



GONIOMETRIE AU SENS DU MAXIMUM DE VRAISEMBLANCE PAR METHODES CONNEXIONNISTES (1)

*P. MARTIN * ET P. LARZABAL *†*

* THOMSON-CSF, Division RGS, Service Traitement du Signal, 66 rue du Fossé Blanc, 92231 Gennevilliers
† LESIR, URA CNRS n°1375, Ecole Normale Supérieure de Cachan, 61 avenue du Président Wilson, 94235 Cachan Cedex.

RESUME

La méthode du Maximum de Vraisemblance est une méthode quasi-optimale d'estimation de la direction d'arrivée de sources bande étroite par un réseau de capteurs. Pourtant, du fait de sa complexité, elle reste peu appliquée. D'autre part, compte-tenu des progrès effectués dans la technologie VLSI, l'intérêt dans l'emploi des réseaux de neurones s'est récemment développé. L'objectif de cet article est d'appliquer un réseau de neurones adaptatif à la méthode du Maximum de Vraisemblance.

SUMMARY

The Maximum Likelihood Method is a quasi-optimal method for the estimation of the directions-of-arrival of narrow-band sources by a passive array of sensors. However, it hasn't been applied, because of its high computational load. With the current advances in VLSI technology, the interest in the use of neural networks has recently grown. The goal of this paper is to show an adaptative neural method for Maximum Likelihood bearing estimation.

I. INTRODUCTION

La goniométrie est une partie importante du traitement d'antenne, que ce soit en radio, sonar ou radar. Le problème consiste en l'estimation d'angles d'arrivée (site, gisement) de sources bande étroite, localisées dans le champ lointain d'un réseau de capteurs dont on connaît la structure géométrique et les diagrammes de rayonnement. Les méthodes employées sont soit sous-optimales, mais simples à mettre en oeuvre (formation de voies, méthodes haute résolution : MUSIC, ESPRIT,...), soit plus performantes, mais très coûteuses en temps de calcul (méthode du W.S.F. ou du Maximum de Vraisemblance). Ces dernières méthodes nécessitent une optimisation non linéaire et multidimensionnelle, qui rend impossible toute application temps réel. Pourtant, elles présentent l'intérêt de détecter des sources proches et corrélées pour une structure de réseau quelconque.

Les réseaux de neurones peuvent être un moyen d'alléger le coût en calculs d'algorithmes tels que le Maximum de Vraisemblance. En effet, comme l'ont montré Hopfield et Tank [1], les réseaux entièrement interconnectés peuvent résoudre des problèmes d'optimisation combinatoire complexes, tels que le problème du voyageur de commerce ou du bibliothécaire.

Après avoir présenté la structure et les propriétés des réseaux de Hopfield dans la partie II, nous reformulons le problème de la goniométrie tout en donnant les hypothèses de travail en III. Puis, à partir des conclusions tirées de l'état de l'art de l'approche connexionniste (partie IV), nous proposons deux nouveaux algorithmes en V. Des résultats de simulation sont proposés en VI et nous concluons sur les perspectives de l'approche connexionniste du traitement d'antennes.

II. RESOLUTION D'UN PROBLEME D'OPTIMISATION PAR UN RESEAU DE HOPFIELD

Un réseau de Hopfield est un réseau de P cellules élémentaires non linéaires complètement interconnectées par un ensemble de

poids synaptiques : la connexion entre la sortie du neurone j et l'entrée du neurone i est affectée d'une pondération T_{ij} . De plus, chaque neurone i comporte une entrée spécifique I_i . L'évolution dynamique d'un tel système est donnée par le système d'équations différentielles suivant pour $i=1, \dots, P$:

$$\frac{\partial U_i}{\partial t} = \sum_{j=1}^P T_{ij} V_j(t) + I_i$$

$$V_i(t) = f(U_i(t))$$

où $U_i(t)$ représente l'état interne du neurone et $V_i(t)$ sa sortie. La fonction de transfert ou d'activation f de chaque neurone est habituellement une fonction sigmoïde.

Hopfield et Tank [1] ont associé à ce réseau la fonction d'énergie de Lyapunov suivante :

$$E(t) = -\frac{1}{2} \sum_{i=1}^P \sum_{j=1}^P T_{ij} V_i(t) V_j(t) - \sum_{i=1}^P I_i V_i(t)$$

On peut alors montrer aisément que :

$$\frac{\partial E}{\partial t} = - \sum_{i=1}^P \frac{\partial f(U_i)}{\partial U_i} \cdot \left(\frac{\partial U_i}{\partial t} \right)^2$$

Si la fonction d'activation du neurone est monotone croissante, le réseau évolue vers un état d'énergie plus faible jusqu'à ce qu'un état stable soit atteint.

Cependant, la convergence vers un minimum global ne peut être garantie. De plus, comme le réseau évolue dans l'hypercube de dimension P, il peut converger vers un minimum local contenu à l'intérieur de cet hypercube. Afin d'obtenir un état final binaire, on peut imposer que $\partial E / \partial V_i$ soit de signe constant. Une condition nécessaire, mais non suffisante, de convergence vers un coin de l'hypercube unité est donc $T_{ii} = 0$.

Un réseau de neurones totalement interconnectés de matrice de poids synaptiques $T = (T_{ij})$ et $I = (I_i)$ évolue donc en cherchant un minimum local de la fonction de Lyapunov E. La résolution d'un problème d'optimisation d'une forme quadratique Q donnée est la formulation duale du raisonnement ci-dessus : il s'agit de calculer l'architecture (T, I) du réseau en identifiant l'énergie de Lyapunov à

(1) Cette étude a été menée dans le cadre du contrat DRET n°90/324.



la forme quadratique Q . Une correspondance est alors établie entre les solutions du problème et les états du réseau.

Un réseau de Hopfield tel qu'il vient d'être défini converge vers un minimum local de l'énergie de Lyapunov. Pour augmenter la probabilité de convergence vers le minimum global, on peut employer un modèle stochastique, dont la dynamique est [9]:

$$\frac{\partial U_i}{\partial t} = \sum_{j=1}^N T_{ij} V_j + I_i + n_i(t)$$

où $n_i(t)$ est un bruit blanc de variance proportionnelle au cosinus hyperbolique de l'état interne. Cette stratégie présente pourtant deux inconvénients: un temps de convergence plus long et l'introduction d'un nouveau paramètre, appelé température de diffusion, dont le réglage (loi de décroissance dans le temps) est difficile à effectuer. Dans la suite de l'article, nous retiendrons un modèle de neurones analogiques.

III. TRAITEMENT D'ANTENNE: FORMULATION DU PROBLEME

Considérons un réseau de N capteurs pouvant recevoir les émissions de M sources bance étroite de longueur d'onde λ . L'enveloppe complexe des échantillons reçus peut se mettre sous la forme :

$$\begin{aligned} \underline{X}(t) &= \mathbf{A}(\underline{\theta}) \cdot \underline{S}(t) + \underline{B}(t) \\ &= \sum_{m=1}^M s_m(t) \cdot \underline{a}(\theta_m) + \underline{B}(t) \end{aligned}$$

Le problème consiste en l'estimation du vecteur azimut $\underline{\theta} = (\theta_1, \dots, \theta_M)^T$ à partir des T observations correspondant à des réalisations indépendantes de $\underline{B}(t)$. Les signaux sources $s_m(t)$ seront considérés comme des paramètres déterministes inconnus. Si l'on suppose le bruit complexe, gaussien, stationnaire de moyenne nulle et de variance $\sigma^2 I$, les échantillons $\underline{X}(t)$ suivent alors une loi gaussienne de moyenne $\mathbf{A}(\underline{\theta}) \cdot \underline{S}(t)$ et de variance $\sigma^2 I$. A partir de la densité de probabilité conjointe des échantillons, la log-vraisemblance est alors donnée par

$$LV(\underline{\theta}, \sigma^2, \underline{S}) = -NT \log \sigma^2 - \frac{1}{\sigma^2} \sum_{t=1}^T |\underline{X}(t) - \mathbf{A}(\underline{\theta}) \cdot \underline{S}(t)|^2$$

Estimer le triplet $(\underline{\theta}, \sigma^2, \underline{S})$ au sens du maximum de vraisemblance revient à maximiser LV . Une optimisation séparée par rapport à la variance du bruit, puis par rapport aux amplitudes donne une log-vraisemblance réduite que l'on peut écrire

$$\begin{aligned} LV(\underline{\theta}) &= - \sum_{t=1}^T |\underline{X}(t) - P_{\Lambda(\underline{\theta})} \underline{X}(t)|^2 \\ &= \text{tr} (P_{\Lambda(\underline{\theta})} \widehat{R}_X) \end{aligned}$$

où $P_{\Lambda(\underline{\theta})}$ est la matrice de projection sur l'espace engendré par les colonnes de $\mathbf{A}(\underline{\theta})$ (projecteur sur l'espace signal):

$$P_{\Lambda(\underline{\theta})} = \mathbf{A}(\underline{\theta}) (\mathbf{A}^\dagger(\underline{\theta}) \mathbf{A}(\underline{\theta}))^{-1} \mathbf{A}^\dagger(\underline{\theta})$$

et \widehat{R}_X est la matrice de covariance de l'observation :

$$\widehat{R}_X = \frac{1}{T} \sum_{t=1}^T \underline{X}(t) \underline{X}^\dagger(t)$$

La maximisation de LV est un problème non linéaire à M dimensions: sa résolution est d'une grande complexité. L'algorithme de Ziskind et Wax [2] semble être le plus utilisé actuellement. Son principe est le suivant: à chaque itération, on fixe $M-1$ directions et on optimise le critère par rapport à une seule direction; à l'itération suivante, on change la direction dans laquelle on maximise L , jusqu'à l'obtention du maximum. L'optimisation multidimensionnelle est ainsi ramenée à plusieurs optimisations monodimensionnelles consécutives.

Plusieurs autres algorithmes ont été proposés jusqu'à présent : algorithme IQML de Brester et Macovski [3], algorithme de Weiss, Willisky et Levy [4], mais ils sont relativement longs à converger quand M augmente.

IV. APPROCHE CONNEXIONNISTE

Pour pouvoir utiliser un réseau de Hopfield, il faudrait identifier la log vraisemblance LV à l'énergie de Lyapunov E du réseau. Dans [5], Rastogi et al propose d'associer à chaque neurone une combinaison amplitude, phase et fréquence spatiale et de former une matrice de solutions possibles $[\underline{Y}_1 \underline{Y}_2 \dots \underline{Y}_P]$ où la colonne Y_i représente un échantillon "type" correspondant à une combinaison donnée (amplitude, phase, azimut). Le critère utilisé est alors le suivant:

$$Q = \sum_{t=1}^T |\underline{X}(t) - [\underline{Y}_1 \underline{Y}_2 \dots \underline{Y}_P] \cdot \underline{V}|^2$$

\underline{V} étant le vecteur formé des sorties des neurones. Lorsque le réseau aura convergé vers un état stable, on aura trouvé la somme d'échantillons type qui approche le mieux $\underline{X}(t)$ au sens des moindres carrés. Cette approche présente deux inconvénients majeurs: le nombre de neurones élevé et une quantification inutile de l'amplitude et de la phase des signaux sources. Pour éviter ceci, nous allons associer à chaque direction possible un neurone, qui si il est activé (sortie V_i égale à 1) indiquera la présence d'une source dans cette direction. Dans cette optique, comme on cherche à identifier le critère d'estimation à une forme quadratique binaire, il doit pouvoir s'écrire :

$$\min_{i,j} \sum_{i,j} f_{ij}(\theta_i, \theta_j) + \sum_i g_i(\theta_i)$$

pour pouvoir créer une énergie de Lyapunov de la forme:

$$E = -\frac{1}{2} \sum_{i=1}^P \sum_{j=1}^P f_{ij}(\theta_i, \theta_j) V_i V_j - \sum_{i=1}^P g_i(\theta_i) V_i$$

Lorsque le réseau aura atteint un état stable correspondant à un minimum de la forme quadratique, les neurones dont la sortie est égale à 1 donnent les angles d'arrivée des sources (minimum du critère d'estimation). C'est pour cette raison que Rastogi et al propose dans [5] de minimiser l'erreur suivante:

$$LV2(\underline{\theta}) = \sum_{t=1}^T \left| \underline{X}(t) - \sum_{i=1}^M P_{\underline{a}(\theta_i)} \underline{X}(t) \right|^2$$

$P_{\underline{a}(\theta_i)}$ est la matrice de projection sur le vecteur directionnel $\underline{a}(\theta_i)$ ($i^{\text{ème}}$ colonne de $\mathbf{A}(\underline{\theta})$). La forme quadratique à minimiser par le réseau de neurones s'écrit donc :

$$LV2(\underline{\theta}) = \sum_{t=1}^T |\underline{X}(t) - [P_{\underline{a}(\theta_1)} \underline{X}(t) \dots P_{\underline{a}(\theta_P)} \underline{X}(t)] \underline{V}(t)|^2$$

L'identification de L avec l'énergie d'un réseau de Hopfield donne l'expression des poids synaptiques suivants:

$$\begin{aligned} T_{ij} &= -2 \text{Real} \left(\frac{1}{T} \sum_{t=1}^T \underline{X}^\dagger(t) \cdot P_{\underline{a}(\theta_i)} \cdot P_{\underline{a}(\theta_j)} \cdot \underline{X}(t) \right) \\ I_i &= \text{Real} \left(\frac{1}{T} \sum_{t=1}^T \underline{X}^\dagger(t) \cdot P_{\underline{a}(\theta_i)} \cdot \underline{X}(t) \right) \end{aligned}$$

L'estimation utilisée par Rastogi n'est donc pas équivalente à celle du maximum de vraisemblance donnée dans la partie III, car, dans le cas général, la projection sur l'espace engendré par les colonnes de $\mathbf{A}(\underline{\theta})$ est différente de la somme des projections sur chaque vecteur directionnel $\underline{a}(\theta_i)$. L'identification de LV et de $LV2$ nous montre qu'il n'y a équivalence que dans les 2 cas suivants:

- présence d'une seule émission,
- orthogonalité des vecteurs directionnels.

Pour une structure antennaire quelconque, le diagramme d'ambiguïté du réseau montre clairement que ce critère n'atteint pas les performances du maximum de vraisemblance (surtout pour un faible nombre de capteurs) et ne peut être utilisé pour obtenir une estimation précise de la position des sources. Les autres articles parus sur le sujet ([6], [7] et [8]) proposent quelques améliorations des propriétés de convergence des réseaux de Hopfield mais ne remettent pas en cause le critère d'estimation employé par Rastogi et al. C'est pourquoi nous allons proposer deux modifications du critère implanté sur le réseau de neurones et les comparer avec celui de Rastogi, pour un même modèle neuronal.



V. NOUVEL ALGORITHME NEURONAL ADAPTATIF A PLUSIEURS NIVEAUX

Construction du réseau

Le but de l'utilisation des réseaux de neurones est l'obtention d'un algorithme rapide et performant permettant de positionner des sources proches et corrélées avec une antenne de géométrie quelconque. Pour cela, le nombre de neurones du réseau doit être le plus faible possible. Nous allons donc adapter une architecture neuronale à plusieurs niveaux (figure 1):

- balayage de l'espace avec un écart angulaire élevé entre 2 neurones consécutifs. Son but est surtout la détection de sources et une estimation grossière de leurs positions. On peut utiliser pour cela l'algorithme de Rastogi.

- focalisation autour de chacune des sources détectées: pour cela, il faut modifier le critère d'estimation en nous ramenant au cas où le critère employé par Rastogi est équivalent au maximum de vraisemblance. Nous proposons pour ce faire 2 algorithmes qui nous y ramènent.

Algorithme avec orthonormalisation du réseau

Nous allons utiliser l'estimation des angles d'arrivée donnée par la première étape pour modifier le critère d'estimation en orthonormalisant les vecteurs directionnels.

Pour M sources on peut définir des vecteurs directionnels "virtuels" $\underline{\alpha}(\theta_i)$ par les formules récurrentes suivantes:

$$\underline{\alpha}(\theta_1) = \underline{a}(\theta_1)$$

et pour $1 < i \leq M$:

$$\begin{aligned} \underline{\alpha}(\theta_i) &= \left(\prod_{j < i} P_{\underline{\alpha}(\theta_j)}^\dagger \right) \cdot \underline{a}(\theta_i) \\ &= \left(\prod_{j < i} (I - P_{\underline{\alpha}(\theta_j)}) \right) \cdot \underline{a}(\theta_i) \end{aligned}$$

La log-vraisemblance s'écrit alors:

$$LV(\underline{\theta}) = - \sum_{t=1}^T \left| \underline{X}(t) - \sum_{j=1}^M P_{\underline{\alpha}(\theta_j)} \underline{X}(t) \right|^2$$

On peut alors l'optimiser par un réseau de Hopfield d'une manière similaire à l'algorithme de Rastogi en utilisant les résultats de la 1^{ère} étape pour calculer les vecteurs $\underline{\alpha}(\theta_i)$. La nouvelle expression des poids synaptiques est alors:

$$\begin{aligned} T_{ij} &= -2 \operatorname{Real} \left(\frac{1}{T} \sum_{t=1}^T \underline{X}^\dagger(t) \cdot P_{\underline{\alpha}(\theta_i)} \cdot P_{\underline{\alpha}(\theta_j)} \cdot \underline{X}(t) \right) \\ I_i &= \operatorname{Real} \left(\frac{1}{T} \sum_{t=1}^T \underline{X}^\dagger(t) \cdot P_{\underline{\alpha}(\theta_i)} \cdot \underline{X}(t) \right) \end{aligned}$$

Un des avantages de ce réseau est qu'à chaque convergence du réseau, nous avons une estimation du vecteur $\underline{\theta}$, alors que, par exemple, l'algorithme des projections alternées de Wax et Ziskind ne donne à chaque itération que l'estimation de l'azimut d'une seule source. L'utilisation de réseau de neurones permet donc une optimisation multidimensionnelle.

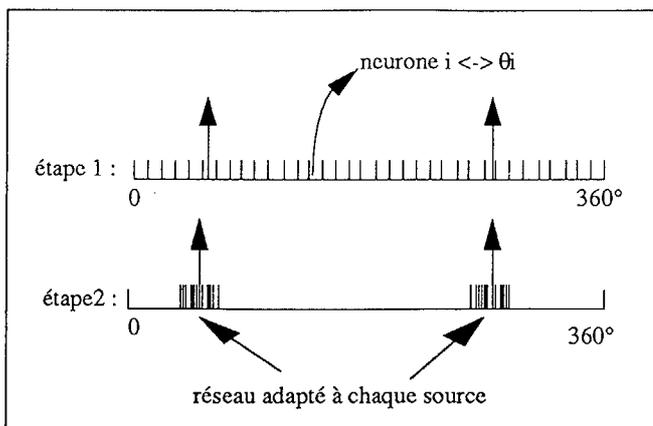


fig 1 : architecture du réseau adaptatif

Algorithme avec estimation du signal source

A partir des estimations des angles d'arrivées de la première étape, nous allons extraire la contribution de la k^{ème} source dans $\underline{X}(t)$. Nous pouvons alors écrire:

$$\underline{\tilde{X}}^{(k)}(t) = \underline{X}(t) - A(\underline{\theta}) \cdot \underline{S}^{(k)}(t)$$

$\underline{S}^{(k)}(t)$ est égal à $\underline{S}(t)$ avec la k^{ème} composante nulle. L'estimation de l'azimut θ_k de la k^{ème} source s'effectue par maximisation de la vraisemblance.

$$LV_k = - \sum_{t=1}^T \left| \underline{\tilde{X}}^{(k)}(t) - P_{\underline{a}(\theta_k)} \underline{\tilde{X}}^{(k)}(t) \right|^2$$

La matrice de poids synaptiques a alors la forme suivante:

$$T = \begin{bmatrix} T^{(1)} & \dots & \dots & 0 & \dots & \dots & 0 \\ 0 & \dots & \dots & T^{(k)} & \dots & \dots & 0 \\ 0 & \dots & \dots & 0 & \dots & \dots & T^{(M)} \end{bmatrix}$$

$$I = \begin{bmatrix} I^{(1)} \\ \vdots \\ I^{(k)} \\ \vdots \\ I^{(M)} \end{bmatrix}$$

où la sous-matrice associée à la source k est définie par

$$T_{ij}^{(k)} = -2 \operatorname{real} \left(\frac{1}{T} \sum_{t=1}^T \underline{\tilde{X}}^{(k)\dagger}(t) \cdot P_{\underline{a}(\theta_i)} P_{\underline{a}(\theta_j)} \underline{\tilde{X}}^{(k)}(t) \right)$$

$$I_i^{(k)} = \operatorname{real} \left(\frac{1}{T} \sum_{t=1}^T \underline{\tilde{X}}^{(k)\dagger}(t) \cdot P_{\underline{a}(\theta_i)} \underline{\tilde{X}}^{(k)}(t) \right)$$

Comparaison des 2 algorithmes

Les 2 nouveaux critères ont été proposés pour se rapprocher le plus possible du Maximum de Vraisemblance. Ils exploitent les deux cas où le traitement de Rastogi est optimal: orthogonalité des vecteurs directionnels et une seule source. La première modification permet une meilleure utilisation des propriétés des réseaux de Hopfield (optimisation multidimensionnelle), alors que la seconde est plus simple, car ramenée à des optimisations monodimensionnelles parallèles, mais dépend plus de l'estimation de l'étape précédente.

VI. RESULTATS DE SIMULATION

Hypothèses

Nous avons pris P=21 neurones sur $[0,60^\circ]$, soit un écart de 3° entre 2 neurones consécutifs et M=2 sources. A la 2^{ème} étape, autour de chaque source, nous prendrons $P_2 = 11$ neurones espacés de $0,3^\circ$. Les 2 émissions seront situées en $11^\circ 7'$ et $48^\circ 6'$ pour correspondre précisément à 2 neurones. Le réseau de neurones que nous avons simulé est un réseau de Hopfield analogique déterministe. La fonction d'activation des neurones est une fonction sigmoïde dont la température est égale à 5:

$$V_i = f(U_i) = \frac{1}{1 + \exp(-U_i/5)}$$

La valeur de température que nous avons retenue n'est qu'heuristique, en fait son choix est délicat quant à la qualité de la convergence. Le système d'équations obtenu est résolu par une intégration de Runge-Kutta-Fehlberg d'ordre 4. Deux étapes de focalisation ont été effectuées pour ne privilégier aucune source: en effet, pour l'algorithme avec orthonormalisation du réseau, le vecteur de base de la procédure d'orthonormalisation de Gram-Schmidt est $\underline{a}(\theta_1)$ pour la première convergence et $\underline{a}(\theta_2)$ pour la seconde.



Résultats pour des émissions non corrélées

L'estimation s'effectue sur 10 échantillons. Les biais et variances sont calculés à partir de 100 réalisations indépendantes. Les performances des trois algorithmes ont été évaluées en calculant l'erreur quadratique moyenne donnée par :

$$\text{M.S.E.} = \frac{\sigma_1^2 + \sigma_2^2}{2} + \frac{b_1^2 + b_2^2}{2}$$

Les résultats sont donnés sur la figure 2.

On peut alors constater que l'amélioration des performances est sensible, surtout pour des rapports signal-à-bruit élevés, car dans ce cas, l'estimation de la première passe est correcte. Par contre, pour des R.S.B. faibles, l'estimation des azimuts de la première étape se dégrade et le cumul des erreurs (erreur sur l'estimation de θ et erreur sur l'estimation du signal source $\underline{S}^{(k)}(t)$) peut expliquer pourquoi la méthode avec orthonormalisation des vecteurs directionnels devient meilleure que celle avec décomposition sur chaque source.

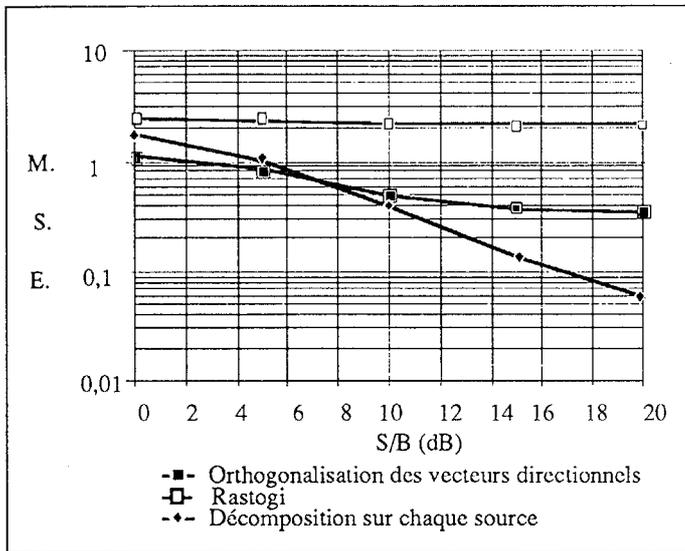


fig. 2 : résultats pour des sources non corrélées

Résultats pour des émissions corrélées

Les sources sont choisies avec un coefficient de corrélation de 0,999. Leur position est la même que celle de la simulation précédente. L'estimation s'effectue sur 10 échantillons et le rapport signal à bruit est égal à 20 dB. Les résultats sont les suivants (pour 100 réalisations indépendantes):

	Orthogonalisation des vecteurs directionnels	Rastogi	Décomposition sur chaque source
M.S.E.	0,36	1,82	0,12

L'amélioration est également, dans ce cas, sensible. L'algorithme de Rastogi donne systématiquement les bornes de l'intervalle, alors que les deux autres algorithmes donnent des résultats moins biaisés.

VII. CONCLUSION

Si on associe un neurone à une direction possible d'arrivée, il n'est pas possible d'implanter directement la méthode du Maximum de Vraisemblance sur un réseau de neurones. Nous avons proposé, dans cet article, deux nouveaux algorithmes neuronaux qui convergent asymptotiquement vers l'estimée au sens du maximum

de vraisemblance des azimuts (en fait, seules les deux premières étapes ont été présentées, il faudrait itérer l'étape 2 une infinité de fois pour converger). L'utilisation d'un algorithme neuronal peut être intéressante car elle permet de positionner rapidement des sources proches et complètement corrélées, surtout lorsque des machines VLSI réellement parallèles existeront. On peut également remarquer que le calcul des matrices de poids synaptiques peut s'effectuer de manière entièrement parallèle. L'estimation fournie par le réseau de neurones peut alors servir d'initialisation à un algorithme rapide de type Gauss-Newton qui convergera immédiatement vers le maximum de la vraisemblance correspondant à la position des sources [10]. De plus, le nombre de neurones ayant convergé vers 1 nous donne le nombre de sources.

A l'heure actuelle, et à notre connaissance, seules des fonctions quadratiques peuvent être optimisées par réseaux de neurones de taille raisonnable. En fait, il existe déjà des réseaux de Hopfield dont l'énergie de Lyapunov est plus générale qu'une quadratique, mais ils font appel à un nombre important de neurones qui rendrait prohibitif le temps de calcul d'une simulation logicielle. Sur un ordinateur traditionnel, le temps de calcul d'un réseau neuromimétique complètement connectés croît comme le carré du nombre de neurones. En revanche, si l'on utilise un circuit VLSI, l'augmentation du temps de calcul suit de façon linéaire l'accroissement du nombre de neurones. L'implantation de ces mécanismes sur silicium sera particulièrement intéressante pour des applications temps réel.

VIII. REFERENCES

- [1] : J.J. Hopfield and D.W. Tank, "Neural Computation of Decisions in Optimization Problems", Biological Cybernetics, vol. 52, pp 141-152, 1985.
- [2] : I. Ziskind and M. Wax, "Maximum Likelihood Localization of Multiple Sources by Alternating Projection", IEEE Trans ASSP, vol. 36, n°10, pp 1553-1560, October 1988.
- [3] : Y. Bressler and A. Macovski, "Exact Maximum Likelihood Estimation of Superimposed Exponential Signal in Noise", Proc. ICASSP, 1985.
- [4] : A.J. Weiss, A. Willsky and B.C. Levy, "Maximum Likelihood Array Processing for the Estimation of Superimposed Signals", Proc. of IEEE, vol. 76, n°2, february 1988.
- [5] : R. Rastogi, P.K. Gupta and R. Kumaresan, "Array Signal Processing with Interconnected Elements", Proc. ICASSP, pp 2328-2331, 1987.
- [6] : D. Goryn and M. Kaveh, "Neural Networks for Narrowband and Wideband Direction Finding", Proc. ICASSP, pp 2164-2167, 1988.
- [7] : S. Jha, R. Chapman and T.S. Durrani, "Bearing Estimation using Neural Networks", Proc. ICASSP, pp 2156-2159, 1988.
- [8] : S. Jha and T. Durrani, "Bearing Estimation using Neural Optimization Methods", Proc. ICASSP, pp 889-892, 1990.
- [9] : B. C. Levy and M.B. Adams, "Global Optimization with Stochastic Neural Network", Proc. of IEEE first Conf. on Neural Networks, San Diego, pp III 681-687, 1987.
- [10] : H. Clergeot and S. Tressens, "Comparison of Two Efficient ML Algorithms For High Resolution Sources Tracking-Time Recursive Implementation", Proc ICASSP, pp 2963-2966, 1990.