (3-17)$$

et la probabilité de toutes les pistes ayant reçu m_i plots chacune, peut être donnée comme suit

$$P_{ER} = \Delta^{\sum_{i=1}^{n_k} m_i - n_k} \prod_{i=1}^{n_k} \prod_{l=2}^{m_i} f(v_{il}) \quad (3-18)$$

Une fois la probabilité d'erreur calculée, on peut déterminer la probabilité totale Q pour une association donnée par la multiplication des probabilités données par les équations (3-11), (3-16), et (3-18).

$$Q = (\beta')^{n_k} \Delta^{\sum_{i=1}^{n_k} m_i} \exp(-k\beta'S) \prod_{i=1}^{n_k} \left[P_{TL}(D_i) P_d^{m_i'} (1-P_d)^{(D_i-m_i')} \prod_{l=2}^{m_i} f(v_{il}) \right] \quad (3-19)$$

On définit une constante C par : $C = \Delta^{\sum_{i=1}^{n_k} m_i} \exp(-k\beta'S)$. L'objectif recherché est de trouver une association de donnée qui maximise Q . En prenant le logarithme des deux membres de l'équation (3-19) on maximise $L' = \ln Q - \ln C$. On définit une nouvelle fonction L qui est nulle dans le cas où m_k observations sont générées par des sources indépendantes et chacune a un seul tour de durée de vie $D_i = 0$, avec $i=0, 1, \dots, m_k$.

$$L = L' - m_k \ln \lambda'_N \quad (3-20)$$

avec $\lambda'_N = \lambda_N + \beta(1 - e^{-1/D_E})$. En remplaçant l'équation (3-19) et l'expression de $f(v_{il})$ donnée par l'équation (3-17) dans (3-20), l'expression de L devient :

$$L_k = n_k \ln \frac{\beta'}{\lambda'_N} + \sum_{i=1}^{n_k} \left\{ \ln [P_{TL}(D_i)] + m'_i \ln P_d + (D_i - m'_i) \ln (1 - P_d) \right. \\ \left. + \sum_{l=2}^{m_i} \left[\ln \frac{p_d}{\lambda'_N (2\pi)^{d/2} \sqrt{S_{il}}} - \frac{\tilde{z}_{il}^T S_{il}^{-1} \tilde{z}_{il}}{2} \right] \right\} \quad (3-21)$$

L'application de cette méthode d'association plots/pistes nécessite énormément de calcul et par conséquent son implémentation est difficile. Pour la rendre utilisable dans la pratique, on est amené à développer une forme séquentielle conduisant à une réduction du temps de calcul et par conséquent une facilité d'implantation.

III.5. METHODE D'ASSOCIATION PROBABILISTIQUE DE DONNEES (PDA)

La méthode d'association probabilistique de données [9] est une approche sous-optimale appliquée à la poursuite quand le taux de fausses alarmes est élevé. Les fausses mesures sont considérées indépendantes dans le temps et dans l'espace. Le nombre de faux plots est supposé indépendant d'un tour à l'autre. Après le test de validation, plusieurs mesures, considérées incorrectes, sont écartées. Cependant, il peut rester un ou plusieurs plots dans la fenêtre de validation, qui vont être associés à la cible en poursuite. Cette méthode est basée sur le principe d'incorporer toutes les mesures validées pour mettre à jour l'état de la piste. Ceci est effectué en se servant de la probabilité à posteriori que chaque plot validé est généré par la cible en poursuite. Elle est calculée en fonction de toutes les informations qu'on peut acquérir sur la cible telle que la position, la signature, ...

On indique par $\chi_{k,i}$, où $i=1, 2, \dots, m_k$, l'événement qu'une mesure $z_{k,i}$ validée soit correcte, et par $\chi_{k,0}$, l'événement qu'aucune mesure ne soit reçue dans la fenêtre de validation de la cible en poursuite. L'estimation de l'état X_k d'une cible effectuée sur la séquence des mesures des k tours est la combinaison de toutes les estimations individuelles correspondant aux mesures validées au k ème tour,

$$\hat{X}_{k/k} = E[X_k / Z^k] = \sum_{j=0}^{m_k} E\{X_k | \chi_{k,j}, Z^k\} P\{\chi_{k,j} | Z^k\} \quad (3-22)$$

où $E\{X_k | \chi_{k,j}, Z^k\}$ est l'estimation correspondant à chaque événement d'association $\chi_{k,i}$, et $P\{\chi_{k,j} | Z^k\}$ est la probabilité à posteriori correspondante. Ainsi on écrit

$$\beta_{k,j} = P\{\chi_{k,j} | Z^k\}, j=0,1, 2, \dots, m_k \quad (3-23)$$

$$\hat{X}_{k/k} = \hat{X}_{k/k-1} + W_k v_k \quad (3-24)$$

avec

$$v_k = \sum_{i=1}^{m_k} \beta_i(k) v_i(k) \quad (3-25)$$

La densité de probabilité des mesures, conditionnée sur les données passées et supposées correctes, est considérée connue et s'écrit sous la forme suivante

$$P(z_{k,i} | \chi_{k,i}, Z^{k-1}) = f(z_{k,i} | Z^{k-1}) \quad (3-26)$$

Tandis que la densité de probabilité des mesures, conditionnées sur les données passées et supposées incorrectes, est uniforme dans la fenêtre de validation de volume V_k , cette densité est définie par l'expression suivante

$$P(z_{k,i} | \chi_{k,j}, Z^{k-1}) = V_k^{-1}, i \neq j \quad (3-27)$$

Les probabilités à posteriori $\beta_{k,i}$ peuvent donc être exprimées en fonction de la densité de probabilité des mesures comme suit

$$\beta_{k,j} = \frac{f(z_{k,j} | Z^{k-1})}{b_k + \sum_{i=1}^{m_k} f(z_{k,i} | Z^{k-1})}, i=1,2, \dots, m_k \quad (3-28)$$

$$\beta_{k,0} = \frac{b_k}{b_k + \sum_{i=1}^{m_k} f(z_{k,i} | Z^{k-1})} \quad (3-29)$$

avec

$$b_k = m_k V_k^{-1} \frac{\alpha_1 + \alpha_2 - \alpha_1 \alpha_2}{(1 - \alpha_1)(1 - \alpha_2)} \quad (3-30)$$

α_1 est la probabilité que la mesure correcte ne soit pas dans la fenêtre de validation, et α_2 est la probabilité que la mesure correcte ne soit pas détectée. La densité de probabilité de l'état de la cible X_k conditionnée sur les données passées est considérée normale avec la moyenne $\hat{X}_{k/k-1}$ et la covariance $P_{k/k-1}$

$$P(X_k | Z^{k-1}) = \mathfrak{N}(\hat{X}_{k/k-1}, P_{k/k-1}) \quad (3-31)$$

Par conséquent, la fonction densité de probabilité donnée par l'équation (3-26) des mesures validées par la cible en poursuite et conditionnée sur les données passées, est considérée normale tronquée.

$$f(z_{k,j} | Z^{k-1}) = (1 - \alpha_1)^{-1} \mathfrak{N}(\hat{X}_{k/k-1}, P_{k/k-1}) \quad (3-32)$$

La méthode d'association probabilistique de données est une méthode basée sur le principe d'associer à chaque plot reçu une probabilité, et les pistes sont mises à jour avec la somme des plots pondérés par ces probabilités. Cette méthode offre une bonne performance de poursuite en présence de clutter dense sans pour autant augmenter les capacités de stockage et de calcul. De plus, sa performance est étendue à la poursuite des cibles manœuvrantes. L'inconvénient du PDAF réside dans sa faible performance envers les cibles manœuvrantes. L'information du début d'une manœuvre est contenue dans la grande valeur de la distance statistique entre la piste et la mesure (innovation), alors que c'est cette grandeur qui permet au filtre de donner un faible poids à la position mesurée et un fort poids à la position prédite, de sorte que la mesure soit ignorée.

III.6. METHODE MODIFIEE D'ASSOCIATION PROBABILISTIQUE DE DONNEES

La méthode d'association plots/pistes, que nous avons développé dans ce paragraphe, prend en considération le problème de poursuite des cibles dans un environnement de clutter [11]. Dans cette situation la cible peut ne pas être détectée, et le clutter peut générer de faux plots, ce qui rend difficile la prise d'une décision d'association correcte. Pour améliorer la

performance de poursuite, les propriétés des échos, qui ont donné les plots, sont utilisées dans la fonction d'association. Ces propriétés sont :

- Le rang des mesures déterminé à partir de la distribution d'enveloppe du clutter seul et du signal plus clutter.
- La vitesse radiale obtenue à partir de la FFT du signal radar.

On indique par z_{kT} les mesures qui sont utilisées pour la mise à jour des pistes. Par analogie, on indique par z_{kD} les propriétés utilisées dans la fonction de décision. Le vecteur de mesure totale est donc

$$z_k = [z_{kT}^T z_{kD}^T]^T \quad (3-33)$$

On définit par $Z_{kT} = \{z_{kT,j}\}_{j=1}^{m_k}$ l'ensemble des mesures validées au $k^{\text{ième}}$ tour ou m_k est le nombre des mesures, et par $Z_{kD} = \{z_{kD,j}\}_{j=1}^{m_k}$ l'ensemble des propriétés de détection. L'historique des mesures obtenues durant k tours est exprimé par $Z^k = \{Z_{jT}\}_{j=1}^k$. On suppose que les fausses mesures sont indépendantes et uniformément distribuées dans l'espace d'observation de volume V_k avec la densité de distribution V_k^{-1} . L'estimation d'état de la cible s'écrit sous la forme conditionnelle suivante

$$\hat{X}_{k/k} = E[X_k | Z^k] = \sum_{i=0}^{m_k} \beta_{k,i} E[X_k | \chi_{k,i}, Z^k] = \sum_{i=0}^{m_k} \beta_{k,i} \hat{X}_{k/k,i} \quad (3-34)$$

où $\chi_{k,i}$ est l'événement que la $i^{\text{ème}}$ mesure $z_{kT,i}$ provienne d'une cible réelle avec $i=1,2,\dots, m_k$, et $\chi_{k,0}$, est l'événement qu'aucune mesure ne provienne de la cible. $\beta_{k,i}$ est la probabilité que l'événement $\chi_{k,i}$ soit correct en se basant sur toutes les mesures reçues durant les k tours,

$$\beta_{k,j} = P[\chi_{k,j} | Z^k]; j = 0,1,2,\dots,m_k \quad (3-35)$$

L'état de la cible X_k est supposé normalement distribué avec la moyenne $\hat{X}_{k/k-1}$ et la covariance $P_{k/k-1}$.

$$P(X_k | Z^{k-1}) = N(X_k; \hat{X}_{k/k-1}, P_{k/k-1}) \quad (3-36)$$

La fonction d'association est effectuée sur les mesures qui ont vérifié le test de validation (Voir Chapitre 2). En utilisant la loi Bayésienne, l'équation (3-35) peut être développée sous la forme suivante

$$\beta_{k,j} = P[\chi_{k,j} | Z_{kD}, Z_{kT}, Z^{k-1}, m_k] = \frac{\gamma_{k,j}}{\sum_{j=0}^{m_k} \gamma_{k,j}} \quad (3-37)$$

avec

$$\gamma_{k,j} = P[Z_{kD} | \chi_{k,j}, Z^{k-1}, m_k] P[Z_{kT} | \chi_{k,j}, Z^{k-1}, m_k] P[m_k | \chi_{k,j}, Z^{k-1}] P[\chi_{k,j} | Z^{k-1}] \quad (3-38)$$

Les quatre termes de l'équation (3-38) sont calculés indépendamment l'un de l'autre. Ils dépendent étroitement des propriétés des mesures Z_{kD} . Pour raison de simplicité, on ne prend en considération que la propriété du rang (le nombre de coups qui ont donné la mesure). La généralisation à d'autres propriétés peut facilement être faite. Pour $i = 0$, les mesures validées sont considérées incorrectes, et on a

$$P[Z_{kD} | \chi_{k,j}, Z^{k-1}, m_k] = \prod_{j=E_1}^{m_k} P_{R/C}(z_{kD,j} = R_j) \quad (3-39)$$

$$P[Z_{kT} | \chi_{k,j}, Z^{k-1}, m_k] = V^{-m_k} \quad (3-40)$$

$$P[\chi_{k,i} | Z^{k-1}] = \alpha + (1 - \alpha)(1 - P_d) \quad (3-41)$$

Pour $i=1,2,\dots, m_k$, les mesures sont normalement distribuées, on a dans ce cas

$$P[Z_{kD} | \chi_{k,j}, Z^{k-1}, m_k] = \frac{P_{R/T}(z_{kD,j} = R_i)^{m_k}}{P_{R/C}(z_{kD,j} = R_i)} \prod_{j=1}^{m_k} P_{R/C}(z_{kD,j} = R_j) \quad (3-42)$$

$$P[Z_{kT} | \chi_{k,j}, Z^{k-1}, m_k] = (1 - \alpha)^{-1} N(z_{kT,j}; \hat{z}_{k/k-1}, S_{k/k-1}) = f_k(z_{kT,j}) V^{-(m_k-1)} \quad (3-43)$$

$$P[\chi_{k,i} | Z^{k-1}] = (1 - \alpha)P_d / m_k \quad (3-44)$$

On note que les termes $\prod_{j=1}^{m_k} P_{R/C}(z_{kD,j} = R_j)$ et V^{m_k} sont identiques. Par substitution des équations (3-39) à (3-44) dans l'équation (3-38), on obtient

$$\gamma_{k,0} = \frac{\alpha + (1 - \alpha)(1 - P_d)}{(1 - \alpha)P_d} m_k \quad (3-45)$$

$$\gamma_{k,i} = V \frac{P_{R/T}(z_{kD,i} = R_i)}{P_{R/C}(z_{kD,i} = R_i)} f_k(z_{kT,i}); i=1,2,\dots,m_k \quad (3-46)$$

Les probabilités $\beta_{k,i}$ avec $i=0,1,\dots,m_k$, sont calculées en remplaçant les équations (3-45) et (3-46) dans l'équation (3-37).

III.7. METHODE ADAPTATIVE D'ASSOCIATION PROBABILISTIQUE DE DONNEES

Dans ce paragraphe, nous décrivons une méthode d'association probabilistique de données dans laquelle la période de répétition des impulsions d'émission (*Pulse Repetition Frequency*, PRF) est variable, et peut être sélectionnée par l'opérateur radar[17]. Cette adaptation est basée sur la matrice de covariance de l'estimation de l'état de la cible. Cette matrice de covariance reflète l'effet de l'incertitude de l'origine des mesures sur l'estimation de l'état de la cible. L'incertitude des origines des mesures radar se manifeste par des augmentations des erreurs d'estimation. Pour remédier à cette situation, nous augmentons la matrice de covariance de l'état estimé, et par conséquent la matrice de covariance de l'état prédit augmente aussi. Cette situation surgit surtout en présence de clutter dense et de taux élevé de fausses alarmes. L'adaptation du temps de mise à jour est effectuée comme suit. A la fin de traitement du $k^{\text{ème}}$ tour le temps prochain d'acquisition des mesures au $(k+1)^{\text{ème}}$ tour est sélectionné selon la condition suivante

$$T(k + 1) \rightarrow P_{k/k-1}(i,i) = d_i^2 \sigma_{x,y}^2; i=1,2 \quad (3-47)$$

$P_{k/k-1}(i,i)$ est le $i^{\text{ème}}$ élément de la matrice de covariance de l'état prédit, qui correspond à la composante X ($i=1$) ou Y ($i=2$) de la position. $\sigma_{x,y}$ est la variance des erreurs de mesure radar

correspondant à X ou à Y. La covariance de prédiction peut donc être réglée par l'opérateur en choisissant une valeur convenable du paramètre d_j .

III.8. METHODE D'ASSOCIATION PROBABILISTIQUE CONJOINTE DE DONNEES

La méthode d'association probabilistique conjointe [15] est caractérisée par la prise en considération de toutes les pistes et mesures dans chaque événement d'association plots/pistes. Elle est supposée fonctionner dans des situations de poursuite multicibles et en présence de multiples plots dans la même fenêtre de validation. Ceci est effectué en associant une probabilité conjointe à chaque événement d'association plot/piste possible. Cet événement est la combinaison de tous les événements individuels des associations possibles.

On indique par $\chi_{k,i}$, où $i=1, 2, \dots, m_k$, l'événement qu'une mesure $z_{k,i}$ validée est correcte, et par $\chi_{k,0}$ l'événement qu'aucune mesure n'est reçue dans la fenêtre de validation de la cible en poursuite. L'estimation de l'état X_k d'une cible effectuée sur la séquence des mesures des k scans est donnée comme suit

$$\hat{X}_{k/k} = \hat{X}_{k/k-1} + W_k v_k \quad (3-48)$$

Avec

$$v_k = \sum_{i=1}^{m_k} \beta_i(k) v_i(k) \quad (3-49)$$

où v_i est l'innovation du plot i , et $\beta_i(k)$ est la probabilité d'association de ce plot à la piste considérée. Dans le cas de la méthode JPDA, $\beta_i(k)$ est la probabilité conjointe d'association calculée en fonction des probabilités de tous les événements conjoints $\chi_{k,i}$ possibles. La détermination d'un événement conjoint est basée sur le principe que deux pistes ne peuvent pas être associées avec le même plot d'une part, et d'autre part, deux plots ne peuvent pas être générés par la même cible. Nous décrivons la probabilité de tous les événements $\chi(k)$ de l'histoire des mesures Z^k des k tours d'antenne comme suit

$$\begin{aligned} P[\chi(k) | Z^k] &= P[\chi(k) | Z_k, Z^{k-1}] \\ &= \frac{1}{C} P[\chi(k) | Z^{k-1}] P[Z_k | \chi(k), Z^{k-1}] \end{aligned} \quad (3-50)$$

où C est une constante de normalisation. Le premier terme $P[\chi(k)|Z^{k-1}]$ du membre droit de l'équation (3-50), indique la probabilité des événements indépendants de l'histoire Z^{k-1} , qu'on peut écrire sous la forme simplifiée $P[\chi(k)]$. Le deuxième terme indique la probabilité de tous les événements des associations possibles du $k^{\text{ième}}$ tour, et peut être écrit sous la forme

$$P[Z_k | \chi(k), Z^{k-1}] = \prod_{i=1}^{m_k} P[z_{k,i} | \chi_{k,i}, Z^{k-1}] \quad (3-51)$$

Notons que les plots réels associés avec les pistes sont considérés normalement distribués, tandis que les faux plots sont considérés indépendant et uniformément distribués dans l'espace de validation. Le nombre de faux plots reçus tour d'antenne est supposé une variable aléatoire indépendant et de distribution de Poisson. Tandis que la probabilité de distribution $P_i^t(k)$ d'une mesure $z_{k,i}$ validée par une piste t est considérée normale si elle est vraie et uniforme si c'est une fausse alarme.

$$P_i^t(k) = P[z_{k,i} | \chi_{k,i}, Z^{k-1}] = \begin{cases} N[v_i(k)] P_d & i = 1, m_k \\ \lambda(1 - P_d) & i = 0 \end{cases} \quad (3-52)$$

où λ est la densité des plots de clutter dans la fenêtre de validation, et P_d est la probabilité de détection. Finalement, la probabilité conjointe d'association d'un plot i à la piste t est la somme des probabilités de tous les événements conjoints dans lesquels la piste t est associée avec le plot i . Ainsi on écrit

$$\beta_i^t = \frac{1}{b} \frac{P_i^t}{\sum_{l=1}^T P_l^t + \sum_{j=0}^{m_k} P_j^t - P_i^t + P^0} \quad (3-53)$$

avec $t=1,2,\dots,T$, et $i=0,1,2, \dots, m_k$. b est un facteur de normalisation qui permet d'assurer la condition $\sum_{j=0}^m \beta_j^t(k) = 1$, et P^0 est une constante arbitraire choisie pour l'amélioration de performance de la méthode.

III.9. METHODE D'ASSOCIATION BASEE SUR LES MODELES DE MARKOV CACHES (HMM)

L'application des modèles Markoviens cachés (*Hidden Markov Modele*, HMM) au problème d'association plots/pistes permet de prendre en considération les données ambiguës et d'intégrer les fonctions d'initiation et d'abandon dans un même algorithme de poursuite [14].

III.9.1. Présentation des modèles de Markov cachés

Un modèle de Markov caché est un processus doublement stochastique, dans lequel un phénomène stochastique, qui n'est pas directement observable, peut être observé à travers un autre processus qui est lui aussi stochastique. Il est défini par le quintuple suivant: $\{Q, V, A, B, \pi\}$ où

- $Q=\{q_1, q_2, \dots, q_N\}$ est un ensemble fini de N états,
- $V=\{V_1, V_2, \dots, V_m\}$ est l'ensemble des paramètres de sortie,
- A est la matrice des probabilités de transition des états

$$A = \{a_{ij}\} \quad a_{ij} = \Pr(q_j \text{ à } t + 1 \mid q_i \text{ à } t) \quad (3-54)$$

- B est le vecteur des probabilités des paramètres mesurés, conditionnées par les états q_i ,

$$B = \{b_j(k)\}; b_j(k) = \Pr(V_k \text{ à } t \mid q_j \text{ à } t) \quad (3-55)$$

- Π est le vecteur des probabilités des états initiaux,

$$\Pi = \{\pi_i\}; \pi_i = \Pr(q = q_i \text{ à } t = 1) \quad (3-56)$$

Le processus d'état est caché pour l'observateur et seulement connu à travers les mesures $\Theta_T = \{\Theta(t_1), \Theta(t_2), \dots, \Theta(T)\}$, d'où le mot 'caché'. Il existe trois problèmes clés associés avec la théorie des modèles Markoviens cachés qui sont :

- **Problème d'évaluation** : où on cherche à évaluer la probabilité de la séquence des mesures Θ_T donnant le HMM $\lambda=\{A, B, \pi\}$ avec $\Theta(t) \in V$.

- **Problème d'estimation** : où on cherche à déterminer la séquence d'états cachés $I_T = \{i(t_1), i(t_2), \dots, i(T)\}$ donnant la séquence des mesures Θ_T et le modèle λ . Ce problème est résolu par l'algorithme de Viterbi (Voir §3.9.3).
- **Problème d'apprentissage** : où on cherche à sélectionner le meilleur modèle λ connaissant certaines données liées à la transition entre les différents états.

Pour appliquer les modèles de Markov cachés au problème de poursuite, une distance dans laquelle la cible est permise de se déplacer est définie et divisée en un nombre fini de cellules. Chaque cellule est associée à un état du modèle de Markov. L'état zéro est défini par le cas où la cible se déplace en dehors de la distance permise, où elle est perdue. Le principal concept de l'application des HMMs est la dérivation des éléments de A et B, ceci correspond à la transition de l'état initial et le retour vers cet état (initiation et abandon de piste). Les éléments de A sont choisis de sorte que les pistes lissées sont plus vraisemblables que les pistes rudes.

III.9.2. Application à la Poursuite

Pour mieux présenter la poursuite par la méthode des modèles de Markov cachés (HMM), on considère l'exemple suivant. On suppose que la distance maximale de parcours est divisée en n cellules correspondant à n états en plus de l'état zéro, $Q=\{q_i, i=0,1,2,\dots,n\}$. A l'instant t, deux cibles se trouvent aux états $w_1(t)$ et $w_2(t)$ donnés par le vecteur suivant

$$I(t) = (w_1(t), w_2(t))^T; w_1(t), w_2(t) \in \{q_i, i = 0,1,2,\dots,n\} \quad (3-57)$$

La séquence des mesures est donnée comme suit

$$\Theta_T = \{\Theta(1), \Theta(2), \dots, \Theta(T)\} \quad (3-58)$$

avec $\Theta(t) = \{\Theta_1(t), \Theta_2(t), \dots, \Theta_m(t)\}$. Notre objectif est d'estimer la piste combinée de Viterbi $I(t)$. Pour cela, on a besoin de développer les probabilités de transition des états et des mesures A et B et d'étendre l'algorithme de Viterbi à ce cas. Ensuite, on considère le cas de deux pistes. Finalement, l'extension à un nombre arbitraire de pistes et de mesures est facilement obtenue.

La probabilité de transition des mesures peut être donnée comme suit

$$B_{\binom{i}{j}}(\Theta(t)) = \Pr \left[\Theta(t) \mid \begin{pmatrix} w_1(t) = q_i \\ w_2(t) = q_j \end{pmatrix} \right] \quad (3-59)$$

où q_i et q_j sont les états corrects des pistes à l'instant t et $\Theta(t)$ est le vecteur des mesures des deux pistes à l'instant t . Le double indice $\binom{i}{j}$ fait référence aux deux mesures reçues des deux cibles. Notons que nous ne savons pas encore laquelle des deux mesures est générée par la première ou la deuxième cible. La probabilité de transition des états s'écrit sous la forme suivante

$$A_{\binom{ik}{jl}} = \Pr \left[\begin{pmatrix} w_1(t+1) = q_k \\ w_2(t+1) = q_l \end{pmatrix} \mid \begin{pmatrix} w_1(t) = q_i \\ w_2(t) = q_j \end{pmatrix} \right] \quad (3-60)$$

Le vecteur d'état de la piste composée est vu comme une matrice désordonnée. On suppose que les deux cibles ont des probabilités de transition identiques et indépendantes qui peuvent être exprimées par $a_{\binom{ik}{jl}} = a_{ik}a_{jl} + a_{il}a_{jk}$ et les éléments a_{ik} , a_{il} , a_{jk} et a_{jl} sont définis par l'équation (3-54).

III.9.3. Algorithme de Viterbi

L'algorithme de Viterbi est formulé comme suit. On suppose qu'à l'instant $t=1$, on se dispose d'une séquence de mesure Θ_T (Equation (3-58)). On définit deux paramètres δ et ψ à l'instant $t=1$ comme suit

$$\delta_1 \binom{i}{j} = \ln \pi \binom{i}{j} + \ln B_{\binom{i}{j}}(\Theta(1)); \quad 0 \leq i \leq n, \quad 0 \leq j \leq n \quad (3-61)$$

$$\psi_1 \binom{i}{j} = 0 \quad (3-62)$$

Pour $t=2, 3, \dots, T$, on a

$$\delta_t \binom{i}{j} = \ln B \binom{i}{j} (\Theta(t)) + \max_{K,L \in [0,n]} \left[\delta_{t-1} \binom{K}{L} + \ln a \binom{K}{L} \binom{i}{j} \right]; 0 \leq i \leq n, 0 \leq j \leq n \quad (3-63)$$

$$\psi_t \binom{i}{j} = \arg \max_{K,L \in [0,n]} \left[\delta_{t-1} \binom{K}{L} + \ln a \binom{K}{L} \binom{i}{j} \right] \quad (3-64)$$

La piste de Viterbi est définie par l'expression suivante

$$I_T^* (\Theta_T) = [I_V(1), I_V(2), \dots, I_V(T)] \quad (3-65)$$

où chaque élément $I_V(t)$ est exprimé par

$$I_V(T) = \arg \max_{i,j \in [0,n]} \delta_T \binom{i}{j} \quad (3-66)$$

$$I_V(t) = \psi_{t+1}(I_V(t+1)); t = T-1, T-2, \dots, 1 \quad (3-67)$$

Après la détermination de la piste composée de Viterbi, nous pouvons séparer les deux pistes en se servant de la probabilité de transition a_{ij} de chaque piste individuelle.

III.10. CONCLUSION

La situation aérienne se caractérise en général par un taux élevé de fausses alarmes causées par le clutter, et des cibles multiples qui peuvent générer de fortes manœuvres. Le nombre de plots excessifs reçus sur un tour d'antenne constitue souvent une ambiguïté d'association plots/pistes. Cette situation a poussé certains concepteurs de radars à concentrer leurs efforts autour du développement et du perfectionnement des algorithmes de traitement automatique de données radar, faute de répondre aux exigences de la surveillance aérienne moderne, civile et militaire, en terme simplicité de l'exploitation des situations aériennes. Ces algorithmes se déroulent généralement sous de fortes contraintes de temps réel et de précision. L'association de données radar a consommé la grande partie de ces efforts.

Dans ce chapitre, nous avons présenté les principes théoriques de quelques méthodes, nouvelles et anciennes, qui ont été déjà développées pour résoudre le problème d'association de données radar. Elles se classent en deux catégories, les méthodes bayésiennes et les méthodes non bayésiennes. Les méthodes bayésiennes sont basées sur le principe d'associer à chaque mesure reçue une probabilité d'association. Le filtre d'association probabilistique de données est un exemple. Les méthodes non bayésiennes sont basées sur le principe d'associer à chaque piste une probabilité de vraisemblance. Les méthodes basées sur le maximum de vraisemblance et les modèles de Markov cachés sont deux exemples. Toutes ces méthodes diffèrent entre elles par la complexité des calculs qu'elles engendrent, le coût d'implémentation nécessaire et la qualité de la poursuite obtenue. Pour répondre aux exigences technologiques et opérationnelles, des chercheurs, tel que D. Sengupta et R. A. Ittis [18] ont appliqué d'autres nouvelles techniques à savoir les réseaux de neurones.

CHAPITRE IV

GENERALITES SUR LES RESEAUX DE NEURONES

CONTENU :

IV.1. HISTORIQUE.....	54
IV.2. INTRODUCTION.....	55
IV.3. MODELE BIOLOGIQUE.....	55
IV.4. MODELE DE NEURONES ARTIFICIELLES.....	56
IV.4.1. Fonction de base.....	57
IV.4.2. Fonction d'activation.....	57
IV.5. STRUCTURE DES RESEAUX DE NEURONES	58
IV.5.1. topologie des connexions.....	58
IV.5.2. Décomposition des réseaux de neurones.....	59
IV.6. RESEAUX A MEMOIRE ASSOCIATIVE	59
IV.6.1. Etape d'apprentissage	59
IV.6.2. Etape de rappel.....	60
IV.6.3. Réseau direct.....	60
IV.6.4. Réseaux récurrents	62
IV.7. RESEAU DE HOPFIELD.....	63
IV.8. RESOLUTION DU PROBLEME DU VOYAGEUR DE COMMERCE PAR UN RESEAU DE HOPFIELD	64
IV.8.1. Méthode de rétro-propagation du gradient d'erreur.....	66
IV.9. POURSUITE RADAR PAR LES RESEAUX DE NEURONES.....	71
IV.9.1. Par Mesure de Divergence	71
IV.9.2. Par Optimisation.....	72
IV.9.3. Par Reconnaissance de Trajectoires.....	72
IV.10. EXEMPLE D'ASSOCIATION PLOTS/PISTES PAR MESURE DE DIVERGENCE	72
IV.11. EXEMPLE D'ASSOCIATION PLOTS/PISTES PAR OPTIMISATION.....	74
IV.12. ASSOCIATION PLOTS/PISTES PAR UN RESEAU DE HOPFIELD MODIFIE	76
IV.13. CONCLUSION.....	77

IV.1. HISTORIQUE

Nous débutons l'histoire des réseaux de neurones à partir de 1943 [27][28][29] quand McCulloch et Pitts inventèrent le premier neurone formel, un produit scalaire entre un vecteur d'entrée et un vecteur de poids suivi d'un élément de seuillage répondant par 0 ou 1 selon que le résultat du produit scalaire soit supérieur ou inférieur au seuil. L'époque des années 1950 s'est caractérisée par la proposition par D. O. Hebb du principe de la plasticité synaptique comme modèle de la mémoire. F. Rosenblatt proposa le perceptron, un neurone formel doué de la faculté d'apprentissage. C'est un séparateur linéaire permettant d'apprendre à fournir la bonne décision et qui est utilisé dans les opérations de classification.

Dans les années 1960, Minsky et Papert vinrent démontrer qu'avec un perceptron à une seule couche on ne peut séparer que des données linéairement séparables, et qu'il fallait utiliser plusieurs couches de neurones pour effectuer des opérations de classification plus générales. Après l'an 1970, certains chercheurs, comme Anderson et Kohonen, ont continué de travailler sur des idées qui sont déjà apparues dans la littérature en les mieux reformulant, tout en combinant les méthodes de l'algèbre linéaire et les techniques non linéaires. L'année 1982 s'est distinguée par le renouveau mondial des théories des neurones artificiels développées par J. Hopfield. Il proposa pour la première fois un modèle dynamique des réseaux de neurones basé sur la minimisation d'une fonction Energie.

Pourquoi des neurones artificiels ?

Malgré la constante augmentation de puissance des calculateurs et les approches théoriques de plus en plus sophistiquées, un certain nombre de tâches résistent encore aux algorithmes et aux méthodes classiques de traitement des signaux et des données [27]. La plupart de ces tâches relèvent du traitement en temps réel de très grands flots de données souvent multidimensionnelles et arrivant à des cadences élevées. Ces données, qui sont souvent variables et ne répondent pas à des modèles physiques connus, nous laissent démunis devant des opérations de caractérisation, de reconnaissance et de prise de décision. Pourtant ces opérations sont réalisées de manière naturelle chez les êtres vivants. C'est là que réside l'intérêt des neurones artificiels. Il s'agit donc de s'inspirer des architectures et des fonctions du système nerveux pour imaginer de nouveaux algorithmes et concevoir de nouvelles machines plus efficaces, capables d'effectuer et d'exécuter les tâches qui sont considérées jusqu'alors irréalisables.

IV.2. INTRODUCTION

Les réseaux de neurones constituent une catégorie de filtres non linéaires adaptatifs et qui sont caractérisés par une structure parallèle[27-29]. L'architecture de chaque filtre est constituée de plusieurs cellules élémentaires (neurones) interconnectées entre elles pour former un réseau. Le choix des réseaux de neurones dans divers domaines est motivé par la simplicité de la mise en œuvre des cellules, le parallélisme du traitement et leur forte capacité d'adaptation. Les différentes architectures mises en œuvre se distinguent entre elles par la nature du traitement cellulaire, la topologie des connexions des neurones, et le principe d'adaptation (algorithme d'apprentissage).

Les réseaux de neurones ont trouvé diverses applications, parmi lesquelles on trouve le traitement d'image, le traitement de la parole, la reconnaissance de formes dont la reconnaissance des caractères est un exemple, l'automatique et traitement du signal, l'identification et la commande de systèmes, la Robotique, et la biomédecine. Dans le domaine de la défense militaire, les réseaux de neurones sont appliqués aux différents traitements du signal radar tel que le filtrage du clutter, l'identification et la classification des cibles, le filtrage des plots, la poursuite, ...

L'objet du présent chapitre est d'effectuer une synthèse des architectures neuronales existantes et de présenter une étude de celles dédiées à la poursuite radar multicibles. Dans ce qui suit, on décrira les principales architectures des réseaux de neurones et leurs domaines d'application. On présentera ensuite une étude des architectures neuronales appliquées au domaine de la poursuite radar. On terminera par une conclusion sur les perspectives actuelles de recherche dans le domaine de la poursuite par les réseaux de neurones.

IV.3. MODELE BIOLOGIQUE

L'élément fonctionnel de base du système nerveux est le neurone [27], qui présente des différences remarquables d'une espèce à une autre et à l'intérieur d'une même espèce. Les différences portent tant sur l'aspect anatomique que sur l'aspect fonctionnel. Le neurone est une cellule constituée de trois parties qui sont : les dendrites, le soma et l'axone. Les dendrites reçoivent les informations, en provenance d'autres cellules ou de l'extérieur, au niveau des points de contacts appelés synapses. Les informations sont ensuite acheminées vers le soma. Ce dernier reçoit l'ensemble de ces informations et les concentre en effectuant une sommation

dite « Spatio-temporelle » : Spatio parce que l'arbre dendritique accueille les informations venant d'une grande étendue spatiale autour du neurone, et Temporelle parce que la transmission des signaux le long des dendrites est caractérisée par des retards, des atténuations et d'un effet de filtrage passe bas. Après une opération de seuillage, l'information collectée est transmise le long de l'axone vers d'autres neurones. Les neurones sont connectés entre eux par de fortes liaisons. La forme non aléatoire des connexions correspond à des réseaux dont les architectures sont bien connues. La diversité des connexions et des propriétés fonctionnelles des neurones nous permet de constater que les réseaux sont organisés en couches.

IV.4. MODELE DE NEURONES ARTIFICIELLES

Le neurone est un processeur élémentaire à n entrées et une sortie. A chaque entrée est associé un paramètre appelé le poids synaptique. Le traitement cellulaire par un neurone est modélisé par deux opérateurs, un opérateur de sommation qui élabore une somme des entrées d'une même cellule pondérée par les poids synaptiques (fonction de base), et un opérateur qui calcule l'état de sortie (fonction d'activation). Cette fonction peut être dérivable ou non dérivable. Chaque neurone j fournit à sa sortie une valeur V_j qui se propage vers d'autres neurones à travers le réseau de connexions unidirectionnelles (synapses). Arrivée à un nouveau neurone i , cette valeur est pondérée par un poids synaptique w_{ij} qui traduit l'effet de la cellule i sur la cellule j . Les entrées x_i de chaque cellule i sont accumulées avec un seuil externe θ_i pour fournir la valeur du potentiel u_i . Une fonction de base est donc associée à la sortie u_i qui, de sa part, est transformée par une fonction d'activation f pour fournir une nouvelle valeur d'activation V_i qui est la sortie du neurone (voir Figure 4-1). La sortie du réseau de neurones est exprimée en fonction des entrées et des poids par $V=f(x,w)$.




Figure (4-1) Forme générale d'un modèle de neurone artificiel

IV.4.1. Fonction de base

La fonction de base, notée $u(\cdot)$, est une combinaison linéaire ou non linéaire des entrées d'un neurone et des poids synaptiques. Elle peut prendre plusieurs formes, parmi lesquelles nous citons les deux formes suivantes.

Forme linéaire : la valeur du potentiel u est une combinaison linéaire des entrées.

$$u(w, x) = \sum_{j=1}^N w_{ij} x_j \quad (4-1)$$

Forme radiale : la fonction de base est une fonction non linéaire qui donne la distance par rapport à un échantillon de référence.

$$u(w, x) = \sqrt{\sum_{j=1}^N (x_j - w_{ij})^2} \quad (4-2)$$

Cette forme peut être étendue à une forme elliptique.

IV.4.2. Fonction d'activation

La fonction d'activation, notée $F(\cdot)$, caractérise la sortie d'un neurone en fonction des entrées. Elle prend plusieurs formes selon son utilisation, parmi lesquelles on cite,

- **La fonction identité,**

$$f(u_i) = u_i \quad (4-3)$$

- **Fonction Sigmoidale,**

$$f(u_i) = \frac{1}{1 + \exp(-u_i/\sigma)} \quad (4-4)$$

- **Fonction Gaussienne,**

$$f(u_i) = C \exp(-u_i^2/\sigma^2) \quad (4-5)$$

IV.5. STRUCTURE DES RESEAUX DE NEURONES

Un réseau est constitué de plusieurs couches de neurones liées entre elles par un réseau de connexions [27]. Ces couches sont la couche d'entrée, une ou plusieurs couches cachées et la couche de sortie. La dimension d'un réseau de neurones est définie par le nombre de couches cachées et le nombre de neurones par couches. Le nombre de couches est directement lié au réseau de connexion, tandis que le nombre de neurones est lié à la capacité de traitement du réseau. Les réseaux peuvent être récurrents ou directs avec des connexions totales ou partielles, combinées ou non combinées. Des réseaux complexes sont également développés. Ils sont constitués de cellules différentes et leurs lois d'apprentissages sont algorithmiques. Un exemple des réseaux complexes est le réseau ART.

L'utilisation des réseaux de neurones est souvent accompagnée de quelques difficultés. Dans le cas du dimensionnement des réseaux, Il est difficile de choisir un nombre de couches cachées et un nombre de cellule par couche adéquat. Un autre problème rencontré lors de la conception d'un réseau est le choix de la base de données d'apprentissage. La convergence du réseau vers un état stable peut être lente à cause des connexions inutiles entre les différents neurones.

IV.5.1. topologie des connexions

Les connexions peuvent être totales, en bandes, ou en couches On distingue quatre types de connexions,

1. Connexion directe : les sorties d'une couche inférieure sont propagées en avant vers une couche supérieure.
2. Connexion rétrogradée : dans laquelle les sorties d'une couche supérieure sont propagées vers une couche inférieure.
3. Connexion latérale : les sorties se propagent à l'intérieur de la même couche.
4. Connexion retardée : des éléments de retardement sont incorporés dans le réseau de connexion.

IV.5.2. Décomposition des réseaux de neurones

Dans un réseau de neurones, la sortie est représentée par un nœud, et à chaque nœud une classe est associée. Si le nombre de sorties augmente, le réseau devient complexe et sa dimension se trouve augmentée (on aura donc un réseau géant). La gestion des connexions devient en conséquence difficile et le calcul devient volumineux. On est donc obligé de décomposer ce réseau géant en plusieurs sous réseaux, chacun contient un certain nombre de classes. La plus forte décomposition est d'associer une seule classe à chaque sous réseau. Cette décomposition permettra d'éliminer les connexions qui lient les différentes classes, et par conséquent augmenter la vitesse de convergence vers la solution finale.

IV.6. RESEAUX A MEMOIRE ASSOCIATIVE

La mémoire associative est un dispositif capable de mémoriser des informations que l'on peut retrouver ensuite en lui fournissant des données, relatives aux informations stockées, même incomplètes ou bruitées [27-29]. Les réseaux à mémoire associative sont conçus pour rétablir fidèlement les échantillons entachés de bruit de distribution libre à partir d'un signal distordu ou incomplet. Les réseaux à mémoire associative fonctionnent en deux étapes, une étape dite d'apprentissage pendant laquelle les poids synaptiques préstockés sont modifiables selon une règle d'adaptation, suivie d'une étape de rappel pendant laquelle les connexions sont fixes.

IV.6.1. Etape d'apprentissage

La capacité d'apprentissage est une caractéristique essentielle des réseaux de neurones. Cette étape est effectuée sur une base de données afin de déterminer les paramètres de pondération qui définissent le modèle de neurones en question. Le modèle ainsi déterminé sera utilisé dans l'étape de rappel pour effectuer le traitement de données réelles. Les paramètres de pondération optimaux sont obtenus à partir de la minimisation d'une fonction Energie (Fonction de Liapounov). Selon la méthode d'apprentissage utilisée, on distingue les modèles supervisés, non supervisés et à poids fixes. Ce dernier modèle n'a pas besoin d'apprentissage, on parle seulement d'apprentissage supervisé et non supervisé.

L'apprentissage supervisé, dont les réseaux multicouches sont un exemple, est effectué sur une base de données constituée d'échantillons de couples d'entrée/sortie. Les entrées se

propagent à travers les cellules pour donner les sorties. Les poids synaptiques du réseau sont ajustés à chaque application d'un échantillon en minimisant l'écart entre les sorties obtenues et les sorties désirées. Une des méthodes de minimisation est basée sur le principe du gradient (Algorithme de Rétro-Propagation du Gradient d'Erreur, RPGE) présenté ci-dessous.

L'apprentissage non supervisé nécessite la connaissance des prototypes de la base de données utilisée. Le réseau apprend à s'adapter en se basant sur les échantillons précédents. Un exemple d'apprentissage non supervisé est la loi de Hebb et la loi de Kohonen [27]. Pour la loi de Hebb, les poids sont reliés à la corrélation des états des neurones connectés ; c.-à-d. lorsque les cellules i et j sont excitées simultanément, la force de connexion entre elles croit proportionnellement avec le produit de leurs activations. Tandis que le réseau de Kohonen implique l'apprentissage compétitif, c.-à-d. seules les cellules les plus sensibles aux entrées sont adaptées.

IV.6.2. Etape de rappel

Le modèle déterminé dans l'étape d'apprentissage est utilisé dans l'étape de rappel pour effectuer le traitement de données réelles afin de retrouver les sorties des neurones désirées. Les résultats peuvent être retrouvés d'un seul coup ou d'une façon itérative en se servant des équations dynamiques. Pour se faire, deux types de réseaux sont proposés pour retrouver les résultats désirés, les réseaux directs et les réseaux récurrents.

IV.6.3. Réseau direct

Ce sont des réseaux multicouches à connexion directe et effectuent le traitement désiré en une seule itération [29]. Nous distinguons les réseaux linéaires et les réseaux non linéaires. La fonction des réseaux linéaires est une application linéaire de l'espace d'entrée vers l'espace de sortie. Il est obtenu à partir d'une série d'échantillons d'entrées/sorties $\{b^{(m)}, a^{(m)}\}$, avec $m=1,2,\dots,M$. $b^{(m)} = [b_1^{(m)}, b_2^{(m)}, \dots, b_k^{(m)}]$ est le vecteur des entrées, et $a^{(m)} = [a_1^{(m)}, a_2^{(m)}, \dots, a_N^{(m)}]$ est le vecteur des sorties. Dans un réseau à mémoire associative, on cherche à retrouver un échantillon de sortie en se basant sur un échantillon d'entrée. La matrice des poids synaptiques W est calculée par la combinaison linéaire de $a^{(m)}$ et $b^{(m)}$ comme suit,

$$W = \sum_m a^{(m)} b^{(m)T} \quad (4-6)$$

Chaque élément de la matrice W des poids synaptiques est déterminé par la relation suivante,

$$w_{ij} = \sum_m a_i^{(m)} b_j^{(m)} \quad (4-7)$$

Les réseaux non linéaires sont utilisés surtout dans des opérations d'élimination des perturbations non désirables. On donne un échantillon de test t et on définit un vecteur score S en terme de produit interne entre le vecteur d'entrée $b^{(m)}$ et l'échantillon de test t.

$$S = \left[\langle b^{(1)}, t \rangle, \langle b^{(2)}, t \rangle, \dots, \langle b^{(m)}, t \rangle \right] \quad (4-8)$$

Avec

$$\langle b^{(m)}, t \rangle = b^{(m)T} t = \sum_{i=1}^k b_i^{(m)} t_i \quad (4-9)$$

L'opération de la fonction Score S est suivie d'une opération non linéaire dont le résultat est un vecteur de décision V, avec $V = N\{S\}$. Le vecteur V est supposé avoir un seul élément non nul et le résultat à retrouver est le produit AV, ou A est la matrice formée par les vecteurs colonnes $a^{(k)}$. Il s'agit donc de sélectionner un seul nœud et de supprimer tous les autres. L'opération non linéaire $N\{.\}$ peut être un dispositif de seuillage ou de MAXNET.

Pour établir un dispositif de seuillage, il faut, en premier lieu, estimer un seuil θ , $0 < \theta < 1$. Si le seuil θ est choisi petit, des nœuds non convenables peuvent être sélectionnés par erreur. Tandis que, si le seuil est choisi grand, on risque de rater même des nœuds qui conviennent. On suppose que l'échantillon de test t est défini par

$$t = \tilde{b}^{(k)} = b^{(k)} + \delta \quad (4-10)$$

Avec δ un bruit. On cherche à retrouver un seuil défini comme suit,

$$1 + \text{perturbation}(k) > \theta > \text{perturbation}(m); \text{ avec } m \neq k$$

En général, le seuil θ est pris égale à 0.5.

Le dispositif MAXNET est utilisé pour déterminer le nœud qui a la plus grande valeur, il est sélectionné si la condition suivante est vérifiée,

$$1 + \text{perturbation}(k) > \text{perturbation}(m); \text{ avec } m \neq k$$

IV.6.4. Réseaux récurrents

Contrairement aux réseaux directs, les réseaux récurrents sont constitués de neurones dont les sorties sont rebouclées sur les entrées, et nécessitent plusieurs itérations pour retrouver la solution finale [27][29]. Un exemple des réseaux récurrents est le réseau de Hopfield. La convergence vers un état stable fait encore défaut dans de nombreuses architectures. La mécanique statistique et la théorie des systèmes dynamiques constituent les principaux outils d'analyse de la convergence des réseaux de neurones. La convergence des mémoires associatives bidirectionnelles et le réseau de Hopfield vers des états stables est analysée par le concept de la fonction de Liapounov (ou fonction d'énergie). Les principales caractéristiques des réseaux récurrents sont :

- 1)**-Les poids synaptiques sont prédéterminés par la loi de Hebb ou par la minimisation de la fonction énergie.
- 2)**-L'opération de seuillage non linéaire est utilisée dans chaque itération pour aboutir aux états binaires.
- 3)**-Les réactions des états des neurones sont utilisées pour leur mise à jour de leurs sorties.
- 4)**-Les itérations doivent converger vers une solution finale qui minimise la fonction Energie.

On distingue les réseaux de Hopfield séquentiels (asynchrones) et parallèles (synchrones).

IV.7. RESEAU DE HOPFIELD

C'est un réseau récurrent avec une connexion totale. Développé en 1982, le modèle du réseau de Hopfield est caractérisé par des sorties binaires des neurones et des interconnexions symétriques [28-29]. Sa propriété fondamentale réside dans la grandeur d'Energie qui décroît au cours des itérations. Pour illustrer le principe du modèle de Hopfield, on considère un réseau de M neurones à connexion totale avec une matrice d'interconnexion symétrique : $w_{ij}=w_{ji}$ et dont les éléments diagonaux sont nuls : $w_{ii}=0$. On dispose d'un vecteur constitué de M valeurs binaires $\{a_i^{(m)}\}$. Les poids synaptiques sont calculés comme suit,

$$w_{ij} = \begin{cases} \sum_{m=1}^M (2a_i^{(m)} - 1)(2a_j^{(m)} - 1) & \text{si } i \neq j \\ 0 & \text{si } i = j \end{cases} \quad (4-11)$$

Les seuils du réseau sont déterminés par,

$$\theta_i = -\frac{1}{2} \sum_{j=1}^M w_{ij} \quad (4-12)$$

La fonction Energie est donnée par l'expression suivante,

$$E = -\frac{1}{2} \sum_i (u_i - \theta_i) a_i = -\frac{1}{2} \sum_i \sum_j w_{ij} a_i a_j - \sum_i \theta_i a_i \quad (4-13)$$

Si on considère $E(k)$ l'énergie calculée a l'instant k et $E(k+1)$ l'énergie calculée a l'instant k+1, la différence d'énergie entre les deux instants peut être donnée selon l'expression suivante,

$$\begin{aligned} \Delta_k E &= E(k+1) - E(k) \\ &= -\frac{1}{2} \sum_i \sum_j w_{ij} a_i(k+1) a_j(k+1) - \sum_i \theta_i a_i(k+1) + \frac{1}{2} \sum_i \sum_j w_{ij} a_i(k) a_j(k) + \sum_i \theta_i a_i(k) \\ &= -\sum_i [a_i(k+1) - a_i(k)] \left[\sum_j w_{ij} a_j(k) + \theta_i \right] - \frac{1}{2} \sum_i [a_i(k+1) - a_i(k)] \sum_j [w_{ij} [a_j(k+1) - a_j(k)]] \end{aligned} \quad (4-14)$$

Si on pose $u_i(k+1) = \sum_j w_{ij} a_j(k) + \theta_i$ et $\Delta a(k+1) = a(k+1) - a(k)$, l'expression de $\Delta_k E$ se simplifie sous la forme suivante,

$$\Delta_k E = -\sum_i u_i(k+1) \Delta a_i(k+1) - \frac{1}{2} \Delta a^T(k+1) W \Delta a(k+1) \quad (4-15)$$

Les réseaux de Hopfield sont souvent appliqués aux problèmes d'optimisation. La résolution de ce type de problèmes consiste à trouver une solution optimale en appliquant un certain critère, sous un certain nombre de contraintes. Ce critère est souvent la minimisation d'une fonction coût. Cette solution est d'autant meilleure si la fonction coût converge rapidement vers son minimum.

IV.8. RESOLUTION DU PROBLEME DU VOYAGEUR DE COMMERCE PAR UN RESEAU DE HOPFIELD

Le problème du voyageur de commerce est formulé comme suit, Un commerçant voyageur doit visiter un certain nombre de villes et revenir à la ville de départ à la fin du parcours [28, 29]. Il s'agit donc d'appliquer un réseau de Hopfield pour déterminer la séquence des villes à visiter sous les contraintes suivantes : toutes les villes doivent être visitées et ne visiter chaque ville qu'une seule fois, et le voyageur doit rejoindre la ville de départ à la fin du parcours. La fonction coût à minimiser est la distance totale parcourue. Pour permettre cette solution, il faut présenter une architecture du réseau qui convient à ce problème. Par exemple, pour visiter n villes, on doit offrir n positions possibles pour chacune d'elles. Ainsi, on définit une matrice de dimension $(n \times n)$, dont les éléments représentent les positions de chacune des n villes dans le parcours. Par conséquent, on indique par V_{xi} la sortie des neurones, où x indique la ville à visiter et i indique sa position dans le parcours. Pour définir la fonction Energie du problème, on définit les critères de minimisation suivantes

- une ville ne peut être visitée qu'une seule fois dans le parcours,
- chaque position dans le parcours ne correspond qu'à une seule ville, (le voyageur ne peut pas être dans deux villes en même temps),
- Tous les villes doivent être visitées dans le parcours,
- Le parcours doit correspondre à la distance minimale possible.

Par conséquent, la fonction Energie prend la forme suivante

$$\begin{aligned}
 E = & \frac{A}{2} \sum_{x=1}^n \sum_{i=1}^n \sum_{\substack{j=1 \\ j \neq i}}^n V_{xi} V_{xj} + \frac{B}{2} \sum_{x=1}^n \sum_{i=1}^n \sum_{\substack{j=1 \\ j \neq x}}^n V_{xi} V_{ji} + \frac{C}{2} \left(\sum_{x=1}^n \sum_{i=1}^n V_{xi} - n \right)^2 \\
 & + \frac{D}{2} \sum_{x=1}^n \sum_{i=1}^n \sum_{\substack{j=1 \\ j \neq x}}^n d_{xj} V_{xi} (V_{j,i+1} + V_{j,i-1})
 \end{aligned} \tag{4-16}$$

ou V_{xi} est la sortie du neurone (x,i) et d_{xj} est la distance entre les villes x et j avec $d_{xj}=d_{jx}$. Puisque le voyageur revient à la ville de départ, la position $n+1$ dans le parcours n'est autre que la position 1, et la position 0 dans le parcours n'est autre que la position n . Par conséquent, les sorties des neurones correspondants à ces position sont égales et on a $V_{x0}=V_{xn}$ et $V_{xn+1}=V_{x1}$. Le premier terme de la fonction Energie est équivalent à la première contrainte. Il tend vers zéro si et seulement si une seule sortie V_{xi} correspondant à une seule ville x est non nulle. Le deuxième terme est équivalent à la deuxième contrainte. Il est nul si et seulement si une seule sortie V_{xi} correspondant à la position i du parcours est non nulle. Quant au troisième terme qui correspond à la troisième contrainte, il est nul si le parcours contient les n villes que le voyageur doit visiter. Le dernier terme correspond à la dernière contrainte. Il est minimal si la distance du parcours est minimale. La matrice des poids de connexion correspondant à la fonction Energie précédente de dimension $(n^2 \times n^2)$ est définie comme suit

$$T_{xi,yj} = -A\delta_{xy}(1 - \delta_{ij}) - B\delta_{ij}(1 - \delta_{xy}) - C - Dd_{xy}(\delta_{ji+1} - \delta_{ji-1}) \tag{4-17}$$

$\delta_{xy} = 1$ si $x=y$ et $\delta_{xy} = 0$ si $x \neq y$. L'évolution dans le temps du réseau de neurones est décrite par l'équation différentielle suivante :

$$\frac{du_i}{dt} = -\frac{u_i}{t_0} + \sum_{j=1}^n T_{ij} V_j + I_i \tag{4-18}$$

ou t indique le temps et t_0 est une constante de temps, u_i est l'entrée du $i^{\text{ème}}$ neurone, et T_{ij} et I_i sont fixes. Pour la simulation numérique du réseau, l'équation précédente s'écrit sous la forme suivante

$$\Delta u_i = \left(-\frac{u_i}{t_0} + \sum_{j=1}^n T_{ij} V_j + I_i \right) \Delta t \quad (4-19)$$

et la mise à jour des solutions u_i s'effectue par la relation $u_i(t+1) = u_i + \Delta u_i$. Les sorties des neurones sont déterminées par la relation d'entrée/sortie suivante

$$V_i = g(u_i) \quad (4-20)$$

avec g une fonction monotone et non décroissante définie comme étant la fonction sigmoïde. La fonction de Liapounov est donnée sous la forme,

$$E = -\frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n T_{ij} V_i V_j - \sum_{i=1}^n V_i I_i \quad (4-21)$$

Avec $I = Cn$, le courant qui traverse les neurones.

IV.8.1. Méthode de rétro-propagation du gradient d'erreur

La méthode de **Rétro-Propagation du Gradient d'Erreur** (RPGE) [27][29] est destinée à la modification des poids synaptiques d'un réseau de neurones multicouches. On suppose que l'entrée du réseau est constituée d'un vecteur x de dimension p , et sa sortie est constituée d'un vecteur V de dimension n . La sortie d'un neurone i est donnée par la fonction d'activation $f(\cdot)$ de type sigmoïde comme suit

$$V_i = f(u_i - \theta) = \tanh[k(u_i - \theta)] = \frac{1}{1 + \exp[-k(u_i - \theta)]} \quad (4-22)$$

$$f(u_i - \theta) = f\left[\sum_{j=1}^p w_{ij} x_j - \theta \right] \quad (4-23)$$

avec u est la valeur du réseau donnée par la fonction de base (4-1). On veut associer au vecteur d'entrée x un vecteur de sortie V_d . Comme les poids w_{ij} sont des valeurs quelconques,

le vecteur de sortie observé V est différent de celui désiré V_d . On associe à cette différence l'erreur quadratique suivante

$$E = \frac{1}{2} \sum_{i=1}^n (V_i - V_d)^2 \quad (4-24)$$

L'objectif recherché est d'ajuster les poids du réseau en minimisant l'erreur quadratique minimale à la sortie du réseau. Cependant, le problème qui se pose est que les sorties désirées des couches cachées sont inconnues, et par conséquent on ne peut pas calculer l'erreur quadratique associée à chaque couche interne. On va donc tenter d'exprimer l'erreur à la sortie de chaque neurone d'une couche quelconque à partir de l'erreur de la dernière couche. Afin d'illustrer cette méthode, et pour des raisons de clarté, on suppose qu'on dispose d'un réseau constitué de trois couches. C'est ainsi qu'on exprime le gradient de l'erreur par rapport au poids $w_{kh}^{(2)}$ associé à la connexion du neurone h de la couche 1 avec le neurone k de la couche 2 par l'expression suivante

$$\frac{\partial E}{\partial w_{kh}^{(2)}} = \sum_{i \in \text{couche3}} \frac{\partial E}{\partial u_i^{(3)}} \frac{\partial u_i^{(3)}}{\partial w_{kh}^{(2)}} \quad (4-25)$$

Le premier terme du gradient d'erreur peut être exprimé par

$$\frac{\partial E}{\partial u_i^{(3)}} = \frac{\partial E}{\partial V_i^{(3)}} \frac{\partial V_i^{(3)}}{\partial u_i^{(3)}} \quad (4-26)$$

car la sortie $V_i^{(3)}$ est reliée à la valeur de réseau $u_i^{(3)}$ par la fonction d'activation $V_i^{(3)} = f(u_i^{(3)})$.

De plus, cette valeur de réseau du neurone i de la couche 3 est exprimée en fonction des sorties des neurones de la couche 2 par la fonction de base comme suit

$$u_i^{(3)} = \sum_{j \in \text{couche2}} w_{ij}^{(3)} V_j^{(2)} \quad (4-27)$$

A partir des équations (4-24) et (4-27), le premier terme du gradient d'erreur peut donc s'écrire sous la forme

$$\frac{\partial E}{\partial u_i^{(3)}} = (V_i^{(3)} - V_{di}) f'(u_i^{(3)}) \quad (4-28)$$

Le second terme du gradient d'erreur s'écrit sous la forme

$$\frac{\partial u_i^{(3)}}{\partial w_{kh}^{(2)}} = \frac{\partial}{\partial w_{kh}^{(2)}} \left[\sum_{j \in \text{couche2}} w_{ij}^{(3)} V_j^{(2)} \right] \quad (4-29)$$

Dans cette expression le seul terme qui dépend de $w_{kh}^{(2)}$ est celui obtenu pour $k=j$. En remplaçant $V_k^{(2)}$ par son expression, le second terme peut s'écrire sous la forme suivante

$$\frac{\partial u_i^{(3)}}{\partial w_{kh}^{(2)}} = w_{ik}^{(3)} V_h^{(1)} f'(u_k^{(2)}) \quad (4-30)$$

En remplaçant les équations (4-28) et (4-30) dans l'équation (4-25), on obtient l'expression du gradient d'erreur comme suit

$$\frac{\partial E}{\partial w_{kh}^{(2)}} = \sum_{i \in \text{couche3}} (V_i^{(3)} - V_{di}) f'(u_i^{(3)}) w_{ik}^{(3)} V_h^{(1)} f'(u_k^{(2)}) \quad (4-31)$$

Si on pose $\delta_i^{(3)} = (V_i^{(3)} - V_{di}) f'(u_i^{(3)})$, on obtient

$$\frac{\partial E}{\partial w_{kh}^{(2)}} = \left[\sum_{i \in \text{couche3}} \delta_i^{(3)} w_{ik}^{(3)} \right] f'(u_k^{(2)}) V_h^{(1)} \quad (4-32)$$

On remarque que l'erreur affectée à un neurone de la couche 2 est égale à la somme des erreurs des neurones de la couche suivante 3 pondérée par les poids de connexion de ce neurone avec la couche 3. Si on pose

$$\delta_k^{(2)} = \left[\sum_{i \in \text{couche3}} \delta_i^{(3)} w_{ik}^{(3)} \right] f'(u_k^{(2)}) \quad (4-33)$$

on obtient une expression identique à celle du gradient de la dernière couche. On arrive finalement à la relation d'adaptation des poids des neurones de la couche 2 qu'on définit comme suit

$$\Delta w_{kh}^{(2)} = -a\delta_k^{(2)}V_h^{(1)} \quad (4-34)$$

où a est un gain d'adaptation positif. Les trois dernières équations se généralisent à n'importe quelle couche cachée d'un réseau multicouches. On reproduit dans ce qui suit les relations généralisées de la méthode de rétro-propagation du gradient d'erreur.

Règle d'adaptation,

$$\Delta w_{kh}^{(j)} = -a\delta_k^{(j)}V_h^{(j-1)} \quad (4-35)$$

L'erreur d'un neurone,

$$\delta_k^{(j)} = \left[\sum_{i \in \text{couche } j} \delta_i^{(j+1)} w_{ik}^{(j+1)} \right] f'(u_k^{(j)}) \quad (4-36)$$

pour une couche interne, et

$$\delta_k^{(j)} = [V_k^{(j)} - V_{kd}] f'(u_k^{(j)}) \quad (4-37)$$

pour la dernière couche.

L'algorithme de retro-propagation d'erreurs est basé sur la minimisation d'une erreur instantanée et non pas d'une erreur calculée sur toute la phase d'apprentissage. Par conséquent, la vitesse de convergence est lente et nécessite un pas d'adaptation relativement petit afin d'éviter l'instabilité. Une difficulté de la méthode est le choix des valeurs initiales des poids synaptiques du réseau. Nous proposons dans ce qui suit une méthode pour résoudre ce problème, basée sur la dynamique des entrées.

La forme non linéaire de la fonction d'activation $f(\cdot)$ fait apparaître un facteur de correction qui dépend de la pente au point de fonctionnement du neurone. On suppose que les entrées et les poids sont indépendants et les poids sont uniformément distribués dans un intervalle $[-M_1, M_2]$. Les états des neurones sont considérés centrés et de variances σ_u . Afin de conserver une

vitesse de convergence acceptable, on choisit les valeurs initiales des poids en fonction des entrées. Autrement dit, pour une fonction de base définie comme suit

$$u_i = \sum_j w_{ij} x_j \quad (4-38)$$

La moyenne des poids s'écrit sous la forme suivante

$$E[u_i] = \sum_j E[w_{ij}] E[x_j] = 0 \quad (4-39)$$

Pour que la moyenne des poids soit nulle, nous choisissons des poids centrés, on a alors $M_1 = M_2 = M$. Ceci permet d'écrire la variance sous la forme suivante

$$\sigma_u^2 = E[u_i^2] = \sum_j E[w_{ij}^2] E[x_j^2] \quad (4-40)$$

Puisque la répartition des poids est uniforme entre $-M$ et M , on a donc $E[w_{ij}^2] = \frac{M^2}{3}$ et M peut être choisi par l'expression suivante

$$M = \sqrt{\frac{3\sigma_u^2}{\sum_j E[x_j^2]}} \quad (4-41)$$

Pour fixer une vitesse de convergence adéquate sans entraîner l'algorithme vers l'instabilité, le pas d'adaptation doit être choisi avec soin. Une des approches utilisées consiste à choisir un pas permettant d'avoir une décroissance régulière de l'erreur quadratique moyenne. Ce pas est ajusté à chaque itération. Pour cela, on suppose qu'on veut avoir une variation ΔE de l'erreur quadratique moyenne E vérifiant la relation suivante

$$\Delta E = -cE \quad (4-42)$$

ou c est un facteur de la croissance relative choisie. En notant W le vecteur de tous les poids et g le vecteur gradient, la variation moyenne des poids peut être écrite sous la forme suivante

$$E[\Delta W] = E\left[-a \frac{\partial E}{\partial W}\right] = -ag \quad (4-43)$$

Sachant que le gradient moyen est donné, par définition, par l'expression $E[\Delta E] = g^T E[\Delta W]$, alors en tenant compte de l'équation (4-43), on peut écrire

$$E[\Delta E] = -a\|g\|^2 \quad (4-44)$$

Où a est le gain d'adaptation défini dans (4-35). On en déduit la valeur de a comme suit

$$a = -\frac{E[\Delta E]}{\|g\|^2} = \frac{cE}{\|g\|^2} \quad (4-45)$$

A chaque itération, on calcule l'erreur quadratique moyenne et le gradient moyen, puis on ajuste le gain a en vue de la prochaine itération.

IV.9. POURSUITE RADAR PAR LES RESEAUX DE NEURONES

La mise au point d'un système de surveillance aérienne se trouve confronté au problème de gestion d'informations reçues d'un ou plusieurs radars. Ces informations sont généralement complémentaires, incomplètes, contradictoires et hétérogènes. Le traitement de toutes les informations doit être effectué rapidement sous de fortes contraintes du temps réel. L'application des réseaux de neurones au pistage de cibles radar peut être effectuée de trois manières, par mesure de divergence, par optimisation ou par reconnaissance de trajectoires.

IV.9.1. Par Mesure de Divergence

On suppose qu'à l'instant k on dispose de m mesures à associer avec n pistes existantes. On construit un réseau neuronal pour déterminer la similitude entre les pistes et les mesures. Pour cela, on calcule la distance $\phi(i,j)$ entre la piste i et la mesure j . Lorsque cette distance est inférieure à un seuil s , cela signifie que cette mesure j est générée par la cible correspondant à la piste i .

IV.9.2. Par Optimisation

Si on considère que le problème d'association plots/pistes correspond au problème d'optimisation de la distance entre les plots et les pistes sur toutes les associations possibles, on peut donc rapprocher le problème d'association à un problème d'optimisation similaire à celui du « voyageur de commerce », et qui est résolu par un réseau de Hopfield. L'inconvénient de cette approche est que la solution du réseau correspondant converge vers un minimum local de la fonction Energie d'un coté, et de l'autre coté, les informations a priori sur le processus d'association ainsi que la possibilité d'associer un plot plus éloigné à une piste plutôt qu'un plot proche ne sont pas prises en considération.

IV.9.3. Par Reconnaissance de Trajectoires

Si on suppose qu'on peut connaître la forme de la trajectoire, qu'une cible peut suivre, au moyen de sa cinématique, on peut apprendre au réseau de neurones à reconnaître cette forme et à l'anticiper. Dans ce cas, on apprend au réseau une bibliothèque de pistes (pistes prototypes) en les mémorisant, et si une cible s'est présentée, le réseau est capable de sélectionner un prototype dans la bibliothèque qui correspond à cette cible. Il est donc facile de déterminer la position future la plus probable et effectuer ensuite l'association plots/pistes.

IV.10. EXEMPLE D'ASSOCIATION PLOTS/PISTES PAR MESURE DE DIVERGENCE

La méthode qu'on va présenter dans ce paragraphe est basée sur le principe d'optimisation de la distance plot/piste. Le problème d'association plots/pistes est, dans ce cas, approché au problème du voyageur de commerce. Dans ce qui suit, le réseau de Hopfield qu'on va appliquer va être décrit. Au début on définit la probabilité α_{ij} d'associer un plot i à une piste j par l'expression,

$$\alpha_{ij} = \exp \left[- \left(\frac{d_{ij}^2}{2d_{\max}^2} \right) \right] \quad (4-46)$$

où d_{ij} est la distance entre le plot i et la piste j , et d_{\max} est la distance au-delà de laquelle le plot est impossible d'être associé à la piste. Ceci permet d'écarter les couples plot/piste inutiles dès le début, et de permettre au réseau construit de converger rapidement vers la solution finale. La fonction Energie est choisie sous la forme suivante

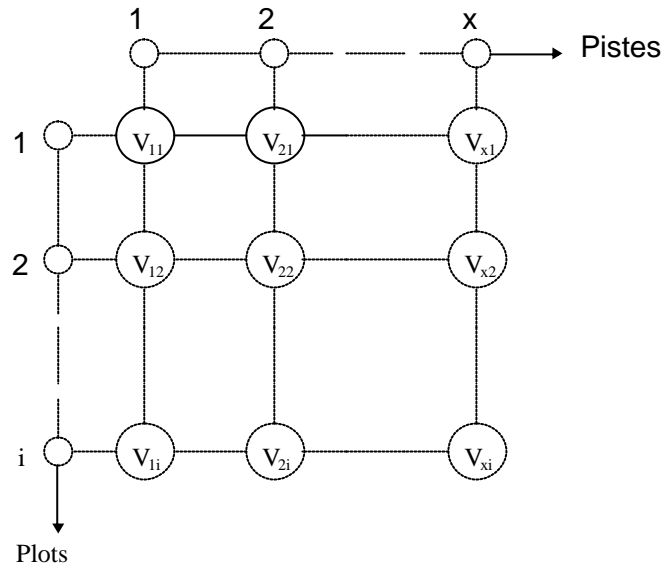


Figure 4-2 Structure du réseau de Hopfield

$$E_{obj} = \frac{1}{N} \sum_{i=1}^M \prod_{j=1}^N (1 - \alpha_{ij} V_{ij}) \quad (4-47)$$

Le réseau obtenu est totalement interconnecté et organisé selon le schéma de la Figure (4-2) On représente par U_{ij} l'entrée d'un neurone (i,j) et par V_{ij} la valeur de sortie de ce neurone. La sortie V_{ij} est définie comme suit

$$V_{ij} = \begin{cases} 1 & \text{si on associe le plot } i \text{ à la piste } j \\ 0 & \text{si non} \end{cases} \quad (4-48)$$

La minimisation de la fonction Energie fait tendre vers 1 les sorties V_{ij} correspondant aux probabilités α_{ij} grandes, et tendre vers 0 les sorties V_{ij} correspondant aux probabilités α_{ij} faibles.

La minimisation de la fonction Energie E_{obj} revient à écrire

$$\frac{dU_{ij}}{dt} = - \frac{\partial E_{obj}}{\partial V_{ij}} \quad (4-49)$$

et $V_{ij} = f(U_{ij})$ avec f une fonction définie de façon que $dV_{ij}/dU_{ij} \geq 0$.

L'algorithme de calcul est le suivant.

1. On dispose de M mesures et N pistes. Un filtre de Kalman permet d'estimer la position future d'une cible (prédiction d'une piste i).
2. On calcule l'ensemble des distances plot/piste d_{ij} .
3. On en déduit les probabilités α_{ij} .
4. On initialise le réseau de neurones de dimension NxM en posant $U_{ij} = \alpha_{ij}$.
5. On remet à jour séquentiellement les entrées U_{ij} par la relation

$$\Delta U_{ij} = -\frac{\partial E_{obj}}{\partial V_{ij}} = \frac{\alpha_{ij}}{N} \prod_{\substack{y=1 \\ y \neq i}}^M (1 - \alpha_{ij} V_{ij}) \quad (4-50)$$

6. On calcule les sortie V_{ij} par la formule

$$V_{ij} = \text{sgm} \left[U_{ij} - 0.5 \text{Max}_{l, l \neq j} (U_{il}) - 0.5 \text{Max}_{y, y \neq i} (U_{yj}) \right] \quad (4-51)$$

de façon que $dV_{ij}/dU_{ij} \approx 0$. Pour inhiber la présence simultanément de deux « 1 » sur la même ligne ou la même colonne, on pose

$$\text{Sgm}(i) = \frac{1}{1 + \exp(-ki)} \quad (4-52)$$

IV.11. EXEMPLE D'ASSOCIATION PLOTS/PISTES PAR OPTIMISATION

On propose dans ce paragraphe une méthode d'association plots/pistes basée sur un réseau de neurones de Hopfield. En comparant le problème du voyageur du commerce avec celui de l'association avec celui d'association de données de poursuite, ce dernier est considéré comme un problème d'optimisation avec des contraintes qu'on va décrire par la suite [18][21][22]. Nous décrivons la fonction Energie du réseau de Hopfield comme suit

$$E_{JPDA} = \frac{A}{2} \sum_{j=0}^m \sum_{t=1}^n \sum_{l=1}^n \sum_{l \neq t} V_j^t V_l^t + \frac{B}{2} \sum_{j=0}^m \sum_{t=1}^n \sum_{l=0}^m \sum_{l \neq j} V_j^t V_l^t + \frac{C}{2} \sum_{t=1}^n \left(\sum_{j=0}^m V_j^t - 1 \right)^2$$

$$+ \frac{D}{2} \sum_{j=0}^m \sum_{t=1}^n (V_j^t - \rho_j^t)^2 + \frac{E}{2} \sum_{j=0}^m \sum_{t=1}^n \sum_{l=1}^n \left(V_j^t - \sum_{\substack{k=0 \\ k \neq j}}^m \rho_k^l \right)^2$$

(4-53)

ou ρ_j^t est la probabilité de vraisemblance normalisée de l'événement d'association de la $j^{\text{ème}}$ mesure avec la $t^{\text{ème}}$ piste, calculée comme suit

$$\rho_j^t = \frac{P_j^t}{\sum_{l=0}^{m_k} P_l^t} \quad (4-54)$$

et P_j^t est donnée par l'équation (3-52). Les probabilités d'association plots/pistes β_j^t sont obtenues par les sorties V_j^t des neurones dans le réseau d'association de dimension $(m+1) \times n$, où m est le nombre de mesure et n est le nombre de pistes. Chaque terme de la fonction Energie (4-53) représente une des contraintes d'association plots/pistes suivantes [25]

- Une mesure ne peut pas être générée par deux cibles.
- Deux mesures ne peuvent pas être générées par la même cible.
- La somme des probabilités d'association relatives à chaque cible est égale à l'unité,

$$\sum_{j=0}^m \beta_j^t(k) = 1$$
- La sortie d'un neurone V_j^t est grande si la probabilité de vraisemblance normalisée ρ_j^t de l'événement d'association correspondant est grande.
- Si la sortie des neurones V_j^t est grande pour une cible t , elle est faible pour les autres cibles.

Si on indique par T_{jk}^t le poids de connexion du neurone (t, j) au neurone (l, k) , et par I_j^t le courant qui traverse le neurone (t, j) , la fonction Energie décrite dans (4-53) peut être simplifiée sous la forme suivante

$$E_{JPDA} = -\frac{1}{2} \sum_j^m \sum_k^m \sum_t^n \sum_l^n T_{jk}^{tl} V_j^t V_k^t - \sum_j^m \sum_t^n V_j^t I_j^t \quad (4-55)$$

avec

$$T_{jk}^{tl} = -A\delta_{jk}(1 - \delta_{tl}) - B\delta_{tl}(1 - \delta_{jk}) - C\delta_{tl} - D\delta_{tl}\delta_{jk} - E(n-1)\delta_{tl}\delta_{jk} \quad (4-56)$$

et

$$I_j^t = C + (D+E)\rho_j^t + E\left(n-1 - \sum_{l=1}^n \rho_j^l\right) \quad (4-57)$$

L'évolution du réseau est décrite par l'équation différentielle suivante,

$$\frac{du_j^t}{d\zeta} = -\frac{u_j^t}{s_0} - A \sum_{\substack{l=1 \\ l \neq t}}^n V_j^l - B \sum_{\substack{k=0 \\ k \neq j}}^m V_k^t - C \left(\sum_{k=0}^m V_k^t - 1 \right) - [D + E(n-1)]V_j^t + (D+E)\rho_j^t + E\left(n-1 - \sum_{l=1}^n \rho_j^l\right) \quad (4-58)$$

Avec

$$V_l^t = g(u_j^t) = \frac{1}{2} \left(1 + \tanh \frac{u_j^t}{u_0} \right) \quad (4-59)$$

Les coefficients A, B, C, D et E sont ajustés pour contrôler l'effet des différentes contraintes et propriétés du processus d'association plots/pistes. La combinaison de ces cinq paramètres permet d'assurer une bonne performance de poursuite par cette méthode.

IV.12. ASSOCIATION PLOTS/PISTES PAR UN RESEAU DE HOPFIELD MODIFIE

Dans le paragraphe précédent, une méthode d'association de données dans un algorithme de poursuite radar a été présentée. On propose de présenter, dans ce paragraphe, une solution au problème d'association de données de poursuite basée sur le réseau de Hopfield dont les poids synaptiques sont calculés différemment [25]. Cette solution apporte deux modifications, la première consiste à utiliser la méthode de Runge-Kutta pour l'intégration des différences avec une mise à jour synchrone au lieu de la méthode d'Euler, et la seconde consiste à utiliser la structure d'optimisation présentée par Aiyer [19]. La nouvelle matrice des poids synaptiques est exprimée comme suit,

$$T_{jk}^{tl} = -A\delta_{jk}(1 - \delta_{tl}) - B\delta_{tl}(1 - \delta_{jk}) - C\delta_{tl} - D\delta_{tl}\delta_{jk} - E(T-1)\delta_{tl}\delta_{jk} + 2 \frac{(A_n - A + A_i)}{n^2} \quad (4-60)$$

Avec δ est le symbole de Kronecker, et n est le nombre de pistes. Les probabilités β_j^t sont approximées par les sorties V_j^j des neurones dans le réseau de dimension $(m+1) \times n$ avec n le nombre de pistes, ρ_j^t est la probabilité de vraisemblance normalisée entre la $j^{\text{ème}}$ mesure et la $t^{\text{ème}}$ piste. Des recommandations ont été données par Aiyer [19] sur le choix des paramètres A , B , C , D , E et A_1 . Par exemple, $A=B$, $C=A/10$ et $A_1=31/32A$. Il a été prouvé [25] que les deux méthodes d'association de données radar basées sur le réseau de Hopfield standard et modifié présentent une bonne suppression des plots de clutter, mais la deuxième fournit à sa sortie des pistes lissées plus proches aux pistes réelles surtout en présence de manœuvres, et produit moins de fausses pistes.

IV.13. CONCLUSION

CHAPITRE V

METHODE D'ASSOCIATION DE DONNEES RADAR PAR UN RESEAU DE HOPFIELD

CONTENU :

V.1. INTRODUCTION.....	79
V.2. DESCRIPTION DE LA METHODE	80
V.3. ANALYSE DES PERFORMANCES.....	83
V.4. DESCRIPTION DES ALGORITHMES DE SIMULATION	84
V.4.1. Génération de trajectoires	84
V.4.2. Génération de mesures radar.....	85
V.4.3. Algorithme de Poursuite	85
V.5. GENERATION DE SITUATIONS AERIENNES	86
V.6. CHOIX DES PARAMETRES DE SIMULATION.....	90
V.7. SIMULATION ET ANALYSE.....	91
V.7.1. Première Situation.....	91
V.7.2. Deuxième Situation.....	96
V.7.3. Troisième Situation.....	101
V.8. DISCUSSION SUR LES RESULTATS	107
V.9. TEST DU RESEAU OBTENU	115
V.10. CONCLUSION	118

V.1. INTRODUCTION

Le problème d'association de données de poursuite multicibles est crucial à cause du nombre des hypothèses d'associations possibles. Ce nombre croît rapidement en fonction du taux de mesures reçues par tour d'antenne. Les approches classiques appliquées à cette tâche sont restées inefficaces dans des situations de clutter dense et complexes en terme de calcul. Parmi les approches les plus utilisées en pratique, on cite la méthode d'association probabilistique conjointe de données (Joint Probabilistic Data Association, JPDA). Elle consiste à déterminer, pour chaque cible, les probabilités d'association de tous les plots, et les utiliser ensuite comme facteurs de pondération pour calculer une mesure moyenne. C'est cette dernière qui est utilisée pour la mise à jour des pistes. Elle permet d'améliorer considérablement la performance de poursuite et réduire le coût de calcul, comparativement aux méthodes optimales. Cependant, même avec la méthode JPDA, la performance de poursuite reste insuffisante en présence de clutter dense et le volume de calcul reste important si le nombre de pistes à poursuivre est important. Les méthodes à base de réseaux de neurones sont développées pour remédier aux insuffisances des méthodes classiques. Le mécanisme de leur application à la perception du mouvement humain est adopté dans les algorithmes d'association de données radar.

On propose, dans ce chapitre, une solution au problème d'association plots/pistes basée sur un réseau de neurones de Hopfield. En comparant le problème d'association avec celui du voyageur de commerce (Voir §4.8) [3], l'association de données de poursuite est assimilée à un problème d'optimisation avec des contraintes. Ces contraintes sont obtenues par une évaluation soignée des propriétés de la loi d'association du filtre JPDA d'un côté, et d'autre côté, de la méthode du plus proche voisin. La performance de la nouvelle méthode dépend étroitement des cinq paramètres qui apparaissent dans la fonction Énergie. Les valeurs de ces paramètres, que nous choisissons, diffèrent de celles proposées dans la littérature [18][22][24]. Elles sont choisies en analysant les résultats d'association comparativement à d'autres méthodes tel que la méthode du plus proche voisin et la méthode d'association probabilistique conjointe de données (JPDA). Le choix convenable de ces paramètres permet à la nouvelle méthode d'association neuronale d'avoir la performance des deux méthodes. L'association plots/pistes se simplifie, en conséquence, à un plot pour chaque piste. Les simulations que nous avons effectuées sont menées afin de démontrer les améliorations de la performance du nouveau associeur neuronal de données radar par rapport à celui basée sur la méthode "JPDA" ou la méthode du plus proche voisin. Nous décrivons dans ce qui suit la méthode d'association basée sur le réseau de Hopfield. Ensuite nous présenterons les algorithmes de génération de données

radar et de la poursuite qui sont utilisés pour la simulation. Les résultats de simulation et les commentaires seront aussi présentés dans ce chapitre. Nous terminerons enfin par une conclusion.

V.2. DESCRIPTION DE LA METHODE

La méthode d'association plots/pistes que nous proposons consiste à appliquer un réseau de Hopfield aux données de poursuite radar pour déterminer les plots qui vont être associés avec les pistes, et résoudre les ambiguïtés d'association qui peuvent surgir (Voir §1.3.3). Cependant, la détermination des couples d'association plots/pistes doit respecter certaines contraintes. Par exemple, un plot ne peut être associé avec plus d'une piste, et on ne peut associer plus d'un plot avec une seule piste comme dans le cas de la méthode du plus proche voisin. De plus, la priorité doit être donnée aux hypothèses d'association plots/pistes qui ont une plus grande probabilité de vraisemblance, comme dans le cas de la méthode d'association probabilistique conjointe de données (JPDA).

La structure du réseau de Hopfield que nous avons utilisé est définie comme suit. On suppose qu'à l'instant k on dispose de m mesures à associer avec n pistes existantes. Par conséquent, on construit un réseau neuronal de dimension $(m+1) \times n$, totalement interconnecté (toutes les sorties du réseau se propagent vers les entrées de chaque neurone), et organisé selon le schéma de la Figure 5-1. Chaque neurone (t, j) correspond à une hypothèse d'association d'un plot j avec une piste t . On représente par u_j^t l'état d'un neurone (t, j) et par v_j^t la valeur de sa sortie. Quand le réseau atteint l'état stable, les sorties v_j^t seront définies comme suit

$$v_j^t = \begin{cases} 1 & \text{si le plot } j \text{ est associé à la piste } t \\ 0 & \text{si le plot } j \text{ n'est pas associé à la piste } t \end{cases}$$

(5-1)

Chaque neurone (t, j) délivre à sa sortie une valeur qui n'est autre que la probabilité d'association du plot j à la piste t . La fonction Energie du réseau de Hopfield est exprimée par

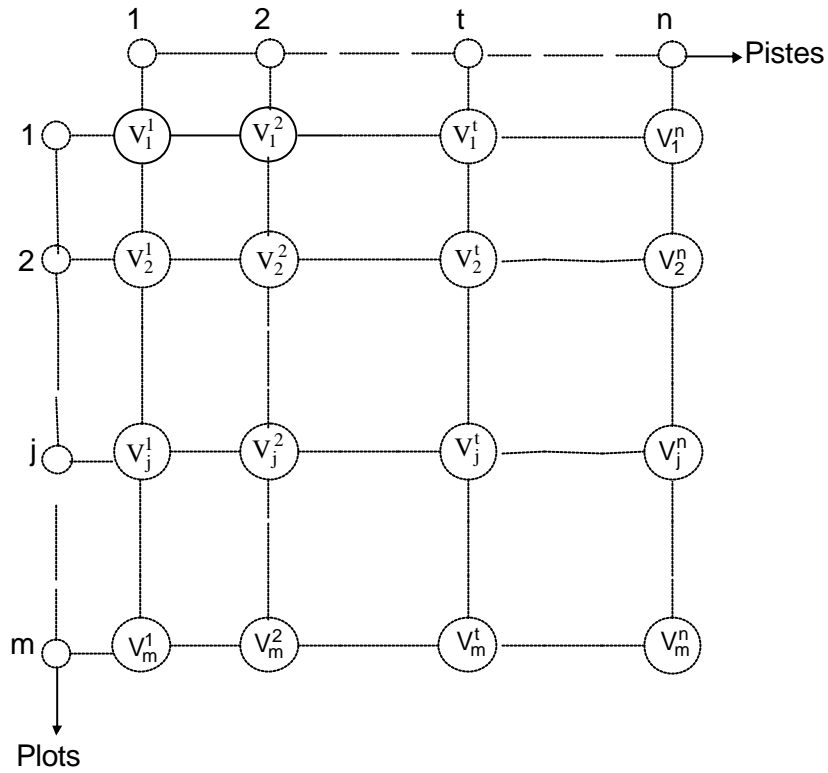


Figure 5-1 Structure du réseau de Hopfield utilisé de dimension $n \times m$ neurones, avec n nombre de pistes et m nombre de colonnes

$$\begin{aligned}
 E_{JPDA} = & \frac{A}{2} \sum_{j=0}^m \sum_{t=1}^n \sum_{\substack{l=1 \\ l \neq t}}^n V_j^t V_j^l + \frac{B}{2} \sum_{j=0}^m \sum_{t=1}^n \sum_{\substack{l=0 \\ l \neq j}}^m V_j^t V_l^t + \frac{C}{2} \sum_{t=1}^n \left(\sum_{j=0}^m V_j^t - 1 \right)^2 \\
 & + \frac{D}{2} \sum_{j=0}^m \sum_{t=1}^n (V_j^t - \rho_j^t)^2 + \frac{E}{2} \sum_{j=0}^m \sum_{t=1}^n \sum_{\substack{l=1 \\ l \neq t}}^n \left(V_j^t - \sum_{\substack{k=0 \\ k \neq j}}^m \rho_k^l \right)^2
 \end{aligned} \tag{5-2}$$

Ou ρ_j^t est la probabilité de vraisemblance normalisée de l'événement d'association de la $j^{\text{ème}}$ plot avec la $t^{\text{ème}}$ piste, et est calculée comme suit

$$\rho_j^t = \frac{P_j^t}{\sum_{l=0}^{m_k} P_l^t} \tag{5-3}$$

et P_j^t est donnée par l'Equation 3-52 (Voir §3.8). Les probabilités d'association plots/pistes β_j^t sont obtenues par les sorties V_j^t des neurones dans le réseau d'association de Hopfield utilisé. Chaque terme de la fonction Energie (5-2) représente une des contraintes d'association plots/pistes suivantes [24] :

- Une mesure ne peut pas être générée par deux cibles.
- Deux mesures ne peuvent pas être générées par la même cible.
- La somme des probabilités d'association relatives à chaque cible est égale à l'unité,

$$\sum_{j=0}^m \beta_j^t(k) = 1$$

- La sortie d'un neurone V_j^t est grande si la probabilité de vraisemblance normalisée ρ_j^t de l'événement d'association correspondant est grande.
- Si la sortie des neurones V_j^t est grande pour une cible t, elle est faible pour les autres cibles.

Si on indique par T_{jk}^{tl} la longueur de connexion du neurone (t, j) au neurone (l, k), et par I_j^t le courant qui traverse le neurone (t, j), la fonction Energie (Equation 5-2) peut être simplifiée sous la forme suivante

$$E_{JPDA} = -\frac{1}{2} \sum_j^m \sum_k^m \sum_t^n \sum_l^n T_{jk}^{tl} V_j^t V_k^t - \sum_j^m \sum_t^n V_j^t I_j^t \quad (5-4)$$

avec

$$T_{jk}^{tl} = -A\delta_{jk}(1 - \delta_{tl}) - B\delta_{tl}(1 - \delta_{jk}) - C\delta_{tl} - D\delta_{tl}\delta_{jk} - E(T - 1)\delta_{tl}\delta_{jk} \quad (5-5)$$

et

$$I_j^t = C + (D + E)\rho_j^t + E\left(n - 1 - \sum_{l=1}^n \rho_j^l\right) \quad (5-6)$$

L'évolution du réseau est décrite par l'équation différentielle suivante,

$$\frac{du_j^t}{d\zeta} = -\frac{u_j^t}{s_0} - A \sum_{\substack{l=1 \\ l \neq t}}^n V_j^l - B \sum_{\substack{k=0 \\ k \neq j}}^m V_k^t - C \left(\sum_{k=0}^m V_k^t - 1 \right) - [D + E(n - 1)]V_j^t + (D + E)\rho_j^t + E\left(n - 1 - \sum_{l=1}^n \rho_j^l\right) \quad (5-7)$$

et la sortie de chaque neurone est exprimée en fonction des états (fonction d'activation) comme suit

$$V_i^t = g(u_j^t) = \frac{1}{2} \left(1 + \tanh \frac{u_j^t}{u_0} \right) \quad (5-8)$$

Les coefficients A, B, C, D et E sont ajustés pour contrôler l'effet des différentes contraintes et propriétés du processus d'association plots/pistes. La combinaison de ces cinq paramètres permet d'assurer une bonne performance de poursuite par cette méthode.

V.3. ANALYSE DES PERFORMANCES

Il est difficile d'analyser la performance d'un système de poursuite multicibles à cause de la diversité des scénarios et des situations aériennes. Le développement d'une simulation de Monte Carlo, qui englobe toutes les fonctions d'un algorithme de poursuite, est nécessaire. Pour l'évaluation de la fonction d'association plots/pistes, les probabilités cumulées de correcte association et de fausse association sont calculées. Pour déterminer la probabilité de correcte association $P_{ca}^t(k)$ et de fausse association $P_{fa}^t(k)$ d'une mesure j à une piste t au tour k , nous multiplions la probabilité de correcte corrélation par la probabilité d'association $\beta_j^t(k)$ de cette mesure à la piste considérée, et on écrit

$$P_{ca}^t(k) = P_{cc} \beta_j^t(k) \quad (5-9)$$

$$P_{fa}^t(k) = P_{cc} (1 - \beta_j^t(k)) \quad (5-10)$$

Les probabilités de correcte et de fausse association sont ajustées à chaque balayage pour obtenir les probabilités de correcte et de fausse association cumulées.

$$CP_{ca}(k+1) = CP_{ca}(k) + [1 - P_T(k)] P_{ca}(k+1) \quad (5-11)$$

$$CP_{fa}(k+1) = CP_{fa}(k) + [1 - P_T(k)] P_{fa}(k+1) \quad (5-12)$$

ou $P_T(k)$, la probabilité de recevoir au moins une mesure dans la fenêtre de validation, est définie comme suit

$$P_T(k) = CP_{ca}(k) + CP_{fa}(k) \quad (5-13)$$

V.4. DESCRIPTION DES ALGORITHMES DE SIMULATION

Les algorithmes de simulation, que nous avons utilisés, sont : algorithme de génération de trajectoires, algorithme de génération de mesures radar et algorithme de poursuite. La première étape consiste à choisir des données d'entrée, les paramètres du filtre de poursuite, et les données de performances souhaitée. Les données d'entrée sont les coordonnées de la position et la vitesse initiales des trajectoires, la direction, la durée et l'amplitude des accélération, la période de balayage radar, la probabilité de détection et de fausses alarmes, densité des plots de clutter dans une région déterminée, paramètres du filtre de poursuite, L'étape d'initialisation consiste à choisir les matrices de covariance des erreurs de mesure R_k et d'accélération Q_k impliquées dans le modèle dynamique de la cible, les matrices de transition F_k et de mesure H_k .

V.4.1. Génération de trajectoires

Il est difficile d'analyser le comportement et d'évaluer la performance d'un algorithme de poursuite au moyens des données réelles calculées directement sur site par un système radar, d'ou l'utilisation des techniques de simulation Monté-Carlo sur un ordinateur numérique. La trajectoire d'une cible est constituée de segments rectilignes et de segments circulaires. Dans un radar TWS la cible est détectée une fois par tour d'antenne, et le temps entre deux détections successives peut varier d'une période à l'autre. Pour des raisons de simplicité, nous prenons l'écart entre deux passages successifs du faisceau d'antenne par la cible égale à la période de balayage radar durant toute la durée de vie de la trajectoire.

Pour chaque trajectoire à générer (voir Figure 5-2), nous définissons les paramètres suivantes: la période de balayage radar T (en seconde), la durée de vie N (nombre de balayages), la vitesse initiale V (en m/s), la direction initiale de la trajectoire α (en °), la séquence de l'accélération $A(.)$ en m/s, et les coordonnées de la position initiales X_0 et Y_0 (en mètre).

V.4.2. Génération de mesures radar

Dans une situation radar les mesures sont entachées de bruit, et des fausses alarmes sont souvent présentes. Il existe aussi l'éventualité de non détection des cibles. Pour simuler cette situation nous avons besoin de: simuler les cas de non détection, ajouter un bruit blanc aux coordonnées (distance et vitesse) des trajectoires que nous avons déjà calculées, ajouter un taux de fausses alarmes qui détermine le nombre de plots de clutter à chaque balayage, et choisir leurs coordonnées (Voir Figure 5-3). Le nombre de faux plots générés à chaque balayage est considéré comme une variable aléatoire régie par la distribution de Poisson. Tandis que les plots sont réparties dans le plan de couverture radar suivant une distribution uniforme. pour raison de convenance, les faux plots sont répartis autour du plot réel de la trajectoire dans la fenêtre de validation.

V.4.3. Algorithme de Poursuite

Pour le bon déroulement des tests de la méthode d'association de données que nous avons présentée, il a fallu concevoir un algorithme de poursuite dont le principe de fonctionnement est présenté dans le Chapitre premier (Voir §2.3). Il est exécuté 16 fois par tour. Dans ce qui suit nous résumons les principales fonctions de cet algorithme (Figure 2-2).

1. Associer les plots radar aux pistes existantes. Les plots associés seront éliminés du buffer d'entrée.
2. Mettre à jour les pistes avec les plots qui leurs sont associés en utilisant un filtre de poursuite, et prolonger celles qui n'ont pas reçu de plots. Dans notre algorithme le filtre que nous avons utilisé est de type $\alpha\beta$ à plusieurs paliers.
3. Abandonner les pistes qui sont prolongées plusieurs tours d'antenne.
4. Initier de nouvelles pistes avec les plots non associés.
5. Envoyer les pistes à la visualisation pour l'exploitation.

La fonction d'association des plots avec les pistes est modifiée en fonction de la méthode utilisée à savoir la méthode du plus proche voisin, la méthode JPDA et la méthode par le réseau de Hopfield sans que le reste de l'algorithme de poursuite soit affecté.

V.5. GENERATION DE SITUATIONS AERIENNES

Pour l'analyse de la méthode qu'on vient de décrire, nous avons généré plusieurs scénarios typiques tel que le croisement de pistes, des cibles qui volent sur des lignes parallèles, et les manœuvres de pistes. Nous présentons dans la Figure 5-4 une situation aérienne constituée de six trajectoires rectilignes. dont les positions initiales et les vitesses sont portées dans le Tableau 5-1. Les coordonnées de ces trajectoires sont entachées de bruit blanc et sont entourées de faux plots. Nous avons généré aussi une deuxième situation aérienne constituée de six trajectoires manœuvrantes (Voir Figure 5-5). Les positions initiales, les vitesses et les débuts des manœuvres sont données par le tableau 5-2. La durée de vie des deux situations est de 30 tours d'antenne.

Cible	Position initiale		Vitesse initiale		Direction (en °)
	x (km)	y (km)	v_x (m/s)	v_y (m/s)	
1	60	0	-340	120	160
2	20	50	70	-400	280
3	50	-20	-390	-130	200
4	50	-50	-390	220	150
5	-20	50	-70	-390	260
6	50	30	-260	-220	220

Tableau 5-1 Positions et vitesses initiales des trajectoires dans le premier scénario

Cible	Position initiale		Vitesse initiale		Direction (en °)	Début manoeuvre	Durée (secondes)	Amplitude (m/s^2)
	x (km)	y (km)	v_x (m/s)	v_y (m/s)				
1	60	0	-340	120	160	20	15	15
2	20	50	70	-400	280	17	23	20
3	50	-20	-390	-130	200	15	20	10
4	50	-50	-390	220	150	0	0	0
5	-20	50	-70	-390	260	20	15	-15
6	50	30	-260	-220	220	0	0	0

Tableau 5-2 Positions initiales, vitesses initiales, et manœuvres des trajectoires dans le deuxième scénario

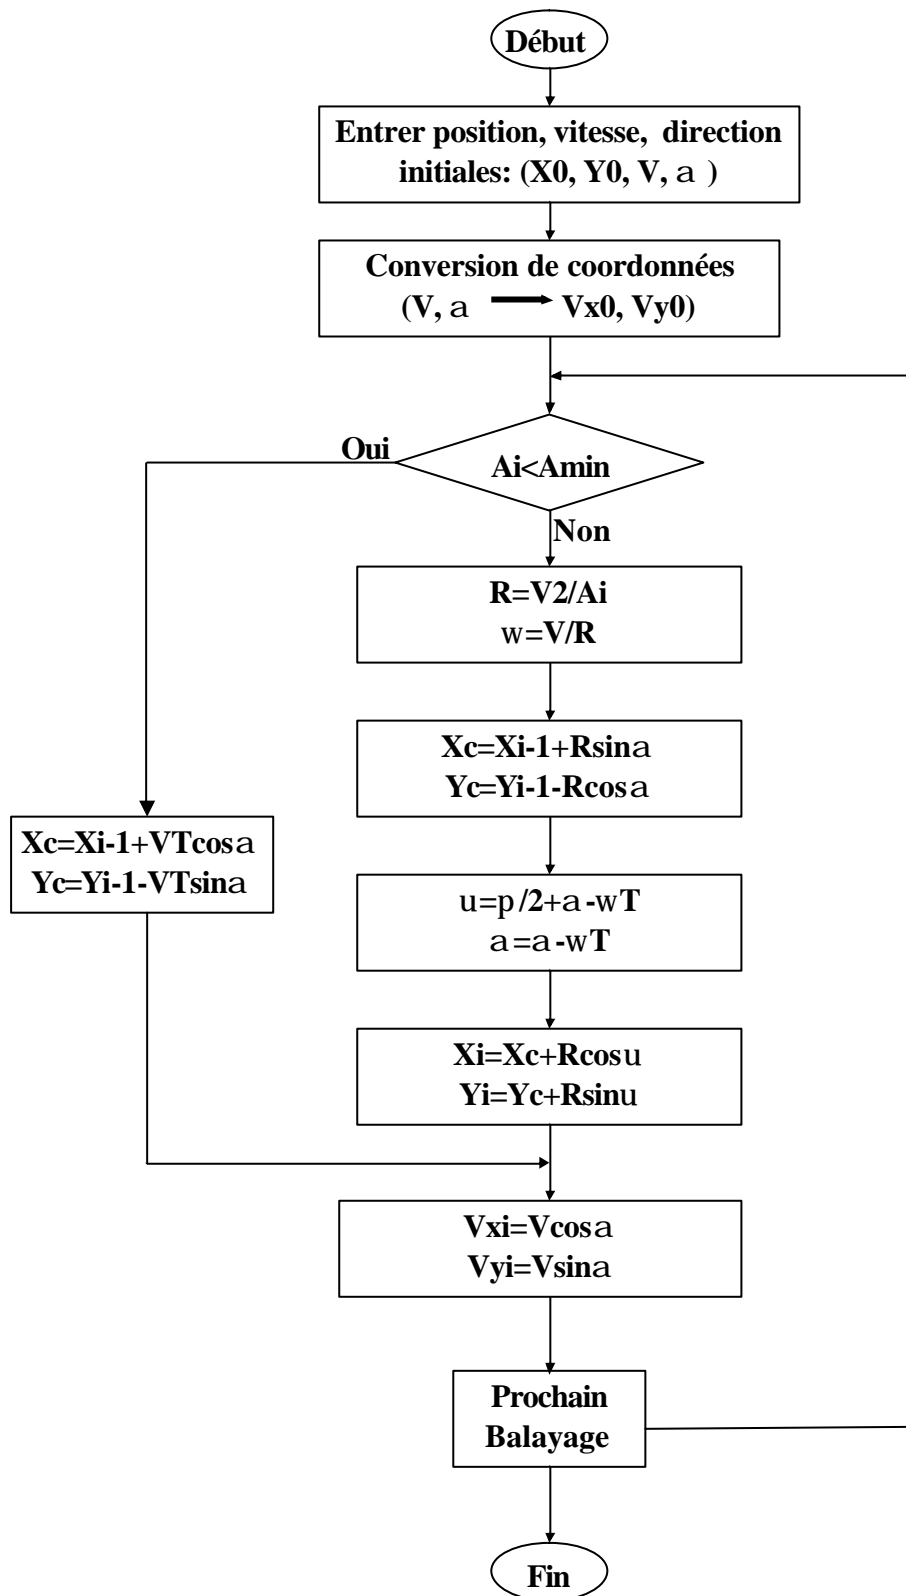


Figure 5-2 Organigramme de l'algorithme de Génération de trajectoires des cibles

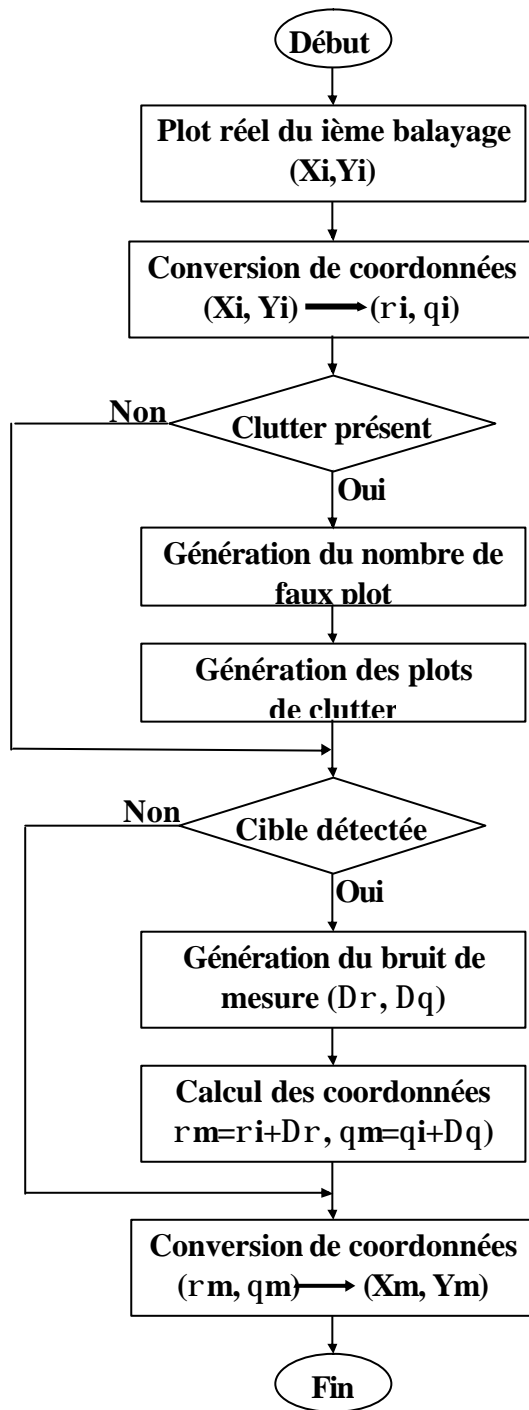


Figure 5-3 Organigramme de l'algorithme de Génération de mesures radar




Figure 5-4 Trajectoires générées avec des plots de clutter dans le premier scénario




Figure 5-5 Trajectoires générées avec des plots de clutter dans le deuxième scénario

V.6. CHOIX DES PARAMETRES DE SIMULATION

La première étape est le choix des constantes qui interviennent dans la simulation. La période de balayage radar est considérée égale à 10s. Les variances des bruits de mesure, considérées identiques pour toutes les cibles et de distribution gaussienne avec moyenne nulle, sont $\sigma_x^2 = 2500 \text{ m}^2$ et $\sigma_y^2 = 2500 \text{ m}^2$. La probabilité de validation des plots est prise égale à $P_G=0.95$ avec un seuil $\gamma=9.2$. La probabilité de détection est considérée égale à $P_d= 0.95$. La densité des faux plots, dans la fenêtre de validation, est prise égale à 0.2 km^{-1} . La deuxième étape concerne l'initialisation du réseau de Hopfield. Les sorties des neurones, définies par l'équation (4-8), sont prises initialement égales aux probabilités de vraisemblances normalisées des plots, $V_1^t = \rho_1^t$ (Voir équation 5-3). Les états des neurones sont donnés donc comme suit

$$u_1^t = \frac{u_0}{2} \ln \frac{\frac{x}{\theta} - V_1^t}{1 - V_1^t} = \frac{u_0}{2} \ln \frac{\frac{x}{\theta} - \rho_1^t}{1 - \rho_1^t} \quad (5-14)$$

La fonction Energie est minimisée à travers la fonction différentielle suivante

$$u_1^t(i+1) = \left(\frac{s_0 - \zeta}{s_0} \right) u_1^t(i) - \zeta A \sum_{\substack{\tau=1 \\ \tau \neq t}}^T v_1^\tau(i) - \zeta B \sum_{\substack{j=1 \\ j \neq i}}^{m(k)} v_j^t(i) - \zeta C \left(\sum_{j=0}^{m(k)} v_j^t(i) - 1 \right) - \zeta [D + E(T - 1)] v_1^t(i) + \zeta (D + E) \rho_1^t + \zeta E \left(T - 1 - \sum_{\tau=1}^T \rho_1^\tau \right) \quad (5-15)$$

La constante de temps du réseau s_0 et l'étape d'itération ζ sont choisis respectivement égales à 1s et 0.00001s. Les équations (5-8) et 5-15) sont répétées jusqu'à ce que les sorties des neurones correspondant aux plots associés se stabilisent aux valeurs maximales et celles des neurones correspondant aux plots non associés se stabilisent aux valeurs minimales.

V.7. SIMULATION ET ANALYSE

La performance de la méthode d'association de données radar à base de réseau de Hopfield, qu'on vient de présenter est contrôlée essentiellement par les cinq paramètres de la fonction Energie (5-2). Le choix convenable de ces paramètres A, B, C, D et E offre à la méthode les propriétés de la méthode du plus proche voisin et de la méthode JPDA. Le nombre d'itération nécessaires pour atteindre l'état stable varie aussi en fonction de ces paramètres [3]. L'étape essentielle dans la simulation est la détermination des paramètres du réseau de Hopfield. Il n'y a pas de règle stricte de choix des cinq paramètres A, B, C, D, et E, et ils sont déterminés expérimentalement. Pour cela, nous avons généré différents scénarios, puis nous avons évalué les résultats d'association de plusieurs situations en fonction des cinq paramètres du réseau. Dans ce qui suit, nous allons présenter trois situations différentes, dans chacune d'elles, nous évaluerons les résultats d'association en fonction des paramètres du réseau de neurones.

V.7.1. Première Situation

Dans la première situation, représentée par la Figure 5-6, six plots sont associés avec quatre pistes dont les probabilités d'association déterminées par le filtre JPDA sont données par le tableau 5-3a. Les résultats d'association (voir tableaux 5-3b à 5-3f) par le réseau de Hopfield en fonction des variations des paramètres du réseau sont identiques à ceux de la méthode du plus proche voisin. Ces associations ont conduit aux résultats suivants: le plot 6 est associé à la piste 1, le plot 4 est associé à la piste 2, le plot 2 est associé à la piste 4 et aucun plot n'est associé à la piste 3.

Nous avons aussi évalué la rapidité du réseau en fonction des cinq paramètres du réseau. Pour le paramètre A, nous avons constaté que le réseau est d'autant plus rapide pour des grandes valeurs des paramètres A, B et C et des faibles valeurs de D et E (Voir Figures de 5-7 à 5-11).




Figure 5-6 disposition des pistes et des plots de la première situation dans l'espace de couverture radar

	Piste n° 1	Piste n° 2	Piste n° 3	Piste n° 4
0	0.049	0.125	0.689	0.114
1	0.293	0.133	0	0.171
2	0.203	0.318	0.142	0.359
3	0	0.098	0	0.084
4	0	0.226	0	0.169
5	0	0.029	0	0.018
6	0.453	0.067	0.168	0.081

Tableau 5-3a Probabilités d'association des plots dans la première situation, cas de quatre pistes et six plots

A	Piste n° 1	Piste n° 2	Piste n° 3	Piste n° 4
1-1000	6	4	0	2

Tableau 5-3b Plots associés aux pistes en fonction du paramètre A du réseau : B=150, C=100, D=10, E=5

B	Piste n°1	Piste n°2	Piste n°3	Piste n°4
1-1000	6	4	0	2

Tableau 5-3c Plots associés aux pistes en fonction du paramètre B du réseau : A=250, C=100, D=10, E=5

C	Piste n°1	Piste n°2	Piste n°3	Piste n°4
1-1000	6	4	0	2

Tableau 5-3d Plots associés aux pistes en fonction du paramètre C du réseau : A=250, B=80, D=10, E=5

D	Piste n°1	Piste n°2	Piste n°3	Piste n°4
0.1-30	6	4	0	2

Tableau 5-3e Plots associés aux pistes en fonction du paramètre D du réseau : A=250, B=80, C=100, E=5

E	Piste n°1	Piste n°2	Piste n°3	Piste n°4
0.1-8	6	4	0	2

Tableau 5-3f Plots associés aux pistes en fonction du paramètre E du réseau : A=250, B=80, C=100, D=10




Figure 5-7 Variation du nombre d'itérations en fonction du paramètre A pour différentes valeurs de B, C, D, et E. (1) B=80 C=100 D=10 E=5, (2) B=150 C=100 D=10 E=5, (3) B=80 C=300 D=10 E=5, (4) B=80 C=100 D=15 E=5, (5) B=80 C=100 D=10 E=7.




Figure 5-8 Variation du nombre d'itérations en fonction du paramètre B pour différentes valeurs de A, C, D, et E. (1) A=130 C=100 D=10 E=5, (2) A=250 C=100 D=10 E=5, (3) A=130 C=300 D=10 E=5, (4) A=130 C=100 D=15 E=5, (5) A=130 C=100 D=10 E=7.




Figure 5-9 Variation du nombre d'itérations en fonction du paramètre C pour différentes valeurs de A, B, D, et E. (1) A=130 B=80 D=10 E=5, (2) A=250 B=80 D=10 E=5, (3) A=130 B=150 D=10 E=5, (4) A=130 B=80 D=15 E=5, (5) A=130 B=80 D=10 E=7.




Figure 5-10 Variation du nombre d'itérations en fonction du paramètre D pour différentes valeurs de A, B, C, et E. (1) A=130 B=80 C=100 E=5, (2) A=250 B=80 C=100 E=5, (3) A=130 B=150 C=100 E=5, (4) A=130 B=80 C=300 E=5, (5) A=130 B=80 C=100 E=7.




Figure 5-11 Variation du nombre d'itérations en fonction du paramètre E pour différentes valeurs de A, B, C, et D. (1) A=130 B=80 C=100 D=10, (2) A=250 B=80 C=100 D=10, (3) A=130 B=150 C=100 D=10, (4) A=130 B=80 C=300 D=10, (5) A=130 B=80 C=100 D=15.

V.7.2. Deuxième Situation

Dans la deuxième situation, onze plots sont associés avec quatre pistes (Voir Figure 5-12). Le tableau 5-4a représente les probabilités d'association initiales déterminées par le filtre JPDA. Les tableaux 5-4b à 5-4f indiquent les résultats d'associations des plots avec les pistes en fonctions des variations des paramètres A, B, C, D, et E qui apparaissent dans la fonction Energie du réseau de Hopfield. Dans cette situation, les résultats d'associations par la méthode du plus proche voisin sont données par les couples (plot, piste) suivants : (9, 1), (4, 2), (10, 3), (8, 4). La comparaison de ces résultats avec ceux de l'association par le réseau de Hopfield nous a conduit à obtenir les valeurs des paramètres du réseau de Hopfield qui conviennent comme suit : A est supérieur à 50, B varie entre 40 et 300, C est supérieur à 50, D est inférieur à 30 et E est inférieur à 18.

L'évaluation de la rapidité du réseau de Hopfield en fonction du paramètre A a montré que le réseau atteint rapidement l'état stable pour des grandes valeurs de A avec une grande valeur de B et C et une faible valeur de D et E (Voir Figure 5-13). Pour le paramètre B, le réseau est plus rapide pour une grande valeur dans l'intervalle de 100 à 350 de B avec des grande valeurs de A et C et des petites valeurs de D et E (Voir Figure 5-14). La rapidité du réseau en fonction des variations du paramètre C, comme le démontre les courbes de la Figure 5-15, est meilleure pour des grandes valeurs de C avec des grandes valeurs des paramètres A et B et des petites valeurs des paramètres D et E. Pour le paramètre D (Voir Figure 5-16), le réseau est d'autant plus rapide pour de faibles valeurs de D avec de grandes valeurs de A, B et C et une petite valeur de E. De même, la rapidité du réseau est grande pour des faibles valeurs de E avec des grandes valeurs de A, B et C et une petite valeur de D (Voir Figure 5-17).




Figure 5-12 disposition des pistes et des plots de la deuxième situation dans l'espace de couverture radar

	Piste n° 1	Piste n° 2	Piste n° 3	Piste n° 4
0	0.109	0.312	0.119	0.104
1	0	0.080	0	0.014
2	0	0	0.032	0
3	0	0	0.009	0
4	0	0.607	0	0
5	0	0	0.004	0.026
6	0.068	0	0.057	0.097
7	0	0	0.055	0.204
8	0.030	0	0.236	0.277
9	0.747	0	0.144	0.033
10	0.044	0	0.223	0.126
11	0	0	0.116	0.114

Tableau 5-4a Probabilités d'association des plots dans la deuxième situation, cas de quatre pistes et onze plots

A	Piste n°1	Piste n°2	Piste n°3	Piste n°4
50-1000	9	4	10	7

Tableau 5-4b Plots associés aux pistes en fonction du paramètre A du réseau : B=150, C=100, D=10, E=5

B	Piste n°1	Piste n°2	Piste n°3	Piste n°4
40-300	9	4	10	7
300-1000	9	4	10	8

Tableau 5-4c Plots associés aux pistes en fonction du paramètre B du réseau : A=130, C=100, D=10, E=7

C	Piste n°1	Piste n°2	Piste n°3	Piste n°4
50-1000	9	4	10	7

Tableau 5-4d Plots associés aux pistes en fonction du paramètre C du réseau : A=250, B=80, D=10, E=5

D	Piste n°1	Piste n°2	Piste n°3	Piste n°4
0.1-30	9	4	10	7

Tableau 5-4e Plots associés aux pistes en fonction du paramètre D du réseau : A=250, B=80, C=100, E=5

E	Piste n°1	Piste n°2	Piste n°3	Piste n°4
0.1-18	9	4	10	7

Tableau 5-4f Plots associés aux pistes en fonction du paramètre E du réseau : A=250, B=80, C=100, D=10




Figure 5-13 Variation du nombre d'itérations en fonction du paramètre A pour différentes valeurs de B, C, D, et E. (1) B=80 C=100 D=10 E=5, (2) B=150 C=100 D=10 E=5, (3) B=80 C=300 D=10 E=5, (4) B=80 C=100 D=15 E=5, (5) B=80 C=100 D=10 E=7.




Figure 5-14 Variation du nombre d'itérations en fonction du paramètre B pour différentes valeurs de A, C, D, et E. (1) A=130 C=100 D=10 E=5, (2) A=250 C=100 D=10 E=5, (3) A=130 C=300 D=10 E=5, (4) A=130 C=100 D=15 E=5, (5) A=130 C=100 D=10 E=7.




Figure 5-15 Variation du nombre d'itérations en fonction du paramètre C pour différentes valeurs de A, B, D, et E. (1) A=130 B=80 D=10 E=5, (2) A=250 B=80 D=10 E=5, (3) A=130 B=150 D=10 E=5, (4) A=130 B=80 D=15 E=5, (5) A=130 B=80 D=10 E=7.




Figure 5-16 Variation du nombre d'itérations en fonction du paramètre D pour différentes valeurs de A, B, C, et E. (1) A=130 B=80 C=100 E=5, (2) A=250 B=80 C=100 E=5, (3) A=130 B=150 C=100 E=5, (4) A=130 B=80 C=300 E=5, (5) A=130 B=80 C=100 E=7.




Figure 5-17 Variation du nombre d'itérations en fonction du paramètre E pour différentes valeurs de A, B, C, et D. (1) A=130 B=80 C=100 D=10, (2) A=250 B=80 C=100 D=10, (3) A=130 B=150 C=100 D=10, (4) A=130 B=80 C=300 D=10, (5) A=130 B=80 C=100 D=15.

V.7.3. Troisième Situation

La troisième situation est plus complexe que les deux premières, car elle est constituée de sept pistes et quinze plots (voir tableaux 5-5a). En appliquant la méthode du plus proche voisin à cette situation, les résultats d'association sont les suivants : le plot 7 est associé à la piste 1, le plot 10 est associé à la piste 2, le plot 14 est associé à la piste 3, le plot 11 est associé à la piste 4, le plots 3 est associé à la piste 5, le plot 1 est associé à la piste 6 et le plot 13 est associé à la piste 7. De plus, nous avons constaté que la méthode du réseau de Hopfield offre des associations proches de celles précédentes si le paramètre A varie entre 50 et 220, B varie entre 260 et 480, C entre 60 et 300, D varie entre 12 et 19, et E inférieur à 3.3 (voir tableaux 5-5b à 5-5f). Cependant, les résultats d'association se sont simplifiés toujours à un seul plot pour chaque piste (Voir Figure 5-26).

L'évaluation de la rapidité du réseau en fonction des paramètres A, B, C, D et E a aboutit aux résultats suivants. Pour le paramètre A, le système est plus rapide si la valeur de A est inférieure à 400 avec une grande valeur de B, une grande valeur de C et qui ne dépasse pas 400, et une petite valeur de D et E (Voir Figure 5-19). tandis que le réseau est rapide si le paramètre B varie entre 300 et 400 pour une grande valeur de A et C, et une petite valeur de D et E, comme le démontre la Figure 5-20. Pour le paramètre C (Voir Figure 5-21), le réseau est plus rapide si la valeur de C varie entre 50 et 300 avec une grande valeur de B, et une petite valeur de D et E. La figure 5-22 montre que le réseau est rapide si la valeur de D est inférieure à 5 avec E est supérieur à 5, ou entre 5 et 9 et E est inférieur à 5. Les valeurs de A, B et C sont grandes. Finalement, la valeur de E qui convient une meilleure rapidité du réseau, est inférieur à 2 pour une grande valeur de A, B et C, et une petite valeur de D (Voir Figure 5-23).




Figure 5-18 disposition des pistes et des plots de la troisième situation dans l'espace de couverture radar

	Piste n° 1	Piste n° 2	Piste n° 3	Piste n° 4	Piste n° 5	Piste n° 6	Piste n° 7
0	0.135	0.132	0.239	0.088	0.577	0.188	0.128
1	0	0	0.208	0	0	0.032	0.035
2	0	0	0.016	0	0	0	0.022
3	0	0	0	0	0.204	0	0.004
4	0	0	0.052	0	0	0	0.006
5	0	0	0	0	0.095	0	0
6	0.012	0	0	0	0	0	0.014
7	0.417	0.193	0	0.349	0	0.110	0.086
8	0.076	0	0	0	0	0	0.070
9	0	0	0	0	0.123	0	0.015
10	0.040	0.538	0.027	0.478	0	0.325	0.004
11	0.235	0.077	0	0.083	0	0.090	0.220
12	0.012	0	0	0	0	0	0.063
13	0.047	0.015	0.017	0	0	0.040	0.221
14	0.011	0.042	0.437	0	0	0.211	0.106
15	0.010	0	0	0	0	0	0

Tableau 5-5a Probabilités d'association des plots dans la troisième situation, cas de sept pistes et quinze plots

A	Piste n° 1	Piste n° 2	Piste n° 3	Piste n° 4	Piste n° 5	Piste n° 6	Piste n° 7
50-220	8	10	14	7	0	1	13
220-750	8	10	14	7	0	11	13
750-1000	8	10	14	7	3	11	13

Tableau 5-5b Plots associés aux pistes en fonction du paramètre A du réseau B=150, C=100, D=10, E=5

B	Piste n° 1	Piste n° 2	Piste n° 3	Piste n° 4	Piste n° 5	Piste n° 6	Piste n° 7
50-90	8	10	1	7	3	11	13
90-180	8	10	14	7	0	11	13
180-260	8	10	14	11	0	1	13
260-480	7	10	14	11	0	1	13
480-1000	7	10	14	11	0	11	13

Tableau 5-5c Plots associés aux pistes en fonction du paramètre B du réseau A=250, C=100, D=10, E=5

C	Piste n° 1	Piste n° 2	Piste n° 3	Piste n° 4	Piste n° 5	Piste n° 6	Piste n° 7
60-300	8	10	14	7	0	1	13
300-400	8	10	14	7	0	11	13
400-1000	8	10	1	7	0	11	13

Tableau 5-5d Plots associés aux pistes en fonction du paramètre C du réseau A=130, B=15, D=10, E=5

D	Piste n° 1	Piste n° 2	Piste n° 3	Piste n° 4	Piste n° 5	Piste n° 6	Piste n° 7
0.1-12	8	10	1	7	3	11	13
12-19	8	10	14	7	3	11	13
19-30	8	10	14	7	0	11	13

Tableau 5-5e Plots associés aux pistes en fonction du paramètre D du réseau A=250, B=80, C=100, E=5

E	Piste n° 1	Piste n° 2	Piste n° 3	Piste n° 4	Piste n° 5	Piste n° 6	Piste n° 7
0.1-3.3	8	10	14	7	0	11	13
3.3-4.8	8	10	1	7	3	11	13
4.8-10	8	10	1	7	3	14	13

Tableau 5-5f Plots associés aux pistes en fonction du paramètre E du réseau A=250, B=80, C=100, D=10




Figure 5-19 Variation du nombre d'itérations en fonction du paramètre A pour différentes valeurs de B, C, D, et E. (1) B=80 C=100 D=10 E=5, (2) B=150 C=100 D=10 E=5, (3) B=80 C=300 D=10 E=5, (4) B=80 C=100 D=15 E=5, (5) B=80 C=100 D=10 E=7.




Figure 5-20 Variation du nombre d'itérations en fonction du paramètre B pour différentes valeurs de A, C, D, et E. (1) A=130 C=100 D=10 E=5, (2) A=250 C=100 D=10 E=5, (3) A=130 C=300 D=10 E=5, (4) A=130 C=100 D=15 E=5, (5) A=130 C=100 D=10 E=7.




Figure 5-21 Variation du nombre d'itérations en fonction du paramètre C pour différentes valeurs de A, B, D, et E. (1) A=130 B=80 D=10 E=5, (2) A=250 B=80 D=10 E=5, (3) A=130 B=150 D=10 E=5, (4) A=130 B=80 D=15 E=5, (5) A=130 B=80 D=10 E=7.




Figure 5-22 Variation du nombre d'itérations en fonction du paramètre D pour différentes valeurs de A, B, C, et E. (1) A=130 B=80 C=100 E=5, (2) A=250 B=80 C=100 E=5, (3) A=130 B=150 C=100 E=5, (4) A=130 B=80 C=300 E=5, (5) A=130 B=80 C=100 E=7.




Figure 5-23 Variation du nombre d'itérations en fonction du paramètre E pour différentes valeurs de A, B, C, et D. (1) A=130 B=80 C=100 D=10, (2) A=250 B=80 C=100 D=10, (3) A=130 B=150 C=100 D=10, (4) A=130 B=80 C=300 D=10, (5) A=130 B=80 C=100 D=15.

V.8. DISCUSSION SUR LES RESULTATS

Une première conclusion que nous tirons de l'étude précédente, est que le nombre d'itération nécessaire pour atteindre l'état stable dépend non seulement des valeurs des cinq paramètres du réseau, mais aussi, du scénario de poursuite généré caractérisé généralement par le nombre de plots, le nombre de pistes, et la disposition des uns par rapport aux autres dans l'espace (probabilités d'association initiales calculées par le filtre JPDA). La deuxième conclusion que nous pouvons aussi tirer est que le nombre d'itérations nécessaire au réseau pour atteindre l'état stable est minimale si les valeurs de A, B et C sont grandes et celles de D et E sont faibles.

En effet, la minimisation de la fonction Energie est basée sur la minimisation de chacun des cinq termes qui la constituent. Ces termes peuvent avoir différents effets suivant les contraintes qu'ils représentent qu'on vient de citer ci-dessus. Les deux premières contraintes qu'une piste ne peut générer qu'un et un seul plot à la fois, signifie qu'il ne peut y avoir qu'un seul plots associé à chaque piste. Pour s'assurer qu'il ne peut y avoir plus d'un '1' dans chaque ligne et chaque colonne du réseau de Hopfield, nous devons favoriser les deux premiers termes de la fonction Energie en choisissant les paramètres A et B plus grandes que les autres. Notons que les deux premières contraintes sont réciproques, et par conséquent nous pouvons choisir les paramètres A et B proches ou même égaux. Le troisième terme correspond à la contrainte que la somme des probabilités d'association des plots à chaque piste est égale à 1, ce qui signifie que la somme des sorties des neurones sur chaque colonne du réseau de Hopfield est égale à 1. Le choix d'une valeur grande du paramètre C implique une convergence rapide à 1 des sorties des neurones correspondant aux plots associés, et à 0 celles des neurones correspondant aux plots non associés. L'effet du quatrième terme consiste à favoriser les plots qui ont une grande probabilité de vraisemblance. De cette façon l'association par le réseau de Hopfield maintient les propriétés de l'association par la méthode JPDA tout en respectant les trois premières contraintes. Nous choisissons par conséquent le paramètre D petit. Le cinquième terme correspond à la contrainte qu'un plot soit associé une seule fois, ce qui signifie que si une sortie d'un neurone tend vers 1 les sorties des autres neurones de la même ligne tendent vers 0. Par conséquent le paramètre E est choisi petit de façon à assurer une convergence rapide d'un neurone au maximum dans chaque ligne du réseau de hopfield.

La solution d'un réseau de Hopfield n'est pas unique, et il peut y avoir plusieurs séries de paramètres (A, B, C, D, E) qui répondent aux contraintes précédentes. Par conséquent, il est

préférable de déterminer les intervalles de variation des paramètres du réseau qui conviennent le mieux aux résultats d'association souhaités, et choisir ensuite la série des valeurs qui conviennent. Nous tirons les intervalles de variation des paramètres comme suit : $A=(250,400)$, $B=(300,350)$, $C=(50,300)$, $D=(0,9)$ et $E=(0,2)$. Ceci nous a permis de sélectionner soigneusement les paramètres du réseau comme suit: $A=250$, $B=350$, $C=300$, $D=10$, et $E=1$. Ces valeurs correspondent aussi à la plus forte rapidité du réseau qui est moins de 150 itérations.

Après la sélection des paramètres du réseau, nous l'avons appliqué de nouveau aux trois situations précédentes. Les résultats d'association obtenus dans la première situation sont : le plot 6 est associé à la piste 1, le plot 4 est associé à la piste 2, le plot 2 est associé à la piste 4 et aucun plot n'est associé à la piste 3. Dans la deuxième situation nous avons obtenu les résultats suivants : le plot 9 est associé à la piste 1, le plot 4 est associé à la piste 2, le plot 10 est associé à la piste 3, et le plot 8 est associé à la piste 4. Les couples plots/pistes obtenus dans la troisième situations sont (7,1), (10,2), (14,3), (11,4), (3,5), (1,6) et (13,7). Tous ces résultats d'association correspondent à ceux de la méthode du plus proche voisin excepté la piste 5 dans la troisième situation à laquelle aucun plot n'est associé au lieu du plot 3. Ceci paraît normal car la probabilité de non association (0.577) est beaucoup plus grande que celle d'association du plot 3 (0.204), et selon la méthode JPDA, l'état estimé de cette piste sera très proche à la limite de la fenêtre de validation.

Les simulations ont montré que les probabilités d'association des plots associés aux pistes tendent vers 1, tandis que celles des plots non associés tendent vers 0, comme le démontre les courbes des Figures 5-24 à 5-26. Ceci confirme que la méthode d'association par le réseau de Hopfield a la propriété de la méthode du plus proche voisin qu'un seul plot au maximum est associé à chaque piste.

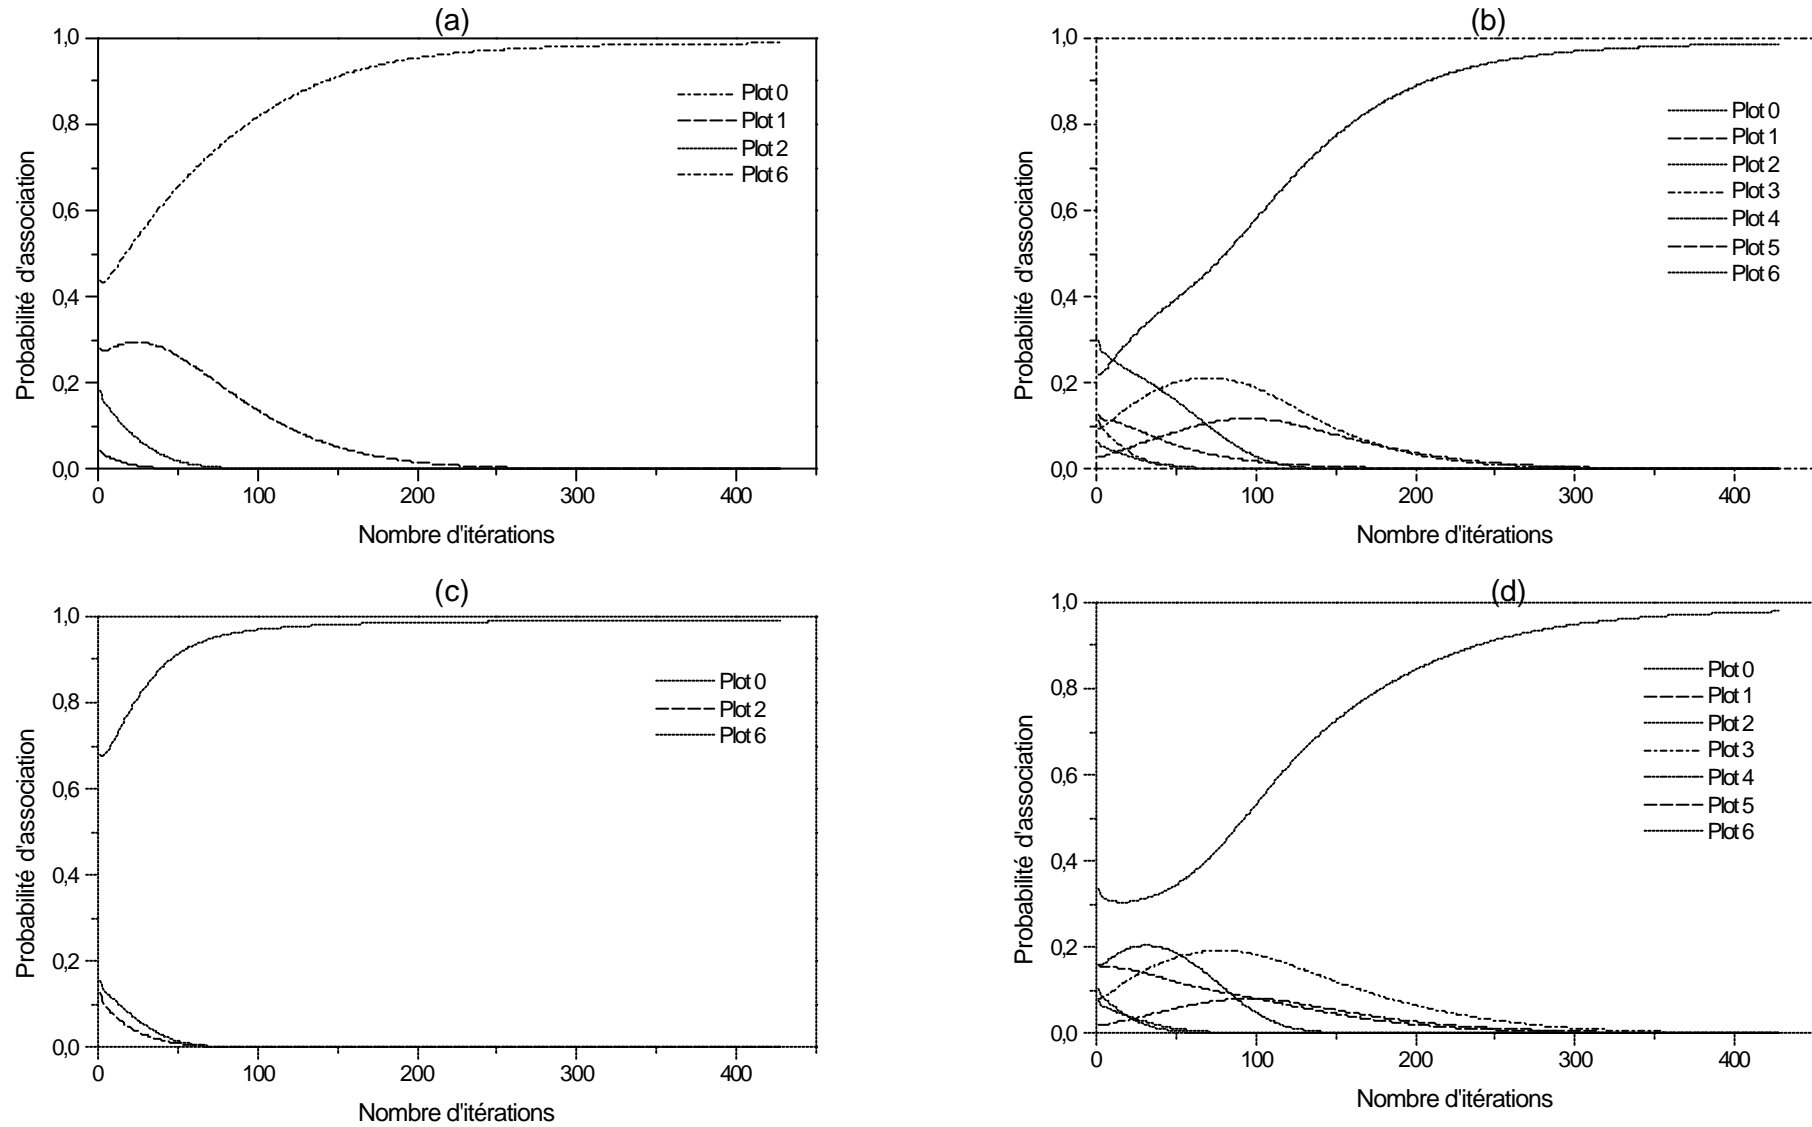


Figure 5-24 Evolution des probabilités d'association des plots avec les pistes de la première situation en fonction du nombre d'itérations du réseau de Hopfield : (a) Piste 1, (b) Piste 2, (c) Piste 3, (d) Piste 4. (Plot 0 signifie aucune association).











Figure 5-25 Evolution des probabilité d'association des plots avec les pistes de la deuxième situation en fonction du nombre d'itérations du réseau de Hopfield : (a) Piste 1, (b) Piste 2, (c) Piste 3, (d) Piste 4. (Plot 0 signifie aucune association).



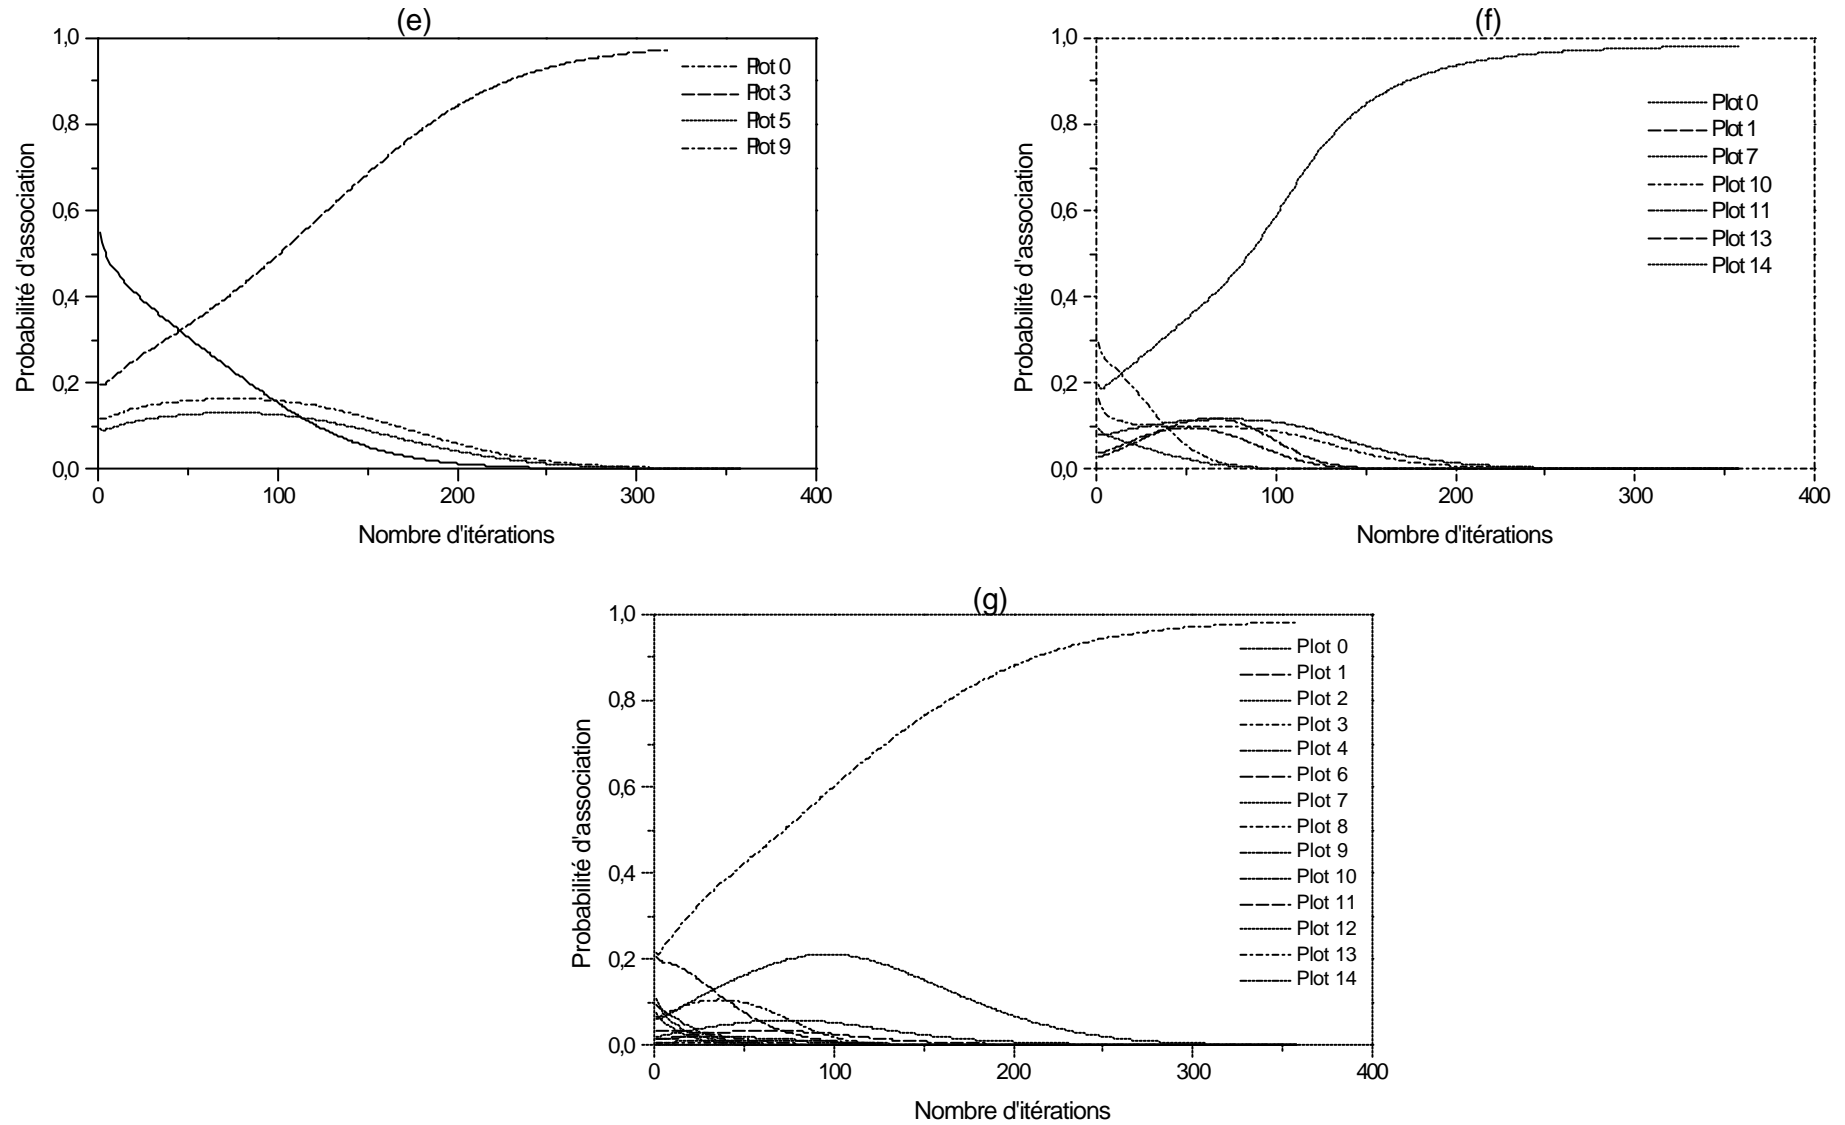


Figure 5-26 Evolution des probabilités d'association des plots avec les pistes de la troisième situation en fonction du nombre d'itérations du réseau de Hopfield : (a) Piste 1, (b) Piste 2, (c) Piste 3, (d) Piste 4, (e) Piste 5, (f) Piste 6, (g) Piste 7. (Plot 0 signifie aucune association).

En plus des résultats précédents, nous avons évalué aussi la fonction Energie dans chacune des trois situations précédentes. Il est à noter que les états des cellules d'un réseau de Hopfield peuvent soit changer soit rester stables. Par conséquent, la fonction d'énergie peut soit rester inchangée soit diminuer. Mais elle ne peut en aucun cas augmenter. Autrement dit, l'énergie d'un réseau décroît à chaque mise à jour des cellules et se stabilise à une valeur minimale.

L'évaluation de la fonction Energie du réseau obtenu dans les trois situations précédentes montre qu'elle converge toujours vers des valeurs minimales, comme s'est présenté dans les figures 5-27 à 5-29. Le nombre d'itérations nécessaire pour atteindre sa valeur minimale diffère d'une situation à une autre indépendamment de la dimension du réseau de Hopfield utilisé. Par exemple, dans la première situation, qui est la plus simple, six plots sont à associer avec quatre pistes et le nombre d'itérations est de 65 (voir Figure 5-27). Dans la deuxième situation, onze plots sont associés avec quatre pistes et le nombre d'itération est de 90 comme le montre la Figure 5-28. Tandis que dans la troisième situation, qui est plus complexe que les deux premières, quinze plots sont à associer avec sept pistes, et le nombre d'itérations est de 120 (voir Figure 5-29).




Figure 5-27 variation de la fonction Energie Normalisée dans la première situation en fonction du nombre d'itérations




Figure 5-28 variation de la fonction Energie Normalisée dans la deuxième Situation en fonction du nombre d'itérations




Figure 5-29 variation de la fonction Energie Normalisée dans la troisième Situation en fonction du nombre d'itérations

V.9. TEST DU RESEAU OBTENU

Pour le test du réseau ainsi obtenu, nous avons utilisé les scénarios générés dans le paragraphe 5.5. Nous avons appliqué le réseau de Hopfield que nous avons obtenu à la poursuite des pistes générées (voir figures 5-30 et 5-32). La poursuite de ces mêmes trajectoires des deux scénarios par la méthode JPDA est montrée dans les Figures 5-31 et 5-33, et nous avons effectué une comparaison entre les deux méthodes. Nous remarquons que la performance de l'association de données par le réseau de Hopfield est améliorée par rapport à celle de la méthode JPDA. Ceci s'explique par la prise en considération d'un seul plot pour la mise à jour des pistes dans la méthode à base de réseau de neurones, tandis que dans la méthode JPDA tous les plots situés dans la fenêtre de validation sont pris en compte.




Figure 5-30 Poursuite du premier scénario par le réseau de Hopfield obtenu




Figure 5-31 Poursuite du premier scénario par la méthode JPDA




Figure 5-32 Poursuite du deuxième scénario par le réseau de Hopfield obtenu





Figure 5-33 Poursuite du deuxième scénario par la méthode JPDA

V.10. CONCLUSION

Nous avons présenté, dans ce chapitre, la méthode d'association des données radar par les réseaux de neurones. La méthode est basée sur un réseau de Hopfield. La technique utilisée est équivalente à celle du voyageur de commerce. Une comparaison est faite entre le nouveau associeur neuronal et celui basé sur la méthode d'association probabilistique conjointe de données radar (JPDA). La simulation de plusieurs scénarios aériens a permis de sélectionner convenablement les paramètres du réseau de neurones, et qui assurent une performance comparable en même temps à celle de la méthode JPDA et de la méthode du plus proche voisin. Les résultats de simulation ont montré que cette méthode offre une bonne performance de poursuite pour des valeurs grandes de A, B et C, et des valeurs faibles de D et E. Le réseau de Hopfield ainsi obtenu correspond aux valeurs des paramètres suivants : A=250, B=350, C=300, D=10, et E=1. Le nombre d'itérations nécessaire pour la stabilité du réseau est de 120.

L'application du réseau de Hopfield obtenu à la poursuite de plusieurs scénarios a montré une amélioration remarquable de la performance de l'association plots/pistes comparativement aux méthodes JPDA et du plus proche voisin.



Dans ce travail nous avons considéré le problème d'association plots/pistes dans un algorithme de poursuite appliqué aux radars de surveillance aérienne à balayage panoramique. La méthode d'association, que nous avons présenté, est basée sur un réseau de neurones de Hopfield. Elle permet de déterminer, parmi les plots reçus ceux qui vont être associés aux pistes. Pour permettre le test et l'évaluation de la nouvelle méthode dans un environnement proche de la réalité, nous avons développé un algorithme qui englobe toutes les fonctions nécessaires d'un système de poursuite.

La nouvelle méthode d'association plots/pistes, basée sur le réseau de Hopfield, permet de déterminer les plots qui vont être associés aux pistes existantes. En comparant le problème du voyageur de commerce avec celui d'association de données radar, ce dernier est considéré comme un problème d'optimisation dont les contraintes sont choisies à partir des propriétés de la méthode d'association probabilistique conjointe de données (JPDA) et de la méthode du plus proche voisin. Ces contraintes ont permis de formuler convenablement la fonction Energie du réseau. Nous avons utilisé les probabilités de vraisemblance des événements d'association plots/pistes, calculées par la méthode JPDA pour initialiser le calcul itératif du réseau de Hopfield. Nous avons démontré que le choix d'un réseau de Hopfield adéquat dépend des cinq paramètres A, B, C, D et E qui apparaissent dans la fonction Energie. Les valeurs de ces paramètres sont sélectionnées en analysant les propriétés des deux méthodes du JPDA et du plus proche voisin, de sorte que l'association plots/pistes se simplifie à un seul plot pour chaque piste. Pour ce faire, nous avons simulé plusieurs scénarios afin de prendre en considération toutes les situations aériennes possibles. Les résultats de simulation ont montré que cette méthode offre une bonne performance de poursuite pour des valeurs larges de A, B et C, et des valeurs faibles de D et E.

Nous avons démontré aussi à travers la simulation que le nombre d'itérations nécessaire pour atteindre la solution finale dépend non seulement des paramètres du réseau obtenu mais aussi de la situation aérienne. Cette dernière est généralement caractérisée par le nombre de plots et le nombre de pistes, et la disposition des uns par rapport aux autres dans l'espace de couverture du radar. Nous avons démontré aussi que les sorties, des neurones correspondant aux plots associés, convergent toujours vers 1 et se stabilisent à des valeurs maximales que nous normalisons souvent à 1. Tandis que les sorties des neurones correspondant aux plots non associés convergent vers 0 et se stabilisent à des valeurs minimales qui sont souvent normalisées à 0. Par conséquent, la matrices de sortie finale est toujours constituée d'un 1 au

maximum sur chaque ligne et chaque colonne. L'évaluation de la fonction Energie du réseau de Hopfield converge toujours vers 0 et se stabilise à une valeur minimale.

Finalement, la comparaison entre l'association plots/pistes par le réseau de Hopfield obtenu et l'association par la méthode du filtre JPDA d'un coté, et par la méthode du plus proche voisin d'autre coté, a démontré la supériorité de la performance de l'association par le réseau de Hopfield sur les deux autres méthodes.

Ce travail constitue une étude exploratrice de l'application des réseaux de neurones en général et le réseau de Hopfield en particulier, pour effectuer l'association plots/pistes dans les algorithmes de poursuite radar. Une étude plus approfondie doit être menée afin de ressortir les avantages de cette méthode comparativement à d'autres méthodes classiques, et de démontrer l'implémentabilité simple des réseaux de neurones sur un hardware spécifique ou général.

BIBLIOGRAPHIE

- [1] Merlin Skolnik. *'Radar Handbook'*, deuxième édition, Chapitre 8 « Automatic detection tracking and sensor integration » par G. V. Trunk.
- [2] A. Farina, E. Studer. *'Introduction to radar data processing'*, Volume I and II,
- [3] Blackman S. S. *'Multiple Target Tracking with Radar Applications'*, Artech House publishers, Dedham, Massachusetts, 1986.
- [4] N. Wax, *'Signal-to-Noise Improvement and the Statistics of Tracking Populations'*, Journal of Applied Physics, Vol. 26, pp. 586-595, May 1955.
- [5] Kalman R. E. (1960).
'A New Approach to Linear Filtering and Prediction Problems',
Journal of Basic Engineering, pp. 35-46, March 1960.
- [6] Sittler R. W. (1964).
'An Optimal Data Association Problem in Surveillance Theory',
IEEE Transaction on Military Electronics, MIL-8, pp. 125-139, April 1964.
- [7] Bar-shalom Y., and Jaffer A. (1972).
Adaptive nonlinear filtering for tracking with measurements of uncertain origin.
In Proceeding of the 1972 IEEE CDC, New Orleans, LA, pp. 243-247, December 1972.
- [8] Singer R. A., Sea R. G., and Housewright K. B. (1974).
'Derivation and evaluation of improved tracking filters for use in dense multitarget environment'.
IEEE Transaction, IT-20, 4, pp. 423-432, July 1974.
- [9] Bar-shalom Y., and Tse E. (1975)
Tracking in a cluttered environment with probabilistic data association.
Automatica, 11, pp. 451-460, September 1975.
- [10] Stein J. J., and Blackman S. S. (1975)
Generalized correlation of multi-target track data.
IEEE Transaction on Aerospace and Electronic Systems, AES-11, 6, pp. 1207-1217, November 1975.
- [11] Nagarajan V., Sharma R. N., and Chidambara M. R. (1984)
An algorithm for tracking a maneuvering target in clutter.
IEEE Transaction on Aerospace and Electronic Systems, AES-20, 5, pp. 560-573, September 1984.
- [12] Emre E., and Seo J. (1989)
A unifying approach to multi-target tracking.
IEEE Transaction on Aerospace and Electronic Systems, AES-25, July 1989.

- [13] A. M. Walton (1990)
Tracking maneuvering targets with a low probability of detection in clutter.
IEE Proceedings, Vol.137, Pt. F, N°3, pp. 183-186, June 1990.
- [14] Xie Xianya, and Evans, R.J. (1990).
Multiple target tracking using Hidden Markov Models.
IEEE 1990 International radar conference, pp. 625-628, 1990.
- [15] J. A. Roecker, G. L. Phillis (1993).
Suboptimal joint probabilistic data association.
IEEE Transaction on Aerospace and Electronic Systems, Vol. 29, No. 2, pp. 510-517, April 1993.
- [16] B. Zhou, N. K. Bose (1995).
An efficient algorithm for Data association in multitarget tracking.
IEEE Transaction on Aerospace and Electronic Systems, Vol. 29, No. 1, pp. 458-468, January 1995.
- [17] Ahmeda, S.S.; Harrison, I.; Woolfson, M.S. (1996)
Adaptive probabilistic data-association algorithm for tracking in cluttered environment
IEE Proceedings - Radar, Sonar and Navigation, Vol: 143, pp. 17-22, February 1996
- [18] Sengupta, D.; and Iltis, R. A. (1989).
'Neural solution to the multiple target tracking data association problem.'
IEEE Transaction on Aerospace and Electronic Systems, Vol. 25, pp. 96-108, January 1989.
- [19] S. V. B. Aiyer, M. Niranjana and F. Fallside (1990).
'A theoretical Investigation into the Performance of the Hopfield Model.'
IEEE Transaction on Neural Network, Vol. 1, P. 204-214, 1990.
- [20] Kim, K.; Shafai, B. (1991).
'Neural target tracking'
In Conference Proceedings of 1991 IEEE International Conference on Systems, Man, and Cybernetics, Vol. 3, Charlottesville, VA, USA, pp. 1523-1528, October 1991.
- [21] Chin, L. (1991).
'Neural Network approach in multiple target tracking'
1991 IEEE International joint Conference on Neural Conference, pp. 1220-1223, Vol. 2, Singapore, November 1991.
- [22] B. Zhou, N. K. Bose (1993).
'A comprehensive analysis of 'Neural solution to the multitarget tracking data association problem' by D. Sengupta, and R. A. Iltis (1989).'
IEEE Transaction on Aerospace and Electronic Systems, Vol. 29, No. 1, pp. 260-263, January 1993.
- [23] Wei Y., Shiyi M., Pinxing L., Shaohong L. (1994).
'Neural solution to multitarget tracking in clutter with velocity measurements'
IEEE Transaction on Aerospace and Electronic Systems, Vol. 29, No. 2, April 1993.

- [24] S. Mao, P. Lin, W. Yu (1993).
'A new insight to the ANN-based multitarget tracking data association'.
In Proceeding of the 1993 IEEE International Symposium on Circuits and Systems, New York, NY, Vol. 4, pp. 2423-2426, May 1993.
- [25] H. Leung, M. Blanchette (1994).
'Data association for multiple target tracking using Hopfield neural network'.
In Proceedings of the 1994 IEEE International Symposium on Speech, Image processing and Neural Networks, Vol. 1, Hong Kong, P. 280-283, April 1994.
- [26] F. Wang, J. Litva, T. Lo, E. Bossé (1996).
'Performance of neural data associator'.
IEE Proceedings radar, sonar and navigation, Vol. 143, N0 2, pp71-78, April 1996.
- [27] Jeanny Herault, Christian Jutten (1994)
'réseaux Neuronaux et Traitement du Signal'.
Editions Hermès, 1^{ère} édition, 1994.
- [28] Hervé Abdi (1994)
'Les réseaux de Neurones'.
Presses Universitaires de Grenoble, 1994.
- [29] S. Y. Kung (1993)
'Digital Neural Networks'.
PTR Prentice Hall, englewood Cliffs, New Jersey 07632, 1993.
- [30] H. Leung, Z. Hu, M. Blanchette (1996).
'Evaluation of multiple target track initiation techniques in real radar tracking environments'.
IEE Proceedings radar, sonar and navigation, Vol. 143, N0 4, pp. 246-254, August 1996.