

# Pistage radar à l'aide d'un réseau de neurones avec prise en compte d'attributs de plots

M. Winter<sup>(1)</sup>, V. Schmidlin<sup>(1)(2)</sup> et G. Favier<sup>(1)</sup>  
winter@alto.unice.fr

<sup>(1)</sup>Laboratoire I3S/CNRS/UNSA

250, av. Albert Einstein, Sophia-Antipolis, 06560 Valbonne

<sup>(2)</sup> SYSTELIA Technologies

6, bd Marechal Leclerc, 83320 Carqueiranne

## RÉSUMÉ

Cet article présente une extension d'une méthode neuronale de pistage permettant de prendre en compte les attributs de plots suivants : vitesse Doppler, densité de faux-échos et vraisemblance plot. Après avoir rappelé le principe de l'approche neuronale dédiée à l'affectation plot-piste, nous décrivons comment chaque attribut peut être introduit dans cette approche. Des résultats de simulations illustrent le comportement de cette nouvelle méthode neuronale de pistage.

## ABSTRACT

This paper presents an extension of a tracking neural method allowing to take into account the following plot attributes: the Doppler velocity, the plot likelihood and the density of false echoes. We first recall the principle of the neural approach dedicated to the plot-to-track association problem. Then, we explain how each attribute can be introduced in this approach. Finally, some simulation results illustrate the behaviour of this new tracking neural method.

## 1 Introduction

Le pistage multicible est un domaine de recherche qui fait l'objet de nombreuses études depuis une dizaine d'années. L'introduction d'informations supplémentaires, par l'intermédiaire des attributs des plots, ouvre de nouvelles perspectives, et ne peut qu'augmenter les performances d'un système de pistage. Les attributs considérés dans cet article sont les suivants :

- **la vitesse Doppler** : estimée à partir de la fréquence Doppler de chaque détection élémentaire constituant le plot.
- **la densité de faux échos  $\Phi_i$**  : estimée à l'aide du nombre de faux échos présents dans le voisinage du plot  $i$ .
- **la vraisemblance plot** d'un plot  $i$  : estimée à partir de la probabilité *a posteriori*  $P(H_i|z_i)$  pour que l'hypothèse "le plot  $i$  est un écho provenant d'une cible" soit correcte, connaissant la mesure  $z_i$  issue du capteur.

Après avoir rappelé, dans le paragraphe 2, le principe de l'approche neuronale que nous avons développée pour résoudre le problème de l'affectation plot-piste [4, 5], nous décrivons, dans le paragraphe 3, comment chacun de ces attributs peut être introduit dans cette approche. Le paragraphe 4 présente quelques résultats de simulation permettant d'illustrer le fonctionnement de la nouvelle méthode neuronale de pistage proposée, et de montrer l'amélioration des performances apportée par la prise en compte des

attributs de plots. Le paragraphe 5 conclut cet article en décrivant quelques perspectives de recherche.

## 2 Le pistage neuronal

Un capteur radar délivre à chaque tour d'antenne un ensemble d'échos (appelés plots) dont certains sont susceptibles de représenter des cibles. En effet, chaque objet présent dans l'espace d'observation ne donne pas forcément lieu à un écho (on parle dans ce cas de *non-détection*) et chaque plot ne correspond pas forcément à un objet à détecter (on parle alors de *faux-écho*). Le pistage consiste à corrélérer temporellement ces informations de façon à décrire les pistes des cibles détectées dans l'espace d'observation. Dans cet article, on s'intéresse plus particulièrement au problème de l'association plot-piste, qui consiste à associer au mieux les plots du tour d'antenne courant  $k$  aux positions prédites des pistes obtenues au tour d'antenne précédent ( $k - 1$ ). On parle aussi d'affectation plot-piste ou d'entretien de piste. Ces associations plot-piste sont généralement décidées de manière à maximiser un critère de vraisemblance globale. Dans le cas d'un vecteur de mesure de dimension 2, et sous l'hypothèse gaussienne, la vraisemblance  $g_{x,i}$  associée à l'affectation du plot  $i$  avec la piste  $x$  est égale à [1] :

$$g_{xi} = \frac{1}{2\pi\sqrt{|S_x|}} e^{-\frac{\rho_{xi}}{2}} \quad (1)$$

Où  $|S_x|$  représente le déterminant de la matrice de covariance de l'innovation relative à la piste  $x$ , délivrée par un filtre de Kalman, et  $\rho_{xi}$  correspond à la distance statistique  $\rho_{xi} = \nu_{xi}^t S_x^{-1} \nu_{xi}$ ,  $\nu_{xi}$  étant l'erreur de prédiction (innovation) calculée comme la différence entre la position du plot  $i$  et la position prédite de la piste  $x$ . Définissant la quantité  $D_{xi}$  comme le logarithme népérien de  $g_{xi}$  à une constante près :

$$-D_{xi} = \rho_{xi} + \ln |S_x| \quad (2)$$

le problème d'association revient alors à minimiser la somme des  $D_{xi}$  sous la contrainte d'avoir une affectation par plot et par piste au maximum.

Ce problème a déjà été longuement étudié en recherche opérationnelle où il est appelé *problème d'affectation*. Différents algorithmes optimaux existent ; le plus rapide, développé par Burgeois et Lassalle [2], nécessite un temps de calcul proportionnel à la taille du problème élevée au cube. On peut remarquer que ce problème ne fait pas partie des problèmes d'optimisation combinatoire les plus complexes, qualifiés de *NP-complet*, pour lesquels il n'existe pas de solution en un temps polynomial.

Bien qu'il ne s'agisse pas d'un problème *NP-complet*, le calcul de la solution optimale peut être quelquefois trop coûteux pour des applications en temps réel. L'utilisation des réseaux de neurones offre une alternative intéressante ; en effet, les réseaux neuronaux fournissent des solutions très proches de la solution optimale, sans toutefois la garantir, pour un coût calculatoire raisonnable.

Ainsi, dans un premier temps, nous avons utilisé un réseau de Hopfield [3] pour réaliser cette optimisation, en faisant correspondre un neurone à chaque association possible : le neurone  $xi$ , d'état  $V_{xi}$ , symbolise l'association potentielle de la piste  $x$  et du plot  $i$ . A la convergence du réseau,  $V_{xi} = 1$  signifie que le réseau a décidé d'affecter le plot  $i$  à la piste  $x$  et  $V_{xi} = 0$  correspond à une non-association. La mise-à-jour de l'état des neurones s'effectue de la manière suivante :

$$V_{xi}(t+1) = \left[ \frac{D_{max} - D_{xi}}{D_{max}} \right] - A \sum_{j \neq i} f(V_{xj}(t)) - B \sum_{y \neq x} f(V_{yi}(t)) \quad (3)$$

Où :

- $D_{max}$  représente la valeur maximale que peut prendre  $D_{xi}$  au tour d'antenne courant
- $f$  désigne la fonction sigmoïde
- $t$  représente le numéro de l'itération relative à l'optimisation à l'aide du réseau de neurone.

$A$  et  $B$  sont deux paramètres de réglage de la méthode.

Le premier terme du second membre de l'équation (3) est associé à la minimisation du critère de vraisemblance, tandis que les second et troisième termes sont introduits pour la prise en compte des contraintes. Cette approche possède un inconvénient majeur lié au choix des paramètres  $A$  et  $B$  qui pondèrent l'influence des contraintes durant la convergence du réseau. L'introduction de ces paramètres, qui doivent être ajustés expérimentalement, entraîne une sensibilité du réseau à la taille du problème et à la distribution des données  $D_{xi}$ . Ceci signifie qu'il est nécessaire de modifier la valeur de ces paramètres si la taille du problème ou la distribution des distances  $D_{xi}$  change de manière significative entre deux utilisations successives, sous peine de voir se dégrader les performances de ce modèle. Pour pallier ces inconvénients, nous avons développé un nouveau modèle neuronal, spécialement dédié au problème de l'affectation. Une application au pistage monocapteur classique, *i.e.* sans prise en compte des attributs des plots, a été effectuée [5] en utilisant l'équation de mise-à-jour suivante :

$$V_{xi}(t+1) = [D_{max} - D_{xi}] - \max_o [D_{max} - D_{oi}] \max_{o \neq x} [f(V_{oi}(t))] - \max_p [D_{max} - D_{xp}] \max_{p \neq i} [f(V_{xp}(t))] \quad (4)$$

Le remplacement de l'opérateur  $\sum$  dans l'équation (3) par l'opérateur  $\max$  dans l'équation (4) permet de réduire l'influence de la taille du réseau sur l'évolution de l'état de chaque neurone. Chaque neurone est ainsi inhibé par les sorties des deux neurones les plus activés, et ce, quelle que soit la taille du réseau. De plus, l'introduction de l'opérateur  $\max$  permet de déterminer des valeurs analytiques pour les paramètres  $A$  et  $B$ , valeurs qui garantissent le respect des contraintes. Nous présentons, dans le paragraphe suivant, une extension de cette approche neuronale qui permet la prise en compte des attributs des plots définis dans la section 1.

### 3 Introduction des attributs des plots

Les trois attributs considérés, de nature très différente, sont intégrés à la méthode neuronale de pistage de la manière suivante :

#### 3.1 Introduction de la vitesse Doppler

La vitesse Doppler est prise en compte au niveau du filtre de Kalman comme une mesure supplémentaire de l'état de la cible. L'expression de la vraisemblance devient alors :

$$g_{xi} = \frac{1}{(2\pi)^{3/2} \sqrt{|S_x|}} e^{-\frac{\rho_{xi}}{2}} \quad (5)$$

le calcul de la distance statistique  $\rho_{xi}$  prenant maintenant en compte la vitesse Doppler.

### 3.2 Introduction de la vraisemblance plot

Nous avons choisi d'intégrer directement cet attribut dans le critère à optimiser. Le choix des affectations se fait alors en fonction de la vraisemblance de chaque affectation et de la vraisemblance du plot associé. L'expression de  $D_{xi}$  devient :

$$-D_{xi} = \rho_{xi} + \ln |S_x| + \ln [P(H_i|z_i)] \quad (6)$$

### 3.3 Introduction de la densité de faux échos

Il convient tout d'abord de définir de quelle manière la densité de faux échos influence le pistage. Une stratégie consiste à favoriser une association dans une zone à faible densité de faux échos, et inversement. Le réseau de neurones nous permet de mettre en œuvre cette stratégie, sans pour autant avoir à modifier le critère à optimiser défini précédemment. En effet, on sait qu'un réseau du type Hopfield est un système qui converge généralement vers le premier minimum local rencontré de son énergie. L'initialisation du réseau, généralement aléatoire, permet de positionner le système non loin d'un minimum acceptable du critère. En modifiant cette initialisation à l'aide de l'attribut '*densité de faux échos*', on influence la convergence du réseau. L'intégration de cet attribut nécessite de modifier légèrement notre modèle (*i.e.* équation (4)); l'évolution de l'état de chaque neurone est maintenant dictée par les équations suivantes :

$$V_{xi}(0) = \left[ \frac{\Phi_{max} - \Phi_i}{\Phi_{max}} \right] \quad (7)$$

$$\begin{aligned} V_{xi}(t+1) = & (1 - \alpha)V_{xi}(t) + \alpha (D_{max} - D_{xi}) \\ & - \max_o [D_{max} - D_{oi}] \max_{o \neq x} f(V_{oi}(t)) \\ & - \max_p [D_{max} - D_{xp}] \max_{p \neq i} f(V_{xp}(t)) \end{aligned} \quad (8)$$

où  $\Phi_{max}$  désigne la valeur maximale que peut prendre  $\Phi_i$  au tour d'antenne courant et  $\alpha$  correspond à un facteur d'oubli.

## 4 Simulations

Nous avons intégré cette méthode neuronale de pistage avec attributs dans un logiciel de pistage développé au

laboratoire I3S. La figure 1 montre la simulation de neuf pistes.

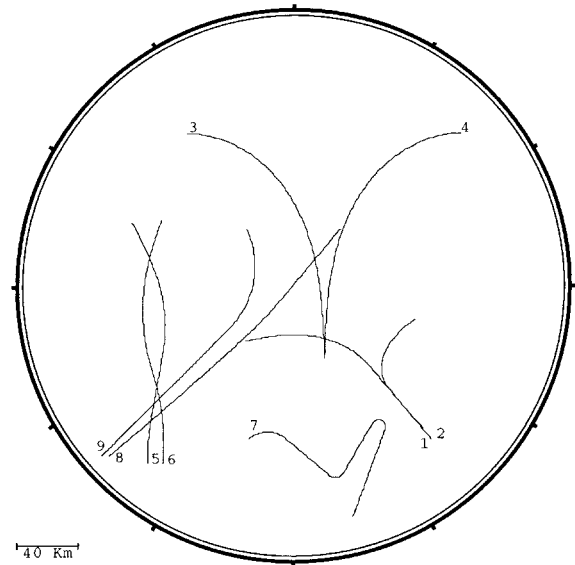


FIG. 1: Trajectoires générées

Un générateur de plots radar a ensuite été utilisé pour simuler un capteur radar 2D avec les caractéristiques suivantes :

- écart-type du bruit en distance : 150m
- écart-type du bruit en azimut : 0.007rd
- probabilité de détection : 0.85
- portée du capteur : 150km

Une zone à forte densité de faux échos a été simulée au dessus de la zone de croisement des pistes 5, 6, 8 et 9, pour mettre en évidence l'apport de l'attribut densité de faux échos au niveau du pistage. Des simulations de type Monte-Carlo (avec 50 séquences de bruit différentes) ont été effectuées. Les figures 2 et 3 illustrent les résultats du pistage respectivement sans prise en compte et avec prise en compte des attributs des plots, pour une séquence de bruit particulière.

L'analyse de ces figures montre que l'utilisation des attributs des plots permet une amélioration très significative du pistage dans les zones à forte densité de faux échos.

Pour comparer de façon quantitative les performances du pistage, nous avons considéré les critères suivants, évalués par un moyennage sur les cinquante simulations réalisées :

- **Le pourcentage de cible pistée** (% pistée), calculé comme le rapport entre la longueur d'une trajectoire d'une cible et la longueur de la trajectoire estimée correspondante,
- **Le nombre de rupture** (*Nb Rupt*), *i.e.* le nombre de fois qu'une piste associée à une cible est interrompue,
- **Le retard à l'initialisation** (*Ret Init*), *i.e.* le nombre de tours d'antenne séparant l'apparition d'une cible et l'initialisation de la piste correspondante,
- **L'écart moyen** (*Err Moy*, mesurée en *m*) entre une

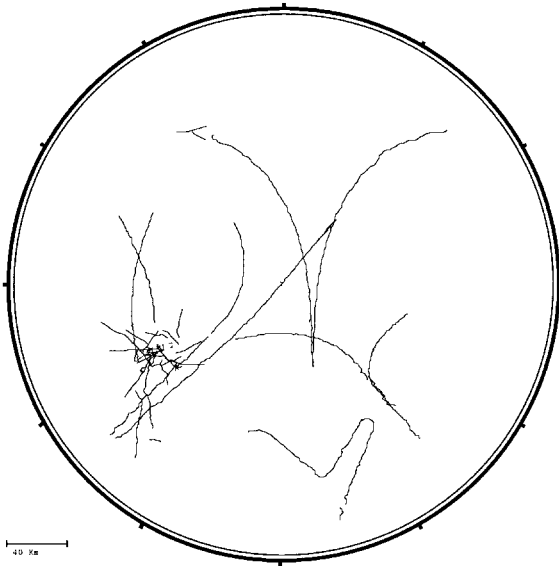


FIG. 2: Résultat du pistage à l'aide de la méthode neuronale sans prise en compte des attributs

trajectoire de cible, et la piste correspondante,

Les tableaux 1 et 2 contiennent les valeurs des critères de performance obtenues en utilisant la méthode neuronale de pistage sans et avec prise en compte des attributs, respectivement.

cibles	% pistée	Nb Rupt	Ret Init	Err Moy
5	86.2	3.35	3.71	513
6	90.8	2.92	2.61	499
8	88.7	3.45	2.41	429
9	93.6	2.73	3.67	398

TAB. 1: Performances de la méthode neuronale sans attributs

cibles	% pistée	Nb Rupt	Ret Init	Err Moy
5	90.1	1.78	2.98	543
6	94.2	1.32	2.08	532
8	91.3	3.2	3.78	423
9	94.5	2.6	2.36	471

TAB. 2: Performances de la méthode neuronale avec attributs

On constate que l'utilisation des attributs permet d'améliorer les performances du pistage relatives aux trois premiers critères. Cependant, l'erreur moyenne entre la position estimée et la position réelle des cibles (critère 4) augmente lorsqu'on prend en compte les attributs. Ces résultats pourraient s'interpréter par une mauvaise estimation de l'attribut vraisemblance plot.

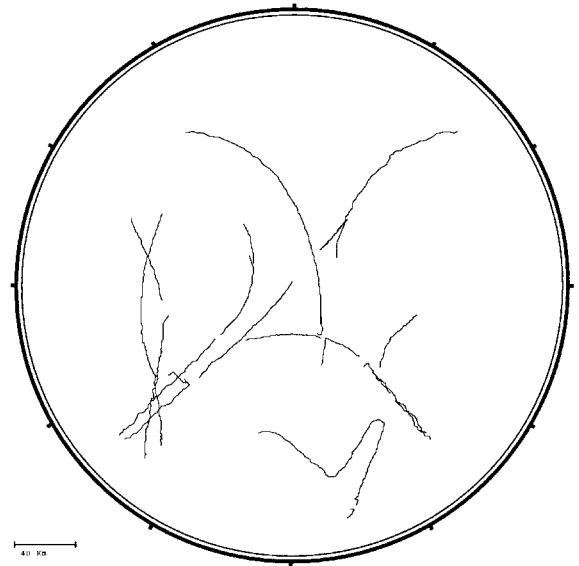


FIG. 3: Résultat du pistage à l'aide de la méthode neuronale avec prise en compte des attributs

## 5 Conclusions et perspectives

Une nouvelle méthode neuronale de pistage monocapteur intégrant des attributs des plots a été proposée dans cet article. Des résultats de simulation ont permis d'illustrer le bon comportement de cette méthode et les améliorations de performance qu'elle apporte par rapport à une solution sans prise en compte des attributs. Des études vont être menées pour évaluer la contribution de chaque attribut et essayer de les prendre en compte de façon la plus efficace possible. Des comparaisons seront également réalisées avec les méthodes classiques de pistage (plus proche voisin, filtre à association probabiliste de données...), sans et avec prise en compte de ces mêmes attributs.

## Références

- [1] S. Blackman. *Multiple-Target Tracking with Radar Applications*. Artech House, 1986.
- [2] F. Burgeois and J.C. Lassalle. *An extension of the Munkres algorithm for the assignment problem to rectangular matrices*. Communications of the ACM, vol. 14, pages 802-806, Décembre 1971.
- [3] J. J. Hopfield. *Neural computation of decisions in optimization problems*. Biological Cybernetics, vol. 52, pages 141-152, 1985.
- [4] V. Schmidlin. *Poursuite multicible multicapteur à l'aide de réseaux neuronaux*. Thèse de l'Université de Nice Sophia-Antipolis, Novembre 1994.
- [5] M. Winter, V. Schmidlin, and G. Favier. *Neural networks for tracking initiation and maintenance*. SPIE AeroSense'97, vol. 3086-20, Orlando, USA, Avril 1997.