



HAL
open science

Mécanisme d'auto-organisation corticale: un modèle basé sur la règle de plasticité synaptique BCM

Thomas Girod, Frédéric Alexandre

► To cite this version:

Thomas Girod, Frédéric Alexandre. Mécanisme d'auto-organisation corticale: un modèle basé sur la règle de plasticité synaptique BCM. Deuxième conférence française de Neurosciences Computationnelles, "Neurocomp08", Oct 2008, Marseille, France. hal-00331561

HAL Id: hal-00331561

<https://hal.science/hal-00331561>

Submitted on 17 Oct 2008

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.

MÉCANISME D'AUTO-ORGANISATION CORTICALE : UN MODÈLE BASÉ SUR LA RÈGLE DE PLASTICITÉ SYNAPTIQUE BCM

Thomas Girod
LORIA/INRIA
BP 239
F-54506 Vandoeuvre
girod@loria.fr

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

Résumé

L'auto-organisation est un principe de traitement et de représentation de l'information important dans le cortex cérébral. Kohonen a popularisé ce principe dans son célèbre modèle de carte auto-organisatrice. Cependant la règle d'apprentissage associée à ce modèle et portant sur les connexions corticales montantes souffre d'un certain nombre de faiblesses qui limitent sa plausibilité biologique et son domaine d'utilisation. Nous avons repris la règle d'apprentissage BCM (Bienenstock-Cooper-Munro) étudiée théoriquement en profondeur pour ses propriétés de stabilité et pour sa compatibilité avec les connaissances actuelles sur l'apprentissage cortical et nous l'avons adaptée pour une utilisation numérique intensive dans de larges cartes corticales soumises à des flux d'information continus. Nous reportons dans ce papier les résultats d'une première série d'expérimentations qui montrent que ce modèle peut être utilisé pour retrouver ces principes d'auto-organisation tels qu'ils peuvent émerger de l'apprentissage des connexions montantes. Nous pensons également que cette même règle pourrait être utilisée, de façon conjointe, pour l'apprentissage des connexions corticales latérales, comme nous commençons à le mettre en oeuvre dans une seconde série d'expérimentations.

1 Auto-organisation corticale

Le cortex est caractérisé par ses propriétés remarquables de plasticité et de ré-organisation que l'on peut observer à différents niveaux de granularité, de la synapse à la voie de traitement impliquant plusieurs aires cérébrales, ce qui permet de placer l'auto-organisation comme un principe fondamental du cortex pour le traitement de l'information qu'il manipule [18].

Ce phénomène, s'il semble universel à la surface corticale, a d'abord été décrit et observé dans les aires perceptives et en particulier dans V1. Ainsi, à un niveau mésoscopique, Hubel et Wiesel [7] ont montré comment, dans une maxicolonne et sous différentes conditions de privation sensorielle, les microcolonnes représentaient (avaient pour stimuli préférentiels) les perceptions élémentaires les plus caractéristiques des flux

d'information leur parvenant de la voie thalamique montante et comment ces colonnes, interconnectées par des connexions latérales, s'organisaient de façon à présenter, sur la surface corticale, une évolution progressive des stimuli considérés. Ce phénomène est fréquemment illustré pour le cas de la sélectivité à l'orientation où des colonnes voisines répondent à des orientations voisines.

Les cartes auto-organisatrices (Self-Organizing Maps, SOM) de Kohonen [10] visent à reproduire ce phénomène d'apprentissage et d'auto-organisation de V1. Au niveau architectural, elles se résument par une couche neuronale recevant un flux d'information montant sur lequel le processus d'extraction des patterns les plus caractéristiques va être réalisé au moyen de ses connexions plastiques et par des inter-connexions latérales figées qui vont assurer la compétition entre les unités de la carte. Il a été de nombreuses fois rapporté, y compris par Kohonen lui même [11], qu'une auto-organisation semblable à celle évoquée plus haut ne se produit que si la règle d'apprentissage définie sur le flux montant s'applique sur les connexions dont le neurone post-synaptique appartient à un voisinage du neurone gagnant dont la taille doit décroître au cours de la convergence du réseau, cette décroissance correspondant à une évolution stéréotypée qui va de la carte entière au neurone unique.

Il convient donc de souligner que le terme post-synaptique de cette règle d'apprentissage hebbienne a tout d'abord une plausibilité biologique discutable car il implique l'utilisation d'un voisinage qui peut être très large en début d'apprentissage et même concerner toute la carte, ce qui se concilie difficilement avec l'exigence d'une règle d'apprentissage locale. D'autre part, cette règle répond mal au dilemme stabilité/plasticité car l'évolution stéréotypée du voisinage permettant la stabilité du réseau ne permet pas de prendre en compte de façon plastique un changement de distribution des entrées. Bien sûr, ce constat n'est pas nouveau mais il n'a pour le moment été proposé d'y remédier que par des mécanismes ad hoc et pas par une remise en cause profonde de la règle d'apprentissage utilisée. Le but de ce papier est de rapporter que le mécanisme d'apprentissage BCM [1], connu pour sa stabilité, ses calculs locaux et sa plausibilité biologique, nous apparait comme une alternative intéressante pour permettre l'apprentissage de cartes auto-organisatrices.

Par ailleurs, les aires corticales, et en particulier l'aire V1 dont il est question ici, sont également décrites par des connexions latérales plastiques, permettant en particulier de faire du groupement perceptif, et par un flux d'information descendant inter-aire modulant l'activité, par exemple à travers des processus attentionnels [5]. Nous expliquerons en conclusion de ce papier que nous pensons qu'un autre intérêt d'utiliser la règle d'apprentissage BCM est de pouvoir l'utiliser également sur ces autres flux corticaux. Nous en menons actuellement les premières expérimentations pour les connexions latérales.

2 Architecture

En vue de comparer les propriétés d'auto-organisation avec celles des cartes de Kohonen, nous avons construit un modèle simplifié de l'architecture de V1 avec connexions montantes plastiques et connexions latérales fixes. Afin de pouvoir utiliser le cadre de simulation des champs neuro-naux, la granularité de notre modèle se situe à l'échelle de la population de neurones. Une unité de calcul représente donc une population de cellules ; une connexion entre deux unités représente de nombreuses synapses excitatrices et inhibitrices ; les potentiels des unités et les activités transmises ne correspondent pas précisément à des potentiels membranaires ou à des fréquences de décharges de cellules particulières, mais sont des indicateurs d'activité plus macroscopiques de populations de neurones.

2.1 Connectivité montante

La connectivité montante véhicule l'entrée d'information dans le cortex. Dans le cortex visuel, il s'agit de connexions thalamo-corticales partant de LGN et pénétrant la couche IV de V1 [6].

L'organisation de LGN est rétinotopique. La projection thalamo-corticale est composée de connexions relativement rapides [13] et parallèles. La divergence de ces connexions est très faible, formant des champs récepteurs localisés. Chez le chat, le champ récepteur moyen est estimé à moins de 2 degrés du champ de vision [16].

Par souci de comparaison avec l'algorithme de Kohonen, nous choisissons ici de simplifier le modèle en ne considérant pas l'ensemble de la rétine et des champs récepteurs locaux, mais plutôt une entrée visuelle limitée et des champs récepteurs identiques pour toutes les unités corticales.

2.2 Connectivité latérale

La connectivité latérale intra-aire est formée par des axones non myélinisés à propagation plus lente. Dans le cortex visuel, on distingue deux schémas de connectivité latérale.

Une connectivité locale est isotropique, se projetant indifféremment dans toutes les directions, jusqu'à 500 mi-

cromètres [15]. Cette connectivité est dominée par des connexions inhibitrices.

Une connectivité plus distante est anisotropique. Elle est principalement composée de connexions excitatrices pouvant se projeter jusqu'à plusieurs millimètres [15]. On observe dans le cortex visuel un schéma de connectivité particulier. Les connexions sont privilégiées entre des neurones iso-orientés et co-alignés. Cette connectivité est généralement considérée comme étant issue de l'exposition à l'environnement et support de phénomènes comme le groupement perceptif [8].

La plasticité des connexions excitatrices de la connectivité latérale peut expliquer de tels phénomènes. Cependant, dans le cadre de ce papier, nous nous contentons pour l'instant d'une connectivité latérale fixe en différence de gaussienne, ce qui est le schéma retenu par Kohonen dans son modèle de carte auto-organisatrice [10].

2.3 Unité de calcul

On caractérise une unité de calcul par trois valeurs : I , l'activité entrante ; c , le potentiel. O ; l'activité sortante.

I est la somme pondérée des activités montantes et latérales. La fonction sigmoïde permet d'avoir un seuil de saturation de l'entrée, améliorant la stabilité de l'algorithme. \vec{d} représente l'activité présynaptique montante, pondérée par les poids \vec{w} . \vec{O} représente l'activité présynaptique latérale, c'est à dire l'activité sortante de la carte corticale, pondérée par les poids \vec{l} .

$$I = \sigma\left(\sum_i d_i \cdot w_i + \sum_i O_i \cdot l_i\right) \quad (1)$$

L'activité entrante I est intégrée itérativement pour obtenir le potentiel c de l'unité. Cette intégration est faite à l'aide d'un filtre exponentiel. Le paramètre τ contrôle la vitesse d'intégration de l'activité entrante.

$$\dot{c} = \frac{I - c}{\tau} \quad (2)$$

L'activité sortante O simule un seuil de décharge. La combinaison du seuil de décharge et de l'intégration itérative de l'activité permet de simuler la latence de décharge des neurones. λ est la pente de la sigmoïde. Le choix du seuil de décharge centré sur $c = 1$ est motivé par les propriétés de l'apprentissage BCM.

$$O = \frac{1}{1 + e^{-c \cdot \lambda + \lambda}} \quad (3)$$

3 Apprentissage BCM

Dans ce contexte, nous appliquons la règle d'apprentissage BCM [1] sur la connectivité montante. BCM (Bienenstock-Cooper-Munro) [1] est une règle de plasticité synaptique hebb/anti-hebb (renforcement et dépression).

Elle permet à une unité d'acquérir la sélectivité à une disposition de son entrée. Elle se base sur une compétition temporelle entre les stimuli, plutôt qu'une compétition spatiale par normalisation des poids synaptiques. Les poids synaptiques varient selon l'équation suivante :

$$\dot{w}_i = \eta d_i \cdot \phi(c, \theta) \quad (4)$$

où η est le taux d'apprentissage, d_i le terme présynaptique, et $\phi(c, \theta)$ le terme postsynaptique.

$$\phi(c, \theta) = c(c - \theta) \quad (5)$$

La fonction ϕ peut prendre un signe positif ou négatif suivant la position du potentiel c par rapport à un seuil θ . Le seuil θ est donc la limite entre le renforcement (LTP) et la dépression (LTD).

$$\dot{\theta} = \frac{c^2 - \theta}{\bar{\tau}} \quad (6)$$

Le paramètre θ est dynamique, fonction de la moyenne temporelle du potentiel de l'unité. Cela signifie que le seuil LTP/LTD se déplace en fonction du passé de l'unité. Le déplacement de θ étant supra-linéaire par rapport à c , la règle BCM converge vers un état où $\bar{c} \approx 1$. Le potentiel de l'unité oscille alors entre une activité très élevée pour le stimulus sélectif et ≈ 0 pour tout autre stimulus.

Une étude de la stabilité de l'apprentissage est présentée dans [2]. La variation des poids converge vers un état stable si l'inégalité suivante est vérifiée :

$$\eta \bar{\tau} d^2 < 1 \quad (7)$$

où η est le taux d'apprentissage, $\bar{\tau}$ la dimension de la moyenne temporelle et d l'activité moyenne induite par les stimuli.

4 Application de BCM au modèle

Dès son origine, l'algorithme d'apprentissage BCM a été présenté comme un modèle de l'apprentissage cortical. Ultérieurement, il a effectivement été étudié dans le cas d'une population de neurones en interaction par le biais de connexions latérales fixes [3]. Cependant, à notre connaissance, il n'a pas été déployé de façon à étudier l'émergence d'une auto-organisation dans une population neuronale importante et soumise à un flux d'information continu. Notre contribution se place dans la continuité de travaux visant à émuler de grandes populations de neurones à l'aide de modèles de champs neuronaux [14] (nous en avons d'ailleurs adapté les outils logiciels); comme indiqué dans l'équation 2, elle propose également une adaptation *on-line* de l'algorithme BCM, lui permettant d'être appliqué à un flux d'information continu.

4.1 Paramètres

Le modèle BCM classique intègre directement l'activité entrante pour obtenir le potentiel de l'unité. Nous l'appliquons ici à un modèle où le potentiel est calculé itérativement (équation 2). Nous avons vérifié expérimentalement que la condition de stabilité présentée à l'équation 7 se généralise à la condition suivante :

$$\eta \bar{\tau} d^2 < 1 \quad (8)$$

Comme nous l'avons dit, la convergence de BCM mène à une oscillation du potentiel c avec $\bar{c} \approx 1$. C'est pour cette raison que nous avons placé le seuil de décharge de la fonction de sortie à 1.

Nous avons choisis les paramètres de saturation de l'entrée et de vitesse d'intégration de l'activité entrante de sorte qu'une unité au repos recevant une stimulation moyenne aura une latence de 10-15ms. Une stimulation saturée aura quand à elle une latence presque nulle.

Le paramètre $\bar{\tau}$ est garant d'un apprentissage stable. Pour nos simulations, nous avons choisi $\bar{\tau} = 100\tau$. En effet, les observations biologiques de déplacement du seuil LTP/LTD indiquent une échelle en secondes, minutes, voir en heures. Ce choix rend l'apprentissage stable mais très lent, de par l'inégalité 8. On est dans un cas typique de dilemme stabilité/plasticité.

Il est démontré dans [3] qu'une connectivité latérale fixe entre les unités BCM d'une population n'altère pas la nature des points fixes de l'algorithme. Une connectivité latérale inhibitrice favorise la répartition de la sélectivité dans la population. Dans [4] sont présentés quelques exemples de convergence de cartes neuronales avec des connexions latérales fixes. Nous retenons une connectivité latérale en différence de gaussiennes. Les deux gaussiennes sont normalisées de sorte que la somme des poids latéraux pour une unité est nulle.

4.2 Résultats

Nous avons testé notre modèle en effectuant un apprentissage basé sur des filtres de Gabor. Le jeu d'apprentissage est constitué de 32 filtres de Gabor dont les orientations sont uniformément réparties sur $[0; \pi[$. Les filtres de Gabor sont présentés aléatoirement toutes les 30 millisecondes. Dans un premier temps, la distribution de probabilité est uniforme. On notera qu'il n'y a aucun contrôle de l'apprentissage : celui-ci est effectué à chaque pas de temps (1ms), pour chaque unité.

La figure 1 montre l'émergence de la sélectivité à l'orientation en même temps que l'auto-organisation de la carte. Il est intéressant de constater que l'usage de l'apprentissage BCM met en place un processus d'auto-organisation avec une interaction latérale figée. En tant que tel, l'apprentissage BCM nous apparait donc comme une alternative intéressante à l'algorithme SOM classique, car il




FIG. 1. Champs récepteurs d'une carte 20x20 après apprentissage sur des filtres de gabor.




FIG. 2. Champs récepteurs d'une carte 20x20 après réorganisation. La distribution de probabilité favorise les filtres de Gabor horizontaux.

ne nécessite pas de variation du mécanisme de compétition au fur et à mesure de l'apprentissage.

Dans un second temps, nous avons repris la carte précédente après convergence, et avons poursuivi l'apprentissage en modifiant la distribution de probabilité des 32 orientations, de sorte que l'orientation horizontale soit dominante. La figure 2 montre une réorganisation de la carte reflétant la nouvelle distribution de probabilité, toujours sans nécessiter de variation du taux d'apprentissage ou de la connectivité latérale.

5 Conclusion

De nombreux travaux ont montré la plausibilité biologique de l'apprentissage BCM : reproduction de phénomènes observés dans V1 [12], évidence du seuil

LTP/LTD dynamique [9], lien avec la plasticité STDP [17]. De plus, sa stabilité a fait l'objet de preuves formelles. Nous avons montré dans ce travail que BCM est à même de mettre en place un phénomène d'auto-organisation par un apprentissage permanent, sans nécessiter de phases de relaxation ou de réinitialisation d'activité. Ceci nous apparaît comme étant un avantage non-négligeable pour des applications pratiques : un mécanisme d'apprentissage entièrement distribué, générique, capable d'opérer *on-line* sur les données entrantes permettrait la construction de modèles développementaux, applicables à des problématiques d'intelligence artificielle située.

Le modèle que nous avons présenté se limite encore à l'apprentissage sur la connectivité montante. Or, la plasticité des connexions latérales est un fait avéré. La suite de notre travail portera donc sur l'apprentissage de la connectivité latérale. On cherchera à retrouver la connectivité latérale particulière de V1, entre unités iso-orientées et co-alignées.

Références

- [1] E.L. Bienenstock, L.N. Cooper, and P.W. Munro. Theory for the development of neuron selectivity : Orientation specificity and binocular interaction in visual cortex. *Journal of Neuroscience*, 2, 1982.
- [2] B.S. Blais. *The Role of Environment in Synaptic Plasticity : Towards an understanding of Learning and Memory*. PhD thesis, Brown University - Institut for Brain and Neural Systems, 1998.
- [3] G.C. Castellani, N. Intrator, H. Shouval, and L.N. Cooper. Solutions of the bcm learning rule in a network of lateral interacting nonlinear neurons. *Computational Neural Systems*, 1999.
- [4] L.N. Cooper, N. Intrator, B.S. Blais, and H.Z. Shouval. *Theory of cortical plasticity*. World Scientific, 2004.
- [5] J. Fix, N. Rougier, and F. Alexandre. From physiological principles to computational models of the cortex. *Journal of Physiology - Paris*, 2007.
- [6] D.H. Hubel and T.N. Wiesel. Receptive field of cells in the striate cortex of very young, visually inexperienced kittens. *Journal of Neurophysiology*, 1963.
- [7] D.H. Hubel and T.N. Wiesel. Receptive fields and functional architecture of monkey striate cortex. *Journal of Physiology*, 1968.
- [8] D.H. Hubel and T.N. Wiesel. The period of susceptibility to the physiological effects of unilateral eye closure in kittens. *Journal of Physiology*, 1970.
- [9] A. Kirkwood, M. G. Rioult, and M. F. Bear. Experience-dependent modification of synaptic plasticity in visual cortex. *Nature*, 381 :526–528, June 1996.
- [10] T. Kohonen. The self-organizing map. *Proc. IEEE*, 78(9) :1464–1480, September 1990.

- [11] T. Kohonen. *Self-organizing maps*. information science. Springer, Berlin, 3 edition, 2001.
- [12] C.C. Law and L.N. Cooper. Formation of receptive fields in realistic visual environments according to the bienenstock, cooper, and munro (bcm) theory. *Proc Natl Acad Sci U S A*, 91(16) :7797–801, August 1994.
- [13] L.G. Nowak and J. Bullier. The timing of information transfer in the visual system. *Cerebral Cortex*, 1997.
- [14] N. Rougier. Dynamic neural field with local inhibition. *Biological Cybernetics*, 2006.
- [15] P. Seriès, S. Georges, J. Lorenceau, and Y. Frégnac. Orientation dependent modulation of apparent speed : a model based on the dynamics of feed-forward and horizontal connectivity in v1 cortex. *Vision Research*, 2002.
- [16] P. Seriès, L. Lorenceau, and Y. Frégnac. The "silent" surround of v1 receptive fields : theory and experiments. *Journal of physiology - Paris*, 2004.
- [17] T. Toyozumi, J. P. Pfister, K. Aihara, and W. Gerstner. Generalized Bienenstock-Cooper-Munro rule for spiking neurons that maximizes information transmission. *Proc. National Academy Sciences (USA)*, 102 :5239–5244, 2005. article.
- [18] J.C. Wiemer. *Learning topography in neural networks : towards a better understanding of cortical topography*. PhD thesis, universiti½ de Bochum, 2000.