

DIXIEME COLLOQUE SUR LE TRAITEMENT DU SIGNAL ET SES APPLICATIONS

NICE du 20 au 24 MAI 1985

DETECTION DE GRANDEURS PRIMITIVES DANS UN MESSAGE COMPOSITE PAR UNE
ARCHITECTURE DE CALCUL NEUROMIMETIQUE EN APPRENTISSAGE NON SUPERVISE

J. HERAULT, C. JUTTEN, B. ANS*

Laboratoire de Traitement d'Images et Reconnaissance de Formes
INP-ENSER, 46 avenue Félix Viallet 38031 - GRENOBLE-CEDEX (France)

RESUME

Le problème traité ici est celui de l'analyse des *messages composites* issus d'un ensemble de capteurs sensibles à des *mélanges de sources multiples*. En raison de l'analogie avec les messages véhiculés par les fibres nerveuses, nous proposons une approche utilisant une *architecture de calcul neuromimétique*.

Un réseau d'opérateurs munis des propriétés de plasticité de la cellule nerveuse reçoit les messages composites et, par un mécanisme d'*auto-apprentissage* (sans superviseur), réalise l'extraction des primitives qui composent ces messages.

L'apprentissage est *permanent*, il corrige automatiquement les éventuelles dérives dans la composition du mélange des primitives à discriminer.

Les applications se situent au niveau du pré-traitement de signaux de nature vectorielle : à partir des échantillons du vecteur d'entrée, le système élabore un modèle de la matrice inconnue représentative du mélange et en déduit l'unique décomposition canonique qui permet d'extraire les primitives, c'est-à-dire d'accéder à l'information utile.

SUMMARY

We present here the problem of the analysis of *composite messages* produced by set of sensors each sensitive to a composition of *multiple source signals*. According to the analogy with the messages carried by nervous fibers, we propose an approach based on the principle of a computational neuromimetic architecture.

A network of operators provided with the properties of plasticity of the nervous cell is fed with the composite messages and, by means of a mechanism of *self-learning* (without supervisor), realises the extraction of the primitives which compose these messages.

Learning is *permanent*, it automatically corrects the possible drifts in the composition of the primitives in the message.

Applications lie in pre-processing of signals with vectorial structure : receiving only the samples of the input vector, the system elaborates a model of the unknown matrix of the mixture and finds the unique canonical decomposition which allows the extraction of primitives, i.e. the access to the useful information.

*Laboratoire de Neurobiologie Humaine,
Université de Provence, L.A. CNRS 372
rue Henri Poincaré
13397 - MARSEILLE-CEDEX 13



DETECTION DE GRANDEURS PRIMITIVES DANS UN MESSAGE COMPOSITE PAR UNE ARCHITECTURE DE CALCUL NEUROMIMETIQUE EN APPRENTISSAGE NON SUPERVISE

J. HERAULT, C. JUTTEN, B. ANS

Il est courant d'observer en neurophysiologie que les fibres nerveuses véhiculent des messages complexes résultant d'un mélange de plusieurs grandeurs primitives. Ce phénomène est dû au fait que d'une manière générale des cellules voisines ont des champs récepteurs se recouvrant largement, ou encore que des capteurs sont sensibles à plusieurs grandeurs simultanément. Ce schéma s'applique aussi à tous les capteurs physiques dont on veut exploiter le signal.

Nous proposons ici, selon le modèle de certaines structures nerveuses, un opérateur capable par un mécanisme d'auto-apprentissage (sans superviseur), d'extraire les composantes primitives aléatoires ou déterministes des messages afférents composites. Cette structure est constituée de neurones formalisés (automates à seuil, à sortie continue dans un intervalle de (R^+) en interconnexion complète. Les pondérations de ces interconnexions sont modifiables selon une loi locale modélisant la plasticité des synapses (liaisons entre neurones). Cette loi fait intervenir la corrélation de fonctions non-linéaires de l'entrée et de la sortie de l'opérateur.

1. LE PROBLEME

Supposons que, pour l'analyse d'un système complexe, nous disposions d'un ensemble de n voies de mesure. Chaque voie, issue d'un capteur spécifique, fournit à chaque instant t un signal image d'une certaine combinaison d'un nombre limité de variables internes du système. En supposant que ces variables soient des primitives indépendantes, ou simplement non corrélées, est-il possible de les isoler par une méthode d'analyse statistique, c'est-à-dire sans connaissance a priori sur ces variables ni sur leur poids relatif dans chaque voie de mesure ?

1.1. Les données initiales

Soit un vecteur E dont les composantes E_1, E_2, \dots, E_n sont des signaux temporels, images des composantes X_1, X_2, \dots, X_n d'un vecteur X dans une transformation linéaire représentée par une matrice $n \times n$: A . On écrit :

$$E(t) = A \cdot X(t) \quad (1)$$

Dans la suite la variable t n'apparaîtra plus afin d'alléger l'écriture.

Hypothèse 1 : les composantes de X sont des signaux indépendants ou simplement non corrélés.

Hypothèse 2 : la transformation linéaire $X \rightarrow E$ est régulière : il existe une matrice A^{-1} représentant la transformation inverse.

Hypothèse 3 : les composantes X_k du vecteur X et les coefficients a_{ij} de la matrice A sont inconnus. On ne dispose à chaque instant que des composantes de E .

1.2. Principe de la solution

Le vecteur E est appliqué à un réseau de n opérateurs auto-adaptatifs en interconnexion complète. Ce réseau, à partir de tests d'indépendance statistique entre ses sorties devra ajuster ses paramètres de façon à isoler sur chacune de ses sorties les primitives X_k (fig.1). C'est une architecture neuromimétique : chaque opérateur N_i reçoit une information externe E_i et une information interne $\sum_j c_{ij} S_j$. Les coefficients c_{ij} sont les poids des interconnexions analogues des efficacités synaptiques.

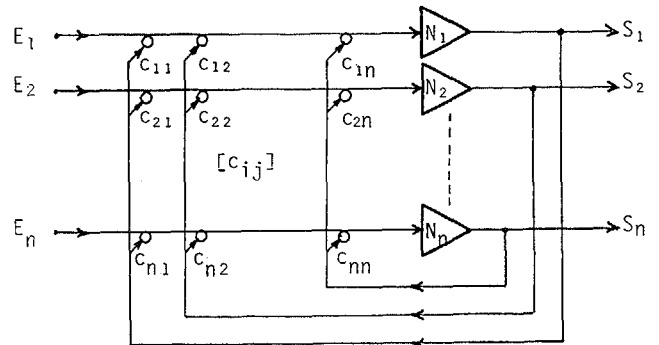


Figure 1 : Réseau d'opérateurs en interconnexion complète. Chaque triangle N_i est un opérateur dont la sortie est S_i . La ligne horizontale à gauche de l'opérateur est une ligne de sommation, elle réalise la somme : $E_i - \sum_j c_{ij} S_j$.

Ce modèle de structure correspond bien au type de connexions entre les cellules dans certaines couches corticales : la densité des interconnexions (10^4 à 10^5 par neurone) suggère que plusieurs centaines de cellules peuvent se trouver en connexion complète dans un certain voisinage [1]. Il est très souvent utilisé en théorie des neurosciences dans les modèles de mémoire associative [2, 3] ou dans les études des processus de coopération-compétition dans les structures nerveuses [4].

Nous pouvons évaluer les possibilités d'une solution à notre problème de la manière suivante : en supposant que les opérateurs du réseau sont linéaires, on peut exprimer la sortie S_i de l'opérateur N_i par :

$$S_i = E_i - \sum_{j=1}^n c_{ij} S_j \quad (2)$$

c'est-à-dire que le vecteur S de sortie du réseau s'exprime par :

$$S = E - C.S \quad (3)$$

C étant la matrice des coefficients c_{ij} .

Soit, en appelant I la matrice identité et en remplaçant E par son expression en fonction de X :

$$S = (I+C)^{-1}.A.X \quad (4)$$

à condition que la matrice $(I+C)$ soit régulière. Si l'on veut que les composantes de X soient isolées chacune sur une composante de S , à un facteur de proportionnalité près, il faut que le produit $(I+C)^{-1}.A$ soit une matrice $n \times n$: P qui ait un seul élément non nul par ligne et par colonne, c'est à dire qui soit une simple permutation des lignes ou des colonnes d'une matrice diagonale :

$$S = P.X \quad (5)$$

$$\text{avec } P = (I+C)^{-1}.A \quad (6)$$

Nous postulons que la matrice C satisfaisant à (6) peut être obtenue par un processus auto-adaptatif apparenté à ceux que l'on rencontre dans le fonctionnement de la cellule nerveuse.

En réalité, ces processus sont encore actuellement mal connus et relèvent le plus souvent d'hypothèses formulées à partir de résultats essentiellement qualitatifs obtenus en physiologie [5, 6]. En conséquence, nous choisirons une hypothèse au formalisme simple compatible dans une large mesure avec les données biologiques de la cellule nerveuse.

1.3. Modèle de la cellule nerveuse

Nous retiendrons ici de la fonction Neurone un modèle simplifié largement utilisé et se résumant ainsi :



DETECTION DE GRANDEURS PRIMITIVES DANS UN MESSAGE COMPOSITE PAR UNE ARCHITECTURE DE CALCUL NEUROMIMETIQUE EN APPRENTISSAGE NON SUPERVISE

J. HERAULT, C. JUTTEN, B. ANS

* La caractéristique de transfert d'un neurone est non linéaire et son signal de sortie est positif. Il est fonction de la somme algébrique p des signaux d'entrée (p est l'analogue du potentiel de membrane). Ainsi, dans le cas du réseau de la figure 1, l'équation (2) devient :

$$\left. \begin{aligned} S_i &= N(p_i) \\ \text{avec } p_i &= E_i - \sum_j c_{ij} S_j \end{aligned} \right\} \quad (7)$$

La fonction neurone $N(p_i)$ sera prise ici comme linéaire entre une valeur seuil θ_i pour p_i et une valeur de saturation S_{at} pour S_i :

$$N(p_i) = \text{Min}(S_{at}, \text{Max}(0, p_i - \theta_i)) \quad (8)$$

Dans de nombreux calculs, une simplification conduit à prendre $S_{at} = \infty$ et $\theta_i = 0$.

* Le processus auto-adaptatif de la cellule nerveuse que nous retiendrons est celui de la *plasticité synaptique*. C'est un mécanisme de régulation de la transmission des signaux entre cellules tel que l'efficacité de transfert de la jonction (synapse) entre deux neurones est une fonction des activités pré- et post-synaptiques. Autrement dit, les coefficients synaptiques c_{ij} du réseau de la figure 1 sont fonction des signaux pré- (S_j) et post- (S_i) synaptiques.

D'une manière générale, il est admis [5, 7] que :

- i. l'efficacité d'une synapse augmente lorsque les neurones pré- et post-synaptiques sont actifs simultanément.
- ii. l'efficacité décroît lorsque l'élément post-synaptique est actif et le pré-synaptique inactif.
- iii. elle diminue en outre lentement en l'absence d'activité post-synaptique.

Ces observations peuvent répondre à un formalisme simple dans le cas d'un modèle continu du neurone, la variation temporelle de l'efficacité synaptique s'exprimant par :

$$\dot{c}_{ij} = -\gamma \cdot c_{ij} + \alpha f(S_i) \cdot g(S_j) \quad (9)$$

où α est le gain d'adaptation, γ est un facteur d'oubli.

Nous n'appliquerons pas cette règle aux coefficients c_{ii} qui peuvent être considérés comme des paramètres de la fonction neurone $N(p_i)$. Celle-ci n'étant pas considérée ici comme variable, nous prendrons $c_{ii} = 0$.

Dans le cadre de cette étude, nous adopterons un modèle très simplifié se définissant ainsi :

$$S_i = N(p_i) = \text{Max}(0, p_i)$$

$$p_i = E_i - \sum_{j=1}^n c_{ij} S_j, \quad j \neq i$$

$$\dot{c}_{ij} = \alpha \cdot f(S_i) \cdot g(S_j), \quad j \neq i$$

L'observation de ces équations conduit à penser que la fonction de chaque cellule N_i au sein du réseau serait d'établir un *modèle* du signal d'entrée externe E_i à partir d'une combinaison linéaire des signaux internes S_j . Ce modèle, \hat{E}_i , serait une estimation de E_i de la forme :

$$\hat{E}_i = \sum_j c_{ij} S_j \quad (10)$$

La sortie S_i exprimerait donc dans ces conditions l'erreur d'estimation :

$$S_i = E_i - \hat{E}_i \quad (11)$$

Nous posons par hypothèse que, si tel est le cas, le processus auto-adaptatif doit tendre à minimiser une fonction de cette erreur. Et d'après les équations (4),

(5), (6) l'erreur obtenue après convergence du processus sera l'une des composantes de X . Le nombre de degrés de liberté du problème est égal au nombre de coefficients c_{ij} à trouver, c'est-à-dire $n(n-1)$.

2. CHOIX D'UNE LOI D'ADAPTATION

Le problème ainsi formulé répond au même type d'équation que le filtrage auto-adaptatif. Nous utiliserons donc la méthode classique qui consiste à minimiser une fonction de l'erreur, soit par exemple, la moyenne quadratique

$$S_i^2 = (E_i - \hat{E}_i)^2 \quad (12)$$

en fonction des coefficients c_{ij} .

Calculons donc le gradient de cette erreur par rapport à chaque composante c_{ij} en utilisant les variables centrées $s_i = S_i - \bar{S}_i$ et $e_i = E_i - \bar{E}_i$.

$$\frac{\partial}{\partial c_{ij}} s_i^2 = \frac{\partial}{\partial c_{ij}} s_i^2 = 2 s_i \frac{\partial s_i}{\partial c_{ij}} \quad (13)$$

En reprenant l'équation (3) du réseau $S = E - C \cdot S$ avec les variables centrées s et e , il vient :

$$(I+C) \cdot s = e \quad (14)$$

Dérivons les deux membres par rapport à l'un des coefficients de C , c_{ij} :

$$(I+C) \frac{\partial s}{\partial c_{ij}} + \begin{vmatrix} 0 & 0 \\ 0 & 1 \end{vmatrix} \cdot s = 0 \quad (15)$$

la matrice du 2e terme a tous ses éléments nuls sauf celui d'indice i, j qui vaut 1. Si la matrice $(I+C)$ est régulière, on peut exprimer le vecteur $\partial s / \partial c_{ij}$ par :

$$\frac{\partial s}{\partial c_{ij}} = - \begin{vmatrix} 0 \dots q_{ij} \dots 0 \\ \vdots \vdots \vdots \\ 0 \dots q_{nj} \dots 0 \end{vmatrix} \cdot s \quad (16)$$

la matrice du second membre a une seule colonne non nulle : la colonne j et ses éléments q_{ij} sont ceux de $(I+C)^{-1}$.

On tire alors pour la composante d'indice k :

$$\frac{\partial s_k}{\partial c_{ij}} = -q_{kj} \cdot s_j \quad (17)$$

soit, en particulier pour la liaison $S_j \rightarrow S_i$:

$$\frac{\partial s_i}{\partial c_{ij}} = -q_{ij} \cdot s_j \quad (18)$$

Multiplions les deux membres par $S_i = \bar{S}_i + s_i$:

$$\bar{S}_i \frac{\partial s_i}{\partial c_{ij}} + s_i \frac{\partial s_i}{\partial c_{ij}} = -q_{ij} S_i s_j = -q_{ij} (\bar{S}_i \cdot s_j + s_i \cdot s_j) \quad (19)$$

ce qui donne si l'on prend la valeur moyenne des deux membres :

$$\frac{\partial}{\partial c_{ij}} s_i^2 = -2q_{ij} \cdot \bar{S}_i \cdot s_j = -2q_{ij} \cdot \bar{S}_i \cdot s_j \quad (20)$$

Le minimum partiel de s_i^2 s'obtient lorsque c_{ij} est tel que la covariance de S_i et S_j est nulle. En utilisant l'algorithme du gradient stochastique, on obtient une loi de variation de c_{ij} qui permet d'atteindre ce minimum :

$$\dot{c}_{ij} = \alpha s_i s_j \quad (21)$$

Cette loi de contrôle de c_{ij} n'est autre, au centrage des variables près, que la règle de plasticité synaptique énoncée par Hebb. Elle indique que les coefficients c_{ij} ne varient plus lorsque les composantes S_i et S_j sont statistiquement indépendantes, ce qui se produit en particulier si le vecteur S répond aux équations



(5) et (6), c'est-à-dire si chaque composante de S est proportionnelle à une composante de X . Cependant, il est évident que la matrice C convenant à (5) et (6) ne peut en général être obtenue par la loi (21) de variation de ses éléments car celle-ci implique à tous instants $c_{ij} = c_{ji}$, c'est-à-dire que le nombre de degrés de liberté du problème se réduit à $n(n-1)/2$ au lieu des $n(n-1)$ prévus initialement.

Nous proposons donc une autre loi qui, en conservant la notion de covariance, permet une dissymétrisation des variations c_{ij} et c_{ji} : il s'agit de prendre à partir de l'expression (9) deux fonctions $f(\cdot)$ et $g(\cdot)$ impaires telles que $f(s_i) \cdot g(s_j)$ soit différente de $f(s_j) \cdot g(s_i)$. Après une série d'essais par simulation du problème [8] nous avons obtenu les meilleurs résultats pour une loi du type :

$$\dot{c}_{ij} = \alpha \cdot s_i^3 \cdot \text{Arctg}(s_j) \quad (22)$$

En prenant le développement limité au premier ordre de $\text{Arctg}(s_i)$, on remarquera que cette loi s'apparente à un algorithme du gradient stochastique appliqué à la recherche d'un minimum de s_i^4 .

En fait, dans les simulations, nous avons recherché la plus grande compatibilité avec les données physiologiques et nous avons remplacé :

- la variable centrée s_j par S_j ,
- la moyenne \bar{S}_j de S_j par son estimation \hat{S}_j à l'aide d'un filtrage passe-bas du premier ordre : $\hat{S}_j(t) = S_j(t) * e^{-t/\tau}$.

L'argument de la fonction Arctg devient donc le filtrage passe-haut du premier ordre de S_j .

En résumé, l'expression que nous avons utilisée dans ces simulations est de la forme :

$$\dot{c}_{ij} = \alpha \cdot S_i^3 \cdot \text{Arctg}(\beta \cdot (S_j - \hat{S}_j)) \quad (24)$$

α étant le gain d'adaptation et β un coefficient.

Cette expression est plausible physiologiquement, elle montre que la plasticité du coefficient synaptique c_{ij} n'est une fonction que des variables locales S_i et S_j ; le facteur pré-synaptique (Arctg), en forme de sigmoïde à point d'inflexion centré à l'origine, exprime qu'une faible activité pré-synaptique peut avoir presque autant d'effet qu'une plus forte, ceci d'autant plus que le coefficient β est élevé. Inversement, le facteur S_i^3 exprime que l'activité du neurone doit être suffisamment élevée pour obtenir une modification notable de l'efficacité synaptique.

Nous allons montrer sur divers exemples le mode de convergence de l'algorithme d'apprentissage que nous proposons et son intérêt pour des applications en traitement du signal dans le cas où l'on dispose de capteurs multiples sensibles à des mélanges de sources multiples, les sources et les mélanges étant inconnus.

3. PROBLEME A DEUX DIMENSIONS

Le problème ici se limite au cas d'un réseau de deux opérateurs-neurones recevant deux signaux E_1 et E_2 qui combinent linéairement, de deux manières différentes, deux grandeurs primitives indépendantes X_1 et X_2 .

$$\begin{aligned} E_1 &= a_{11} X_1 + a_{12} X_2 \\ E_2 &= a_{21} X_1 + a_{22} X_2 \end{aligned} \quad (25)$$

Les équations de fonctionnement du réseau à deux neurones s'écrivent facilement, dans le cas où les signaux évoluent dans la partie linéaire de la caractéristique des éléments :

$$\begin{cases} S_1 = E_1 - c_{12} S_2 \\ S_2 = E_2 - c_{21} S_1 \end{cases} \quad (26)$$

Le réseau n'a évidemment aucune "connaissance" des variables X_1 et X_2 ni des coefficients a_{ij} du mélange, mais nous, nous pouvons mettre en évidence l'existence d'une solution au problème d'extraction des composantes X_1 et X_2 par S_1 et S_2 en reportant (25) dans (26) et en résolvant :

$$\begin{cases} S_1 = \frac{(a_{11} - c_{12} a_{21})X_1 + (a_{12} - c_{12} a_{22})X_2}{1 - c_{12} c_{21}} \\ S_2 = \frac{(a_{21} - c_{21} a_{11})X_1 + (a_{22} - c_{21} a_{12})X_2}{1 - c_{12} c_{21}} \end{cases} \quad (27)$$

Dans cette expression, on voit clairement apparaître une solution à notre problème : une primitive X_j sera isolée sur l'une des sorties si l'autre en est éliminée, c'est-à-dire en annulant l'un des termes entre parenthèses. Ainsi pour que S_1 ne soit fonction que de X_1 , et S_2 que de X_2 , il faut $c_{12} = a_{12}/a_{22}$ et $c_{21} = a_{21}/a_{11}$. L'inverse s'obtient pour $c_{12} = a_{11}/a_{21}$ et $c_{21} = a_{22}/a_{12}$.

De ces deux éventualités, une seule est solution de notre problème : celle qui conduit à la stabilité du système, et qui donne donc $c_{12} \cdot c_{21} < 1$. Dans l'espace de coordonnées constitués par les points P de coordonnées (c_{12}, c_{21}) , il lui correspond le point théorique noté P^* (figure 2.b). Nous nous proposons d'étudier le comportement de l'algorithme d'apprentissage en observant la trajectoire du point P dans le plan (c_{12}, c_{21}) .

3.1. Cas de deux primitives aléatoires

3.1.1. Les deux grandeurs primitives indépendantes X_1 et X_2 sont deux variables aléatoires normales, de moyenne 1 et d'écart-type 0,25. Les composantes E_1 et E_2 résultent du mélange (25) où $a_{11} = 0,3$, $a_{12} = 0,6$, $a_{21} = 0,5$ et $a_{22} = 0,2$. Sur la figure 2.a est représentée la répartition conjointe des couples (E_1, E_2) utilisés dans l'apprentissage. Les coefficients a_{ij} permettent de calculer les coordonnées du point théorique P^* correspondant à l'unique solution stable souhaitée : $c_{12} = 0,3/0,5 = 0,6$ et $c_{21} = 0,2/0,6 = 0,33$.

La loi d'adaptation des coefficients c_{12} et c_{21} est celle définie par la formule (24) avec $\alpha = 0,01$, $\beta = 10$, la constante de temps τ du filtrage passe-bas pour l'estimation de S_j est prise égale à 50 unités de temps. A chaque unité de temps, un couple (E_1, E_2) est généré à partir d'un couple (X_1, X_2) et de la matrice A .

La figure 2.b (page 5) représente dans le plan (c_{12}, c_{21}) quatre trajectoires temporelles fléchées du point courant pendant l'apprentissage, correspondant à quatre états synaptiques initiaux indiqués par les points O, A, B et C .

L'apprentissage se déroule toujours en deux phases très distinctes :

- l'une, *rapide*, vers l'arc d'hyperbole représenté en trait discontinu, lieu des points où les sorties S_1 et S_2 sont *décorrélées* ;
- l'autre, *lente*, où le point courant se déplace le long de l'hyperbole, qui est une phase de *recherche* du mode du mélange des primitives.

Finalement, le point théorique P^* souhaité est effectivement le seul attracteur stable du système, auquel correspond $S_1 = 0,6 X_2$ et $S_2 = 0,5 X_1$: les grandeurs primitives X_1 et X_2 ont été *détectées* dans les messages composites E_1 et E_2 , et ceci *sans* superviseur. La figure 2.c montre la répartition conjointe (S_1, S_2) une fois le point P^* atteint.

DETECTION DE GRANDEURS PRIMITIVES DANS UN MESSAGE COMPOSITE PAR UNE ARCHITECTURE DE CALCUL NEUROMIMETIQUE EN APPRENTISSAGE NON SUPERVISE

J. HERAULT, C. JUTTEN, B. ANS




Figure 2 : a) répartition conjointe des composantes E_1 et E_2 du vecteur d'entrée. Les deux axes obliques donnent les directions propres à chacune des primitives X_1 et X_2 dans cette distribution. b) Evolution de l'état du réseau à partir de quatre conditions initiales différentes. c) Répartition conjointe de S_1 et S_2 quand le système a convergé au point P^* . Les axes relatifs à X_1 et X_2 sont maintenant parallèles aux axes S_1 et S_2 .

4. PROBLEME A TROIS DIMENSIONS

3.1.2. Les deux grandeurs primitives sont deux variables aléatoires à répartition uniforme : X_1 sur $[0,5-1,2]$, X_2 sur $[0,2-0,9]$. Les composantes E_1 et E_2 sont obtenues à partir de X_1 et X_2 par la même matrice A que précédemment et les paramètres α , β , τ sont les mêmes. La figure 3 représente la répartition conjointe des composantes de E et celle des composantes de S après convergence. Ce résultat montre de manière simple l'opération effectuée par le réseau auto-adaptatif.

Nous disposons maintenant d'un réseau de trois opérateurs qui reçoit un vecteur E à trois composantes issu lui-même d'une transformation linéaire d'un vecteur X à trois composantes. Ces dernières sont trois variables aléatoires uniformes.

Le réseau est muni des mêmes lois d'apprentissage et il "découvre" les trois composantes primitives de X dans les mêmes conditions que précédemment. La figure 5 montre, selon trois projections, la trajectoire du point P représentatif de l'état du réseau dans l'espace à 6 dimensions des coefficients c_{ij} .




Figure 3 : Répartitions conjointes de E_1 et E_2 , puis de S_1 et S_2 après convergence.

3.2. Extraction d'un signal noyé dans le bruit

Dans le cas présent, la primitive X_1 est un signal synthétisé non stationnaire. La primitive X_2 est un bruit équiréparti sur $[0-1]$. Les signaux E_1 et E_2 sont obtenus avec la même matrice A et les paramètres α , β et τ sont les mêmes que précédemment. La figure 4 montre la sortie S_1 du réseau avant, et après le début de l'apprentissage ($t=0$). On voit progressivement s'extraire le signal X_1 .

Remarque : Il est important de noter que cette méthode d'extraction de primitives est indépendante de la nature des signaux présentés : aléatoires ou déterministes, à bande large ou étroite, stationnaires ou non.

Figure 4 : voir page 6.




Figure 5 : Trajectoire de l'état du réseau dans l'espace à 6 dimensions des coefficients c_{ij} . On a représenté trois projections. Les pointillés indiquent les coordonnées du point P^* pour lequel le réseau détecte les primitives.



DETECTION DE GRANDEURS PRIMITIVES DANS UN MESSAGE COMPOSITE PAR UNE ARCHITECTURE DE CALCUL NEUROMIMETIQUE EN APPRENTISSAGE NON SUPERVISE

J. HERAULT, C. JUTTEN, B. ANS




Figure 4 : Extraction d'un signal noyé dans un bruit. X_1 : signal primitif à extraire. S_1 : évolution d'une sortie du réseau, l'apprentissage débute à $t = 0$.

5. REMARQUES

Ce système de traitement de signaux est une architecture neuromimétique de calcul. Il utilise une loi d'adaptation basée sur les propriétés de plasticité des interconnexions nerveuses. Des calculs théoriques rudimentaires montrent que les principes mis en jeu sont très voisins de ceux qui sont utilisés classiquement en traitement du signal. Cependant, les non-linéarités typiques de ce système lui confèrent des propriétés remarquables de traitement auto-adaptatif.

Cette première étude, encore rebelle à l'analyse mathématique n'a permis de dégager des idées guide qu'au moyen de simulations numériques. Les principales remarques auxquelles on a pu aboutir sont les suivantes :

- A partir de la statistique des signaux qu'il reçoit, le réseau *élabore un modèle* du mélange des primitives et "découvre" celles-ci par approximation stochastique.
- *Aucune information préalable* sur la nature des primitives n'est nécessaire : elles peuvent être des signaux aléatoires ou déterministes, stationnaires ou non, à bande large ou étroite.
- *Le système est robuste* : il admet de larges plages de variations de ses paramètres.
- *L'apprentissage est permanent* : toute dérive dans les coefficients du mélange est automatiquement compensée, elle n'affecte pas la discrimination des primitives.
- Le pouvoir discriminatoire est *cohérent* : s'il y a moins de primitives que d'opérateurs, certaines sorties du réseau s'annulent de telle sorte que seules un nombre de sorties égal au nombre de primitives soient actives. Au contraire, si le nombre P de primitives est plus élevé que celui N des opérateurs, le système opère un regroupement de celles-ci en N classes, chacune étant distribuée selon une direction voisine de la composante principale du groupe de primitives auquel elle est affectée.
- La modification des efficacités c_{ij} n'existe que si l'activité pré-synaptique présente une certaine variabilité : le terme $(s_j - \hat{s}_j)$ permet de la détecter. En conséquence, si l'entrée E est constante ou nulle, le système conserve la mémoire de son état ; la fonction d'"oubli" est *active*, elle ne peut se réaliser que par l'apparition d'entrées relevant d'une structuration nouvelle.

BIBLIOGRAPHIE

- [1] T.H. BULLOCK. Introduction to nervous systems. W.H. Freeman and Co (1977)
- [2] T. KOHONEN. Self organization and Associative Memory, Springer Verlag, (1984)
- [3] G. PALM. Neural assemblies. An alternative approach to Artificial Intelligence. Springer Verlag, (1982)
- [4] S. AMARI, M.A. ARBIB. Competition and Cooperation in Neural Nets. in S. Levin, Lectures notes in Biomathematics. Springer Verlag, (1982)
- [5] J.P. RAUSCHECKER, W. SINGER. The effect of early visual experience on the cat's visual cortex and their possible explanation by Hebb synapses. J. Physiol., 310, pp. 215-239, (1981)
- [6] T. HEIDMANN, J.P. CHANGEUX. Un modèle de régulation d'efficacité au niveau post-synaptique d'une synapse chimique. C.R. Acad. Sc. Paris, III, 295 : 665-670, (1982)
- [7] D.O. HEBB. Organization of behaviour, Willey, (1949)
- [8] J. HERAULT, B. ANS. Réseaux de neurones à synapses modifiables : décodage de messages sensoriels composites par apprentissage non supervisé et permanent. C.R. Acad. Sc. Paris, t. 299, série III, n° 13, (1984)