

Quelques lois d'adaptation pour neurones artificiels et réels

Frédéric Alexandre

► **To cite this version:**

Frédéric Alexandre. Quelques lois d'adaptation pour neurones artificiels et réels. F. Le Ber et J. Lieber. Journée sur l'adaptation, 2000, Champenoux, France, 6 p, 2000. <inria-00099049>

HAL Id: inria-00099049

<https://hal.inria.fr/inria-00099049>

Submitted on 26 Sep 2006

HAL is a multi-disciplinary open access archive for the deposit and dissemination of scientific research documents, whether they are published or not. The documents may come from teaching and research institutions in France or abroad, or from public or private research centers.

L'archive ouverte pluridisciplinaire **HAL**, est destinée au dépôt et à la diffusion de documents scientifiques de niveau recherche, publiés ou non, émanant des établissements d'enseignement et de recherche français ou étrangers, des laboratoires publics ou privés.

Quelques lois d'adaptation pour neurones artificiels et réels

Frédéric ALEXANDRE
LORIA/INRIA-Lorraine
BP 239
F-54506 Vandoeuvre
falex@loria.fr

Mots clef : connexionnisme, réseaux de neurones artificiels, apprentissage, mémoire, modèles d'inspiration biologique

1 Introduction

Le but de ce texte est de proposer un point de vue de l'adaptation, sous l'angle du connexionnisme. Cet angle sera pris volontairement large, dans la mesure où il me semble important de parler, bien sûr, du caractère adaptatif des réseaux de neurones artificiels, mais au moins aussi important de replacer ces propriétés dans le cadre plus général de l'apprentissage animal et humain.

Je commencerai par une présentation générale du connexionnisme, puis des principales lois d'apprentissage permettant l'adaptation des modèles de réseaux de neurones artificiels. Ceci pourra être replacé d'une part, dans le cadre des statistiques et d'autre part, dans le cadre de l'apprentissage animal et humain. Sur ce dernier point, je ferai une présentation rapide des théories actuellement admises et de leur possible rencontre avec des modèles de réseaux de neurones artificiels.

2 Le connexionnisme

2.1 Lois de fonctionnement des principaux types de réseaux

Avant de parler de réseaux de neurones artificiels (voir [10] et [3] pour des excellentes introductions), il convient tout d'abord de parler du neurone artificiel : il s'agit d'une unité de calcul simple, interconnectée à d'autres unités semblables et effectuant des calculs numériques à partir de ses entrées pour évaluer une sortie qui sera à son tour intégrée par d'autres unités. Considérons par exemple un neurone N_i , recevant en entrée les activités de n autres neurones N_j , avec $j \in \{1, \dots, n\}$, l'influence de ces activités étant pondérée par des poids, aussi appelés coefficients synaptiques, W_{ij} .

La loi de fonctionnement du neurone N_i consiste alors à définir la fonction f qui évalue l'activité du neurone N_i en fonction des activités des neurones N_j et des poids W_{ij} .

$$e_i = f(e_j, W_{ij})_{j \in \{1, \dots, n\}} \quad (1)$$

Diverses architectures de réseaux de neurones ont été proposées, en association avec une loi de fonctionnement des neurones. Cette association architecture-fonctionnement permet de définir le comportement du réseau vis à vis des informations qu'il traite.

Pour les réseaux directs à couches, de type perceptron [9], la loi de fonctionnement s'écrit comme la somme des entrées, pondérée par les coefficients synaptiques, pour laquelle une fonction à seuil g détermine le niveau d'activité du neurone N_i .

$$e_i = g \left(\sum_{j \in \{1, \dots, n\}} W_{ij} \cdot e_j \right) \quad (2)$$

Dans l'espace des entrées e_j et pour des formes simples de g , cette équation représente un hyperplan séparant cet espace en deux parties et, pour une entrée donnée e_j , l'activité du neurone N_i va donc simplement indiquer de quel côté de l'hyperplan se trouve cette entrée.

Dans le cas des cartes auto-organisatrices comme celles de Kohonen [5] (et d'une manière similaire pour les modèles ART de la théorie de la résonance adaptative de Grossberg), la loi de fonctionnement s'écrit :

$$e_i = \sum_{j \in \{1, \dots, n\}} (e_j - W_{ij})^2 \quad (3)$$

Autrement dit, le neurone N_i calcule une distance entre son vecteur poids et l'entrée e_j qui lui est soumise. Le vecteur poids (et à travers lui le neurone N_i) peut ainsi être vu comme une entrée virtuelle, ou encore un prototype ou un représentant d'une telle entrée.

Dans les réseaux récurrents, comme le modèle de Hopfield [4], les connexions ne sont pas destinées à recueillir les entrées, qui sont fournies une par une aux neurones, mais à interconnecter totalement les neurones entre eux. La loi de fonctionnement, similaire à celle des réseaux directs, va alors apprendre des configurations du réseau (et non pas des entrées), comme des états stables. Ensuite, devant un état initial quelconque, le réseau saura osciller de manière à converger vers l'état stable appris le plus proche. Ces états stables appris sont aussi appelés prototypes et peuvent être vus comme des invariants de configuration du réseau, utilisé comme mémoire associative, ou mémoire adressable par son contenu.

Ayant ainsi rapidement vu, pour les principaux types de réseaux, la fonction attendue des différentes architectures (création de frontières de domaines pour les réseaux à couches, positionnement de prototypes pour les cartes auto-organisatrices, mémoire auto-associative pour les réseaux récurrents), voyons comment chacune de ces fonctions peut être rendue adaptative par l'introduction de lois d'apprentissage.

2.2 Lois d'apprentissage

Tous ces réseaux ont pour propriété fondamentale d'être adaptatifs, c'est à dire de pouvoir modifier leur comportement à partir de leur expérience, de manière à remplir au mieux la tâche qui leur incombe. Avant de décrire ce phénomène plus précisément, il est important de souligner deux points. D'une part, pour tous les modèles évoqués ici, l'apprentissage consiste à définir des critères de modifications des poids W_{ij} permettant d'extraire, à partir d'exemples, les invariants utiles à la tâche réalisée. D'autre part, tous les mécanismes d'apprentissage que nous allons voir reposent sur la même loi : la loi de Hebb [2].

$$\Delta W_{ij} = k \cdot e_i \cdot e_j \quad (4)$$

Dans le cas du perceptron, l'apprentissage consiste à proposer des entrées et les sorties désirées associées et à modifier les poids de manière à ce que les sorties calculées tendent à reproduire le comportement désiré, c'est à dire modifier les frontières de séparation paramétrées par les poids. La loi de Hebb devient:

$$\Delta W_{ij} = k \cdot (d_i - e_i) \cdot e_j \quad (5)$$

où d_i est la valeur désirée de la sortie e_i .

Dans le cas des cartes de Kohonen, l'apprentissage consiste, pour une entrée et un jeu de poids donnés, à chercher le neurone gagnant (celui dont les poids sont les plus proches de l'entrée considérée) et à modifier ses poids de manière à le rendre encore plus semblable à cette entrée :

$$\Delta W_{ij} = k \cdot (e_i - W_{ij}) \quad (6)$$

Dans le cas du modèle de Hopfield, la règle de Hebb s'applique directement.

3 S'adapter pour quoi faire?

3.1 Statistiques

Aujourd'hui, les réseaux de neurones artificiels sont avant tout des outils de traitement et d'analyse de données. La loi de Hebb peut être vue comme l'évaluation d'une corrélation entre les activités pré- et post-synaptiques. La loi du perceptron (ou ses dérivées permises par l'algorithme de rétropropagation du gradient pour des perceptrons multicouches) permet de réaliser des fonctions de régression (si la fonction g est continue) ou de discrimination (si g est une fonction escalier). Les algorithmes d'apprentissage des cartes auto-organisatrices permettent, selon les variantes, de réaliser des fonctions de clustering, de quantification vectorielle, de classification hiérarchique ou de nuées dynamiques. Dans le cas des réseaux récurrents comme celui de Hopfield, la loi de Hebb permet d'apprendre des configurations stables de distribution d'activités qui deviendront des états attracteurs du réseau.

En connexionnisme, ces différentes lois d'apprentissage sont classiquement présentées comme étant des techniques d'apprentissage supervisé (perceptron) et non supervisé (Kohonen, Hopfield) dans la mesure où la cible à atteindre par le réseau est donnée explicitement ou implicitement. Notons enfin qu'une variante temporelle de l'apprentissage supervisé permet de déboucher sur l'apprentissage par renforcement [14].

3.2 L'apprentissage animal et humain

Si ces notions d'apprentissage (supervisé ou non) et de renforcement sont utiles dans des perspectives statistiques ou stochastiques, elles ne correspondent pas directement avec les vues classiques de l'adaptation, considérée sous l'angle du comportement animal et humain. Il semble pourtant intéressant (quoique pas forcément nécessaire) de réconcilier ces deux points de vue.

Pour la biologie du comportement, la faculté d'adaptation des animaux est principalement illustrée par deux expériences de conditionnement fondatrices, respectivement dues à Pavlov [7] et Skinner [12].

Le conditionnement répondant (ou pavlovien) consiste à considérer une chaîne réflexe perception-action UCS-UCR (*unconditional stimulus- unconditional response*). On choisit ensuite un stimulus *a priori* neutre CS (*conditional stimulus*), que l'on fait apparaître fréquemment avant UCS. On s'aperçoit alors que pour l'animal, CS devient un prédicteur de la chaîne réflexe et finit lui-même par déclencher une réponse conditionnelle CR.

Si, dans le conditionnement pavlovien, l'action est induite (au début de façon réflexe) par un stimulus, c'est le contraire qui se passe dans le conditionnement opérant (ou skinnerien), où une action doit être tout d'abord produite spontanément pour obtenir enfin une récompense. Cette recherche hypothétique rend cet apprentissage certainement beaucoup plus difficile (plus intelligent ?). En effet, l'expérience classique de Skinner consiste à enfermer un rat dans une cage, sans manger. Seul un mouvement vers une pédale (tout d'abord effectué sans but précis) permet de libérer une boulette de nourriture. C'est ensuite que l'association mouvement-récompense se crée et incite le rat à appuyer sur cette pédale pour satisfaire sa faim.

Ces deux types de conditionnement ont été extensivement étudiés par les biologistes [11]. Au-delà de cette description sommaire et schématique, ils en donnent une description beaucoup plus riche (par exemple en ajoutant des contraintes de temps : le conditionnement répondant ne se réalise que si un intervalle inter-stimulus très précis est respecté entre CS et UCS) et rapportent également un certain nombre d'effets de bord à ces conditionnements (par exemple le *blocking* ou l'*overshadowing* en conditionnement répondant précise les conditions d'apprentissage d'un nouveau CS quand une association CS-CR a déjà été apprise). Enfin, concernant plus précisément l'apprentissage humain, s'il est clair que l'homme est bien sûr sujet à ces conditionnements, on décrit plus volontiers des phénomènes de jugement par contingence, qui peuvent se rattacher à ces conditionnements [6].

Historiquement, ces différentes formes d'adaptation (conditionnement, contingence) ont été modélisées selon plusieurs voies. Tout d'abord, des modèles à base de règles ont tenté de saisir la dynamique de ces phénomènes en évaluant les probabilités conditionnelles que la théorie statistique nous indique

(par exemple, pour le conditionnement répondeur ou le jugement par contingence, évaluer la probabilité d'avoir une sortie sachant l'entrée, y soustraire éventuellement la probabilité d'avoir la sortie sachant que l'entrée est absente, etc).

De nombreux essais de cet ordre ont été menés et, s'ils correspondent le plus souvent à des évaluations relativement proches de la réalité, il est cependant clair qu'ils ne la modélisent pas. Quelle que soit la formule employée, il y a toujours un biais entre les valeurs d'association calculées et celles observées. Autrement dit, notre cerveau ne calcule pas directement des probabilités, ou encore : *nous ne sommes pas des statisticiens intuitifs*.

Une modélisation beaucoup plus proche de la réalité a été obtenue en développant des modèles associatifs à base de réseaux de neurones artificiels. Il suffit par exemple d'utiliser un perceptron où les CS sont les entrées avec des poids initiaux nuls, les UCS sont des entrées avec des poids constants et forts et les CR et UCR sont les sorties (cf. fig. 1), et de choisir une règle d'apprentissage dérivée de celle de Rescorla-Wagner [8]:

$$\Delta W_{ij} = \alpha\beta(\lambda - \sum_{k \text{ avec } e_k \text{ actif}} W_{ik}) \quad (7)$$

où α et β sont des constantes caractérisant respectivement le CS et le CR et λ est nul si e_j n'est pas actif et sinon représente la force associative du CS représenté par l'entrée e_j .




FIG. 1 – Entrées et sorties des neurones pour la modélisation du conditionnement répondeur

En fait, le principe de la loi de Rescorla-Wagner est d'implanter une compétition entre les CS présents, qui doivent se partager λ , la force d'association totale pour le CR considéré. Cela revient aussi à dire que si les CS présents suffisent à prédire le CR (la somme de leur force de prédiction vaut λ), il n'y a pas d'apprentissage, sinon, cet apprentissage se produit, pour les CS présents, en proportion de la différence entre cette somme et λ .

Si cette loi rend bien compte de tous les phénomènes observés entre plusieurs CS concurrents d'un conditionnement répondeur (comme l'overshadowing) et des forces d'association observées dans le cadre du jugement de contingence et du conditionnement opérant, elle reste cependant statique et ne rend donc pas compte des aspects dynamiques et temporels de ces mécanismes, comme par exemple l'intervalle inter stimulus. D'autres modèles neuronaux ont été développés à cette fin par Sutton et Barto [13].

Ce modèle prend la même architecture que celle utilisée pour Rescorla-Wagner et les lois de fonctionnement et d'apprentissage sont décrites par:

$$\bar{x}_i(t+1) = \alpha\bar{x}_i(t) + x_i(t) \quad (8)$$

$$\bar{y}(t+1) = \beta\bar{y}(t) + (1-\beta)y(t) \quad (9)$$

$$y(t) = f\left[\sum_{j=1}^n w_j(t)x_j(t)\right] \quad (10)$$

$$\forall i \in [1..n], w_i(t+1) = w_i(t) + c[y(t) - \bar{y}(t)]\bar{x}_i(t) \quad (11)$$

avec c constante positive, $0 \leq \alpha, \beta < 1$ et f fonction sigmoïdale. Chaque entrée x (correspondant à un CS) a une activité temporelle décroissante, représentée par sa trace \bar{x} , de même pour les sorties y . La figure 2 montre que l'existence de cette trace permet aux signaux CS et CR de se recouvrir et de déclencher un apprentissage qui fait que CS seul suffira ensuite pour activer CR.




FIG. 2 – Déroulement temporel montrant les rôles de CS et UCS dans l'activation de la sortie

A un niveau plus macroscopique, la figure 3 montre que des phénomènes temporels plus complexes comme le blocking peuvent également être expliqués par ce modèle neuronal.




FIG. 3 – Mise en oeuvre du phénomène de blocking

4 Discussion

Après une brève introduction au formalisme neuronal, cette présentation avait pour but de montrer que les réseaux de neurones artificiels pouvaient rendre compte de divers phénomènes d'adaptation. Ceci a été illustré pour le domaine des statistiques aussi bien que pour celui de l'apprentissage animal et humain. Même si cela n'a pas été discuté dans le texte, il est clair que ces développements neuronaux ne peuvent pas être considérés comme des aboutissements pour la modélisation de ces phénomènes et que beaucoup reste encore à faire pour obtenir des systèmes plus fiables et plus proches de la réalité. En particulier, pour ce qui concerne la modélisation biologique, beaucoup reste à faire pour rendre ces systèmes multimodaux, pour rendre compte de phénomènes temporels plus fins et surtout pour mieux ancrer ces systèmes dans des boucles perception-action avec des notions de motivation, attention et inhibition sélectives et intention [1].

Cependant, pour ce qui concerne le but du présent exposé, il me semble remarquable de pouvoir conclure en disant que ce sont à la base les mêmes mécanismes qui peuvent rendre compte de fonctions de classification élémentaires aussi bien que de lois de conditionnement animal. Ceci ne peut qu'apporter de l'eau au moulin de ceux qui, comme nous, cherchent à modéliser de front le traitement de données et la cognition humaine...

Références

- [1] Hervé Frezza-Buet, Frédéric Alexandre, and Nicolas Rougier. A cerebral framework for the integration of biologically inspired temporal mechanisms for sequence processing. In *Neural, symbolic and Reinforcement methods for sequence learning*. Springer, 2000. to appear.
- [2] D. O. Hebb. *The organization of behaviour*. Wiley, New-York, 1949.
- [3] J. Hertz, A. Krogh, and R. Palmer. Introduction to the theory of neural computation. Addison Wesley, 1991.
- [4] J. J. Hopfield. Neural networks and physical systems with emergent collective computational abilities. In *Proceedings of the National Academy of Sciences, USA*, pages 2554–2558, 1982.
- [5] T. Kohonen. *Self-Organization and Associative Memory*. Springer-Verlag, 1988.
- [6] Allan G. L. Human contingency judgments : Rule based or associative. *Psychological Bulletin*, 114(3):435–448, 1993.
- [7] I. P. Pavlov. *Conditioned Reflexes (V.Anrep, trans.)*. London: Oxford University Press", 1927.
- [8] W. A. Rescorla and A. R. Wagner. *Classical conditioning II: Current research and theory*, chapter A theory of Pavlovian conditioning: Variations in the effectiveness of reinforcement and non-reinforcement. Black, A.H. and Prokasy, W. F., appleton-century-crofts edition, 1972.
- [9] F. Rosenblatt. The perceptron: a probabilistic model for information storage and organization in the brain. In James A. Anderson and Edward Rosenfeld, editors, *Neurocomputing: Foundations of Research (1989)*, pages 89–92. The MIT Press, 1958.
- [10] D.E. Rumelhart and J. L. McClelland. *Parallel Distributed Processing: Exploration in the Microstructure of Cognition*. Cambridge, MA: MIT Press, 1986.
- [11] N. A. Schmajuk. *Animal Learning and Cognition*. Cambridge University Press, 1997.
- [12] B.P. Skinner. *The Behavior of Organisms*. 1938.
- [13] R. S. Sutton and A. G. Barto. Toward a modern theory of adaptative network : Expectation and prediction. *Psychological Review*, 88(2):135–170, 1981.
- [14] C. J. Watkins. *Learning from delayed rewards*. PhD thesis, University of Cambridge, 1989.