



HAL
open science

Émergence et apprentissage d'information dans un modèle multimodal de cartes CNFT impulsives

Selma Belgacem, Yann Boniface, Alain Dutech

► **To cite this version:**

Selma Belgacem, Yann Boniface, Alain Dutech. Émergence et apprentissage d'information dans un modèle multimodal de cartes CNFT impulsives. 2009. hal-00802908

HAL Id: hal-00802908

<https://hal.science/hal-00802908>

Preprint submitted on 20 Mar 2013

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.

Emergence et apprentissage d'information dans un modèle multimodal de cartes CNFT impulsives

Selma Belgacem¹, Yann Boniface² and Alain Dutech²

Juillet 2011

¹ LITIS EA 4108 , Université de Rouen,
UFR des Sciences, Site Universitaire du Madrillet
Avenue de l'Université,
76800 Saint-Etienne-du-Rouvray ; France
selma.belgacem@etu.univ-rouen.fr

² INRIA Nancy-Grand-Est & LORIA
615 rue du Jardin Botanique
54 600 Villers-lès-Nancy ; France
{yann.boniface, Alain.Dutech}@loria.fr

Résumé

Devant la diversité des données, il est indispensable de doter les systèmes artificiels d'une capacité d'association des informations. Le but du travail, que nous présentons dans cet article, est de doter un nouveau système neuromimétique d'une capacité d'association des informations corrélées venant de différentes entrées externes. Ce système a une architecture multimodale, composé de cartes CNFT constituées de neurones impulsifs, avec des connexions inter-cartes et intra-cartes. Nous présentons une étude des propriétés fonctionnelles de ce système et des conditions de convergence vers un état stable le préparant à faire émerger cette association et à l'apprendre. Nous présentons, ensuite, un modèle de la loi d'apprentissage STDP que nous avons adapté à la dynamique de notre système. Pour évaluer cet apprentissage, nous avons développé un scénario de mémorisation et de rappel que nous allons expliquer dans cet article.

Mots-clés : système neuromimétique, multimodalité, cartes CNFT, neurone impulsif, association, apprentissage, loi STDP, rappel.

1 Introduction

La multimodalité est un concept largement étudié dans le domaine des neurosciences. Dans ce cadre, les neuroscientifiques s'intéressent aux mécanismes permettant les associations entre différentes entrées sensorielles du cerveau [4]. Cette étude s'étend à l'informatique cognitive en cherchant à reproduire ce phénomène avec des systèmes artificiels. Un robot parviendra-t-il un jour à associer ses différentes entrées sensorielles

en une représentation unique et cohérente de son environnement ? Parviendra-t-il à apprendre ces représentations et à les généraliser ?

Certains travaux ont été effectués pour modéliser la multimodalité avec différents systèmes connexionnistes élémentaires [7, 8]. Le présent travail se concentre sur l'étude des associations multimodales avec un système connexionniste à codage temporel.

Ce système est composé de plusieurs cartes bidimensionnelles de neurones impulsionnels, cartes dont la topologie interne s'appuie sur la théorie des champs neuronaux continus (CNFT) [9, 10].

Notre modèle multimodal de cartes CNFT impulsionnelles, ici appelé *MS-CNFT* (*Multimodal, Spike, Continuous Neural Field Theory*), parce que temporel et fortement connecté, est un système très sensible à la chronologie des stimulations externes et internes.

Sa stabilisation s'obtient grâce à un paramétrage adapté. Après apprentissage, les informations émergentes doivent représenter les entrées sensorielles et leurs associations. Le but du travail présenté est d'étudier les conditions permettant à MS-CNFT l'apprentissage de ces associations. Nous avons choisi, comme loi d'apprentissage, une approximation d'apprentissage Hebbien à dépendance temporelle, la loi *STDP*[3] (Spike-Timing Dependent Plasticity) proposé dans [6].

Fonctionnellement, nous étudions les capacités du système, par les propriétés d'attention des champs de neurones, à transformer les entrées sensorielles en des informations cohérentes ; par le codage temporel et la relaxation, à associer ces entrées cohérentes ; par l'ajout d'une règle d'apprentissage, à apprendre ces associations et, par les propriétés de cohérences spatiales des champs de neurones, à généraliser à la fois la représentation des entrées et celle des associations ou contextes. La dynamique de convergence de notre système s'appuie sur une double relaxation induite d'une part par la connectivité bidirectionnelle entre la carte associative et les cartes de modalité, et d'autre part par la connectivité interne de chacune des cartes.

En terme de validation fonctionnelle de notre apprentissage, nous avons utilisé une méthode de *rappel* qui s'appuie sur l'évaluation de la reconstruction des entrées sensorielles apprises à partir d'entrées bruitées, incomplètes ou manquantes.

Enfin, notre objet est de montrer comment sont construites les différentes phases d'apprentissages, comment le système parvient à reconstruire les associations, et comment nous évaluons les apprentissages. Nous ne cherchons pas à perfectionner la notion de multimodalité par rapport aux applications qui existent, mais plutôt à adopter cette notion de multimodalité comme cadre d'étude. C'est une étude d'évaluation des capacités fonctionnelles d'un système combinant les propriétés topologiques des cartes CNFT et d'apprentissage temporel à partir de neurones impulsionnels, à faire émerger une information cohérente et à apprendre cette émergence dans un cadre multimodal.

Nous commençons par décrire la structure de notre modèle MS-CNFT. Nous expliquerons ses propriétés fonctionnelles. Puis, nous détaillerons son fonctionnement et son aptitude à générer des informations cohérentes, après une étape de paramétrage, à l'aide d'un exemple expérimental. Dans la deuxième partie de l'article, nous présentons le processus d'apprentissage, le modèle de la loi STDP adopté et son évaluation. Enfin, nous exposerons un exemple de simulation du processus d'apprentissage et ses résultats.

2 Système multimodal de cartes CNFT impulsives : MS-CNFT

2.1 Structure de MS-CNFT

MS-CNFT est un ensemble de cartes neuronales connectées, comme montré dans la figure 1, selon une architecture multimodale modélisant une version simple et naïve du cortex associatif. L'architecture multimodale contient trois éléments principaux ; les cartes unimodales, la carte associative et les connexions entre les cartes. Ces dernières sont des connexions bidirectionnelles, non symétriques¹, qui relient chaque neurone de la carte associative à tous les neurones des différentes cartes modales (connexions *feed-back*), en conséquence, chaque neurone de chaque carte modale est de même relié à tous les neurones de la carte associative (connexions *feed-forward*).

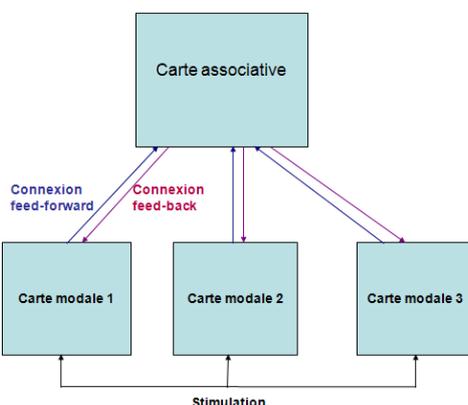


FIGURE 1 – Architecture globale du modèle multimodal

Contrairement au modèle biologique[1], il n'existe pas dans notre modèle de connexion directe entre les cartes modales, l'objectif étant -dans un premier temps- d'étudier les propriétés et conditions de convergence liées à l'utilisation de cette carte associative.

Les cartes dites *modales* représentent l'interface entre le système et le monde extérieur à travers laquelle le système reçoit un signal cohérent censément issu des stimulations sensorielles, elles représentent les entrées du modèle. Les informations sensorielles reçues se propagent vers la carte associative à travers les connexions feed-forward. Les neurones de la carte associative rétropropagent leur état, résultant de l'intégration des signaux reçus des différentes modalités, vers les cartes modales à travers les connexions feed-back. Ce double flux d'information est simultané et continu.

2.1.1 Topologies internes

Pour MS-CNFT, les cartes associatives et modales ont une topologie de type CNFT [10]. Cela signifie que les cartes de notre système sont des cartes bidimensionnelles, constituées de neurones dont l'activité est influencée par une fonction de voisinage. Au sein d'une même carte, les neurones ont un noyau de connexions latérales identiques, stéréotypées, de type *chapeau mexicain* (voir figure 2). Chaque neurone est exciteur

1. la valeur du poids de la connexion d'un neurone i vers un neurone j n'est pas forcément égale à celle de j vers i .

pour ses voisins proches, avec une influence décroissante avec la distance, et inhibiteur pour ses voisins plus éloignés, avec là aussi une influence décroissante avec la distance. Formellement, les connexions en chapeau mexicain se modélisent par une différence de gaussiennes (équation 1) permettant de déterminer le poids w de chaque connexion en fonction de la distance d du neurone cible de la connexion au neurone source de celle-ci. Les paramètres a et A (respectivement b et B) représentent le diamètre et l'amplitude de la gaussienne du voisinage excitateur (resp. inhibiteur) de la différence de gaussiennes, avec $a < b$ et $A \geq B$. Ces inégalités entre ces paramètres d'excitation et d'inhibition et leurs valeurs adéquates ont été déduites et fixées expérimentalement pendant notre étude selon la stabilité² du système.

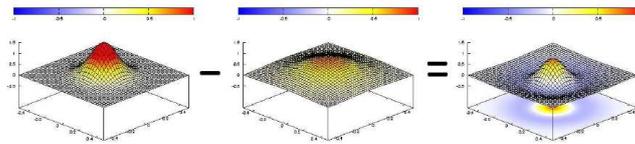


FIGURE 2 – La fonction de voisinage

$$w = w(d) = A \times e^{-\frac{d^2}{a^2}} - B \times e^{-\frac{d^2}{b^2}} \quad (1)$$

Quelles que soient les entrées sur une carte disposant de ce type de connexion, la compétition latérale issue de cette connectivité en différence de gaussiennes permet le *filtrage*. Le filtrage dans notre cas est le fait de ne faire émerger qu'un seul des stimuli d'entrée dans la carte *CNFT*. L'information émergente est sous forme d'un disque d'activités (des neurones actifs) entouré d'un cercle d'inactivités (neurones inhibés) que nous appelons *une bulle d'activités*, comme montré dans la figure 3.

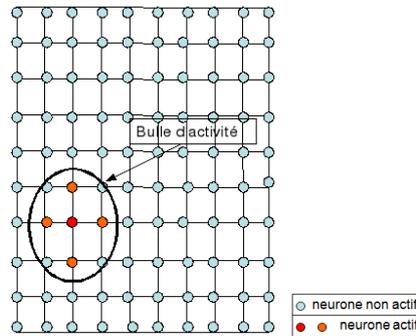


FIGURE 3 – Une carte *CNFT* avec une bulle d'activités en “chapeau mexicain”

Une bulle d'activités bien formée représente une information cohérente, débruitée et stéréotypée, que nous considérons, fonctionnellement, comme un signal d'*attention* du système sur la modalité filtrée par la carte.

D'un point de vue plus global, au niveaux du système complet et de ses cartes de types *CNFT*, connectées comme décrit dans la figure 1, l'activation du système, par ses entrées sensorielles, devrait faire émerger un état stable du système.

2. La notion de stabilité du système est décrite à la fin du même paragraphe.

Cette émergence, du point de vue de la dynamique des réseaux de neurones artificiels, résulte d'un double processus.

- Un processus de compétition interne entre les différents stimuli présentés aux cartes *CNFT* "modales", compétition due à la connectivité en noyau gaussien de nos cartes.
- Un processus de relaxation globale entre les différentes cartes du système, "modales" et "associative" (voir figure 1), porté par la connectivité entre ces cartes. Cette relaxation favorise l'émergence, dans chaque carte modale, d'une bulle d'activités cohérente avec les autres stimuli qui émergent dans les autres cartes de modalité du système.

Ce sont les relations entre les différentes cartes modales, par l'intermédiaire de notre carte associative, qui permettent fonctionnellement l'émergence d'un état cohérent du système que nous souhaitons apprendre avec notre système.

2.1.2 Neurones Impulsionnels

Nous utilisons un seul et unique modèle de neurone artificiel pour tout notre modèle, des neurones dits *impulsionnels* de type *Intègre et tire à fuite* (*Leaky integrate and fire*) [3].

Ce type de neurone, dérivé du modèle *Intègre et Tire*[5], est dit à codage temporel vu que son activité dépend de la proximité temporelle de ses entrées. Ce neurone est dit actif s'il produit à un temps précis une impulsion stéréotypée, appelée *spike*. Ce neurone passe en état actif si son potentiel, qui est la somme pondérée des impulsions reçues de ses entrées au cours du temps (équation 2), dépasse un certain seuil. L'aspect *fuite* de ce neurone est dû à sa dynamique temporelle, qui tend à faire baisser son potentiel au cours du temps. La somme temporelle des entrées, associée à la fuite, produit l'effet fonctionnel suivant : *plus la différence temporelle entre les impulsions reçues en entrée est grande, plus la probabilité que le neurone décharge est faible*.

$$\frac{dv}{dt} = -\frac{v}{\tau} + h + InputCurrent + SynapticCurrent \quad (2)$$

$$SynapticCurrent = \sum_i w_i \cdot S_i \cdot e^{-\frac{(t-t_i)}{\tau_i}} \quad (3)$$

$$S_i = S_i(t_{spike}) = e^{-\frac{(t_{spike}-t_{dernierSpike})}{\tau_i}} \cdot S_i(t_{dernierSpike}) + 1 \quad (4)$$

avec :

- τ représente la constante de temps du neurone x .
- $w(x - y)$ représente le poids de la connexion entre le neurone x et le neurone y , désigné ici par la fonction de voisinage (équation 1).
- h le potentiel de repos du neurone x (c'est le potentiel qu'il aurait sans stimulation et sans connexions latérales).
- $InputCurrent$ représente l'intensité des stimulation externes reçues par le neurone x à l'instant t .
- $SynapticCurrent$ représente la somme des stimulations reçues à travers les synapses connectant le neurone x au reste des neurones du système, pondérées par le poids de connexion (voir équation 3).
- Nous utilisons des synapses temporelles dites *exponentielles* [3]. Ces synapses transforment chaque impulsion électrique reçue du neurone *pré-synaptique* en un courant continu envoyé au neurone *post-synaptique*. La dynamique de ces

synapses est décrite dans l'équation 4 ($t_{dernierSpike}$ représente le dernier temps de décharge du neurone pré-synaptique précédant t_{spike}).

Ces mécanismes et ces structures ont des propriétés fonctionnelles importantes qui aident le système MS-CNFT à générer des informations cohérentes.

2.2 Dynamique du réseau et émergence

Les entrées sensorielles d'un modèle multimodal sont spatialement séparées, une entrée par carte unimodale (voir paragraphe 2.1). Ces entrées sont reçues simultanément sur les différentes cartes unimodales. Nous les considérons comme sémantiquement dépendantes car faisant partie d'une unique information globale. La fonction essentielle du modèle multimodal est d'*associer* ces informations sensorielles et de faire émerger l'information globale au sein du modèle. Cette association se réalise dans la carte associative après un échange d'information avec les cartes unimodales à travers les connexions feed-forward et feed-back.

2.2.1 Evaluation

Pour évaluer la qualité des associations suite à l'apprentissage, nous utilisons une méthode de *rappel*.

En bruitant ou en omettant une ou plusieurs entrées sensorielles, le système est appelé à reconstruire l'information globale à travers la régénération de l'association cohérente correspondante et précédemment apprise. Si nous considérons, par exemple, que nos entrées sensorielles représentent des caractéristiques d'un même objet, telles que sa forme, son odeur, sa couleur... Le système apprend, à travers l'application d'une loi d'apprentissage, à associer les différentes caractéristiques de cet objet. Par exemple, pendant la phase du rappel, nous choisissons d'omettre l'information qui représente la forme de l'objet. Dans ce cas, le système est appelé à faire émerger en premier lieu les entrées présentes reçues par les stimuli les plus cohérents pour le système global. En deuxième lieu, à travers la dynamique globale de circulation de l'information (relaxation intra-cartes et compétition inter-cartes) dans le système, ce dernier est appelé à reconstruire l'information représentant la forme de l'objet dans la carte modal correspondante. Nous expliquerons la phase de rappel dans le cas de notre système MS-CNFT dans le paragraphe 3.4.

2.2.2 Dynamique

Pour appliquer l'apprentissage dans le cas idéal, il faut que l'état global du système soit stable. C'est à dire que dans chaque carte CNFT, après stimulation et un temps de relaxation, une bulle unique apparaisse et que toutes les bulles soient stables³. Les propriétés des cartes CNFT doivent faciliter l'atteinte de cet état global stable :

- La connectivité latérale en noyau gaussien de nos cartes permet à celles-ci, après compétition et convergence entre les différents stimuli, de proposer au reste du réseau une réponse unique et *stéréotypée*⁴, et ce quelque soit l'intensité ou la forme des stimulus proposés. On peut ainsi considérer que nos cartes filtrent les entrées pour les proposer aux cartes associatives sous une forme normalisée.

3. Une bulle est dite stable si son centre ne change pas de position dans la carte et si elle reste présente tant que la stimulation associée est présente. Le centre de la bulle est le neurone le plus excité par les entrées et ses voisins.

4. Il convient de noter que l'obtention de cette propriété est très fortement dépendant des paramètres de notre noyau gaussien

- La propriétés de *résistance à la distraction*. Si une bulle d'activités émerge, avec son action d'inhibition, elle empêche toute autre bulle ou activités sous forme de bruit d'apparaître dans son champs d'inhibition.

Le respect de ces propriétés, dépend fortement du choix de la valeur des paramètres des gaussiennes définissant la connectivité interne des nos différentes cartes, soit les paramètres a, b, A, B . Nous avons choisi $b \gg a$ pour toutes les cartes. La raison de ce choix est d'avoir des champs d'inhibition maximalelement étendus pour les neurones actif. Avec cette condition, le voisinage des neurones les plus actifs empêche toute autre activité d'apparaître dans l'ensemble de la carte.

Outre ces propriétés spécifiques aux cartes *CNFT*, l'utilisation de neurones impulsionnels, avec le choix de modélisation des flux de communication proche du modèle biologique et l'utilisation d'un codage temporel, permet de pallier certains artefacts de la *CNFT* à codage fréquentiel. Lors de l'apparition *simultanée* de stimuli en entrée d'une carte modale, la compétition entre ces stimuli nécessite une *désynchronisation* des stimuli pour se mettre en place. L'apparition de deux stimuli trop proches spatialement dans une carte entraîne un phénomène de *fusion*. Le phénomène de fusion est sous forme d'un glissement spatial des deux stimuli pour former une unique bulle d'activités. Cette bulle d'activité se situe au milieu des deux stimuli. On perd ainsi la cohérence entre chaque pair de stimulus et bulle émergente associée. La dynamique temporelle des neurones impulsionnels rend improbables ces phénomènes de synchronisation.

2.2.3 Propriété d'amorçage des neurones impulsionnels

Ainsi construit, notre réseau convergera vers un état stable à partir des différents stimuli proposés aux différentes cartes d'entrées *sensorielles*. C'est cet état stable que notre système MS-CNFT doit apprendre en considérant les différentes entrées disséminées lors de la convergence comme corrélées et représentant ainsi une vision cohérente de l'extérieur du système. Lors de la convergence du système, la connectivité entre les cartes sensorielles et la carte associative permet à chaque carte sensorielle de recevoir, en plus de ces entrées, des signaux des activités du système et ainsi de favoriser le stimulus le plus en phase avec le reste du système au cours de sa compétition. L'utilisation de neurones impulsionnels nous permet d'amorcer cette relaxation globale du système.

En effet, pour parvenir à ce résultat, il est indispensable de diffuser à travers le réseau les différentes compétitions en cours sur les cartes sensorielles avant que celles-ci n'aient convergé et ne proposent plus qu'un unique signal au système. Les neurones impulsionnels permettent de diffuser des signaux à la carte associative dès la présence des stimuli. Aussi, quand les différentes bulles se forment et entrent en compétition, les neurones impulsionnels permettent de signaler le centre de cette bulle à la carte associative. Recevant ainsi des informations partielles des différentes entrées, la carte associative fait émerger un contexte global cohérent par son propre mécanisme de-compétition. C'est ce contexte, diffusé sur les cartes d'entrées, qui permet d'influencer chaque compétition sensorielle.

2.2.4 Cohérence spatiale et généralisation

La topologie interne des cartes *CNFT*, en noyau gaussien, implique une continuité spatiale entre les entrées (deux entrées proches sur une cartes coderont des stimuli proches). Dans notre système, cette continuité spatiale sera apprise au cours de la présentation des stimuli au système. L'utilisation de cette connectivité au niveau de la carte associative impliquera que les contextes codés dans cette carte répondront, eux-aussi,

à cette propriété. Ainsi deux contextes *proches* dans la carte associative, répondront à des entrées *proches*, c'est à dire à des stimulus proches dans les cartes sensorielles. Cette propriété permet à notre système de non seulement apprendre des contextes, ici définis comme des appariement cohérents de modalités, mais aussi de généraliser cet apprentissage. La cohérence spatiale va permettre à des contextes inconnus d'activer des zones de nos cartes proches de contextes préalablement présentés au système et donc cohérentes pour celui-ci.

2.3 Exemple de fonctionnement du système MS-CNFT

Pour illustrer notre modèle, nous présentons un exemple qui décrit le fonctionnement du système MS-CNFT hors apprentissage. Il montre le mode de circulation et d'apparition des flux d'informations.

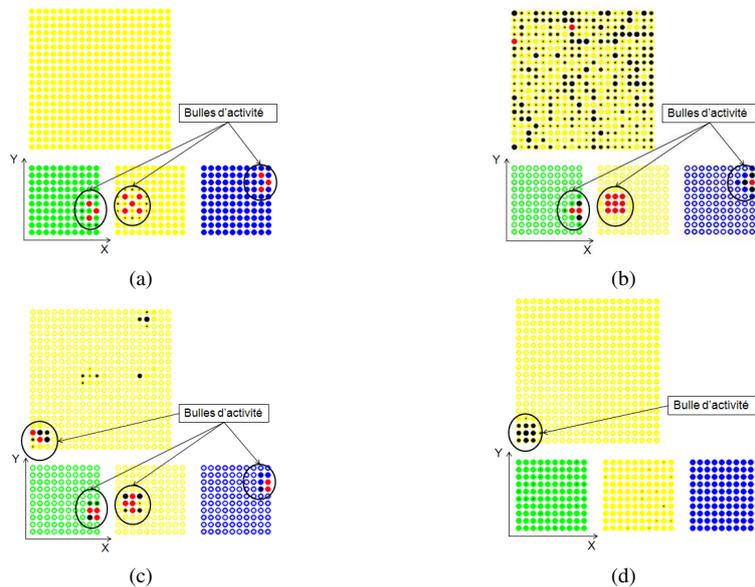


FIGURE 4 – Exemple de simulation avec le système MS-CNFT sans phase d'apprentissage. a) La stimulation des cartes de modalités aux positions (9,3),(2,4) et (9,7). b) La propagation des signaux vers la carte associative. c) La formation d'une bulle d'activité dans la carte associative. d) La neutralisation des stimulations

L'instance du système MS-CNFT que nous avons choisie pour nos simulations se compose de trois cartes de modalités et d'une carte associative, comme le montre la figure 4a. Les positions des stimulations externes sont repérées par leur centre, qui est la position du neurone qui reçoit la stimulation maximale. Grâce aux propriétés des cartes CNFT, la bulle d'activité qui émerge dans chaque carte de modalité se concentre sur la position de cette stimulation maximale. Les combinaisons d'entrées sensorielles diffèrent par les positions des stimulations dans les différentes cartes modales. Ces positions représentent des informations abstraites. Dans d'autres applications, et avec un ensemble de transformations, ces positions peuvent représenter des informations concrètes comme par exemple des caractéristiques d'un objet.

La figure 4a montre les positions des stimulations pour la combinaison d'entrées sensorielles choisie dans cet exemple. Dans la première carte modale (à gauche), la

position de la stimulation est (9,3) selon le repère montré dans la figure 4. Dans la deuxième carte modale, la position de la stimulation est (2,4) et de (9,7) dans la troisième carte modale. Les points colorés représentent des neurones. Les neurones colorés en rouge sont des neurones actifs. Les neurones colorés en noir sont des neurones dont le potentiel est inférieur au seuil d'activation. La taille des neurones noirs dans la figure 4 est proportionnelle à leur potentiel.

Les bulles d'activités résultantes sont repérées par des cercles sur la figure 4. La figure 4b montre l'effet des signaux ascendants qui se propagent vers la carte associative. Tous les neurones de la carte associative commencent à s'activer simultanément. Grâce aux propriétés de la CNFT, une seule bulle émerge dans la carte associative après un temps de relaxation comme le montre la figure 4c. Si les stimulations reçues par les cartes de modalité sont "éteintes" (il n'y a plus de stimulation externe), toute l'activité du système MS-CNFT s'éteint progressivement, comme le montre la figure 4d. Il faut pour cela choisir convenablement les paramètres du système car, pour certains paramétrages, les bulles d'activations peuvent s'auto-entretenir. Cette phase de neutralisation de l'activité du système est nécessaire pour permettre ultérieurement aux nouvelles bulles d'une nouvelle combinaison d'entrées sensorielles d'apparaître.

Comme nous allons le voir maintenant, le but de l'apprentissage sera de modifier la dynamique du réseau pour favoriser l'apparition d'une information cohérente associée aux différentes entrées sensorielles.

3 L'apprentissage du système MS-CNFT avec la loi STDP

Dans le domaine du connexionnisme, une loi d'apprentissage agit sur la plasticité des connexions. Ici, nous nous intéressons aux aspects multimodaux et donc à l'apprentissage de la mise en correspondance des différentes modalités. Ainsi, seules les valeurs de connexions *inter*-cartes sont apprises alors que les valeurs des connexions *intra*-cartes, contenues dans chaque carte CNFT, sont imposées et fixes.

Cet apprentissage se fait en renforçant les connexions feed-back et feed-forward entre les neurones des cartes distinctes dont l'activité concomitante crée les bulles d'activité.

Bien que la biologie distingue deux types de synapses (excitatrices et inhibitrices) articulant les connexions entre les neurones, nous n'utilisons ici que des synapses excitatrices, ce qui correspond à des poids de connexions feed-back et feed-forward toujours positifs. En effet, empiriquement, nous avons constaté que l'ajout de connexions inhibitrices complexifie le modèle sans améliorer significativement ses capacités.

3.1 Principe de STDP

STDP est l'acronyme de Spike-Timing Dependent Plasticity [6]. C'est une loi d'apprentissage biologiquement inspirée. Cette loi est une déclinaison temporelle de la loi Hebbienne. Le principe de la loi Hebbienne dit que si l'activité de deux neurones connectés est corrélée alors la synapse qui les associe voit son poids augmenter. Dans le cadre de la loi STDP, la corrélation entre les neurones connectés est calculée en fonction de la chronologie de leur activité. Le principe ici est de favoriser la synchronisation entre les neurones corrélés. La modification de la plasticité de la synapse dépend d'une fonction de variation du poids synaptique, appelée ΔW , qui s'inspire de données biologique.

Selon la loi STDP, ΔW est fonction de la proximité temporelle ΔT entre l’instant de décharge du neurone pré-synaptique (t_{pre}) et l’instant de décharge du neurone post-synaptique (t_{post}), $\Delta T = t_{post} - t_{pre}$. D’un point de vue fonctionnel dans le cas des synapses excitatrices, si $\Delta T > 0$ on considère que le neurone pré-synaptique est en partie responsable du déclenchement de l’activation du neurone post-synaptique. Dans ce cas, pour augmenter cette corrélation portée par le poids de la synapse associée, il faut renforcer la synapse. Ce cas est appelé *potentiation*. Si $\Delta T < 0$, l’activation du neurone post-synaptique précède l’activation du neurone pré-synaptique et elle n’est pas considérée comme utile pour le neurone post-synaptique. Dans ce cas, le poids de la synapse associée doit être atténué et la synapse est affaiblie. Ce cas est appelé *dépression*.

A priori, l’utilisation de la STDP est d’autant plus efficace que les flux d’information sont cohérent et plus stables. Cette état de stabilité est nécessaire pour concentrer les modifications des poids de connexion là où ces modifications ont vraiment un sens et ne pas essayer d’apprendre du “bruit”. L’utilisation de cartes CNFT, favorisant l’apparition rapide de bulles d’activité cohérentes, prend ainsi tout son sens. Il semblerait alors logique de ne déclencher la STDP après un certain temps, dit temps de relaxation, pour assurer que l’activité des cartes CNFT soit stabilisée. Néanmoins, des expériences préliminaires nous ont montré à l’inverse que l’utilisation de la STDP dès l’apparition des entrées sensorielles améliorerait l’efficacité de l’apprentissage. Nous n’avons donc pas instauré de délais entre la présentation des entrées sensorielles et l’activation de la STDP. Ceci se reflète dans le scénario de mémorisation et de rappel que nous avons développé et utilisé (voir le paragraphe 3.4).

3.2 Le modèle de la STDP adopté

Il y a plusieurs modèles de la fonction de variation du poids ΔW qui sont définis dans la littérature des neurosciences. Nous utilisons le modèle représenté par la figure 5, inspiré du modèle de David Meunier [6], pour notre système MS-CNFT. La fonction de variation des poids ΔW est définie pour un intervalle de valeurs de proximité temporelle ΔT comprises entre -0.5ms et 0.1ms , ce que nous appelons la fenêtre temporelle. Cette fenêtre temporelle est définie en tenant compte de la valeur de la période réfractaire⁵, égale à 0.052ms , dans notre système MS-CNFT. Comme illustré dans la figure 5, la fonction de potentiation ($\Delta W > 0$) vaut $\Delta W = -10 \times \Delta T + 1$ et la fonction de dépression ($\Delta W < 0$) vaut $\Delta W = -1 \times \Delta T - 0.5$. Cette formulation des poids assure que, pour tout ΔT de l’intervalle $[0, \frac{1}{18}]$, $\Delta W(\Delta T) > \Delta W(-\Delta T)$. Comme nous allons l’expliquer en section 3.3, cette dernière propriété est très importante dans le cas de connexions bi-directionnelle (feed-forward et feed-back) pour éviter des phénomènes de désynchronisations de neurones pourtant corrélés.

Le système d’équations 5 présente les équations de mise à jour des poids synaptiques excitateurs selon la fonction de variation des poids synaptique ΔW (figure 5). C’est le système d’équations établi par David meunier [6]. Nous avons choisi les valeurs des paramètres suivantes : la valeur maximale des poids $W_{max} = 0.5$, la fréquence d’augmentation des poids $\alpha_{exc_plus} = 0.01$, la fréquence de réduction des poids $\alpha_{exc_minus} = 0.05$. Par rapport aux valeurs classiques, nous avons choisi une valeur réduite de la valeur maximale des poids et une valeur élevée de la fréquence de réduction des poids pour réduire au maximum la marge de renforcement des synapses

⁵ la période réfractaire est la durée du temps élémentaire pendant laquelle le neurone reste inactif après avoir été actif. Le modèle de neurone utilisé à été modifié pour tenir compte de cette période réfractaire.

excitatrices afin d'éviter la saturation du système.

$$W_{ij}(t + \delta t) = \begin{cases} W_{ij}(t) + \alpha_{exc_plus} W_{ij}(t) \Delta W & si \ \Delta W \geq 0 \\ W_{ij}(t) + \alpha_{exc_minus} (W_{max} - W_{ij}(t)) \Delta W & si \ \Delta W \leq 0 \end{cases} \quad (5)$$

3.3 Problème d'influence mutuelle

Le fait que les connexions entre les cartes modales et la carte associative soient bidirectionnelles peut poser un problème lors de l'utilisation de la STDP : 2 neurones pourtant corrélés peuvent voir leurs poids de connexion diminuer et ainsi se désynchroniser.

Illustrons ce phénomène à travers un scénario de modification des poids synaptiques présenté en figure 6. N_{CM} est un neurone situé dans une bulle d'activité d'une carte modale. N_{CA} est un neurone situé dans une bulle d'activité associative. S_{FF} est une synapse feed-forward connectant N_{CM} et N_{CA} . S_{FB} est une synapse feed-back connectant N_{CA} et N_{CM} . Si N_{CM} décharge à t_1 , il déclenche l'activité de N_{CA} qui décharge à t_2 , avec $t_1 < t_2$. Selon le principe de la loi STDP, le poids de S_{FF} sera augmenté et le poids de S_{FB} sera atténué. Quand N_{CA} décharge à t_2 , il déclenche l'activation de N_{CM} qui décharge à t_3 , avec $t_2 < t_3$. Alors, le poids de S_{FF} sera atténué et le poids de S_{FB} sera augmenté. Ainsi, les poids des deux synapses seront augmentés et atténués quasiment en même temps. Or, dans ce cas, nous cherchons à globalement renforcer les connexions entre la bulle d'activité associative et les bulles d'activité modales. C'est pourquoi nous tenons à garder le renforcement d'un poids toujours supérieur à son atténuation pour des faibles valeur de proximité temporelle entre deux neurones.

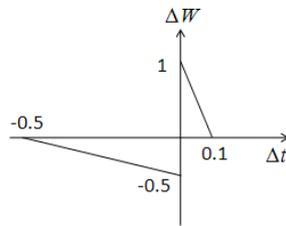


FIGURE 5 – Le modèle STDP avec des valeurs adaptées au système MS-CNFT de la fonction de variation des poids synaptiques excitatrices associé à la loi STDP

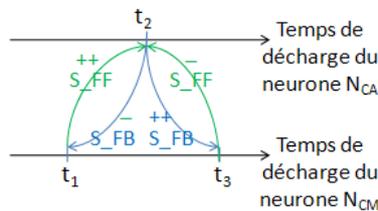


FIGURE 6 – Un scénario de modification des synapses feed-forward et feed-back

3.4 Méthode d'évaluation de l'apprentissage

Le système est appelé à apprendre pour chaque combinaison d'entrées sensorielles l'association correspondante. Pour évaluer cet apprentissage, nous avons choisi dans un premier temps d'adopter la méthode de rappel proposée dans la thèse de Reynaud [8]. Le principe de la méthode, une fois qu'une combinaison d'entrées sensorielles est apprise sous sa forme complète, consiste à essayer de reconstruire cette combinaison si elle se présente sous une forme incomplète ou bruitée. La figure 7 présente une illustration de la phase de rappel dans le cas de notre système MS-CNFT. Supposons que le système ait appris une combinaison $C = (ES_1, ES_2, ES_3)$, telle que ES_i présente l'entrée sensorielle reçue par la carte de modalité i . Pendant la phase de rappel, ES_2 est absente, ES_1 et ES_3 sont présentes. L'information se propage de la carte de modalité 1 et de la carte de modalité 3 vers la carte associative. Une fois la bulle associative formée, elle propage son effet vers les cartes de modalités y compris la carte de modalité 2 à travers les connections feed-back. Ainsi, une bulle d'activité devrait se former dans cette carte de modalité 2. Pour affirmer que le système a appris la combinaison C , il faut qu'une bulle se forme à la position de l'entrée sensorielle absente ES_2 .

Nous avons établi un scénario de simulation pour appliquer la loi d'apprentissage et pour évaluer son effet sur le système MS-CNFT. Nous utilisons une base d'apprentissage constituée de N_c élément, chaque élément étant une combinaison d'entrées sensorielles.

Comme indiqué dans la figure 8, le scénario se compose de trois phases essentielles : la phase d'apprentissage (paragraphe 3.1), la phase de rappel (paragraphe 3.4) et la phase de neutralisation (toutes les entrées stimulatrices sont remises à zéro comme expliqué dans le paragraphe 2.3). Chacune de ces phases est associée à une combinaison d'entrées sensorielles. Ainsi que nous l'avons signalé, lors d'une phase d'apprentissage, l'apprentissage est déclenché dès que les cartes modales sont stimulées par la combinaison d'entrée et il s'arrête avec la phase de neutralisation de cette combinaison sensorielle.

Formellement, un scénario d'apprentissage, illustré sur la figure 9, est définis par les notions suivantes (n et m étant définis expérimentalement), où N_c est le nombre d'entrées sensorielles qui composent la base d'apprentissage :

- Une sous-itération d'apprentissage (SI) : une phase d'apprentissage (de durée D_{app}) + une phase de neutralisation.
- Une itération d'apprentissage (IA) : $N_c \times$ sous-itérations d'apprentissage (avec tirage aléatoire sans remise de l'ordre des combinaisons).
- Une sous-itération de rappel (SR) : une phase de rappel + une phase de neutralisation.
- Une itération de rappel (R) : $N_c \times$ sous-itération de rappel.
- Une tentative de mémorisation (TM) : $n \times$ itération d'apprentissage + une itération de rappel.
- Un scénario d'apprentissage : $m \times$ tentative de mémorisation.

3.5 Résultats de simulation

Dans cette partie, nous présentons une simulation de notre scénario de mémorisation et de rappel.

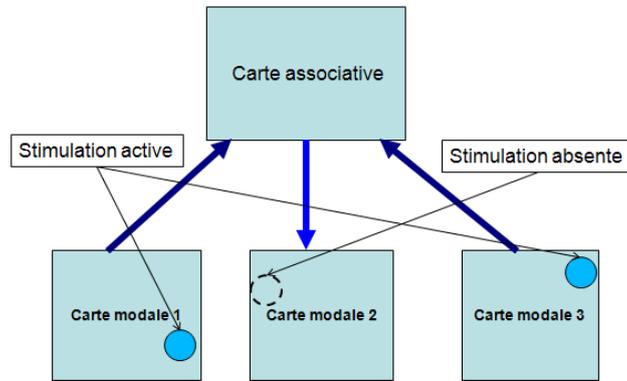


FIGURE 7 – La phase de rappel

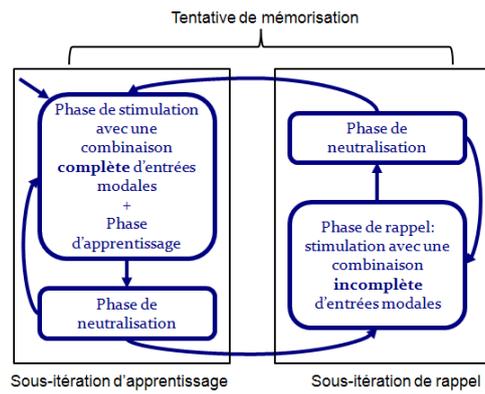


FIGURE 8 – Le scénario automatisé de mémorisation et de rappel pour le système MS-CNFT

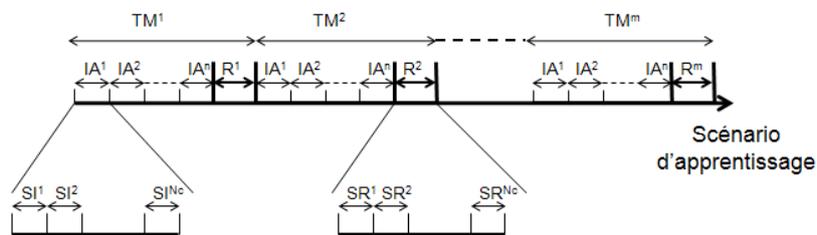


FIGURE 9 – L'évolution du scénario de mémorisation et de rappel

3.5.1 Paramètres des simulations

La base d'apprentissage se compose de trois combinaisons d'entrées sensorielles C_1 , C_2 et C_3 . Les paramètres du scénario de mémorisation et de rappel sont $D_{app} = 25$, $n = 2$ et $m = 5$. Les cartes de modalités sont composées de 100 neurones (10×10) et les paramètres de la fonction de voisinage pour ces cartes de modalité ont les valeurs suivantes : $a_{cm} = 4$, $A_{cm} = \frac{1}{8}$, $b_{cm} = 20$, $B_{cm} = \frac{1}{8}$. La carte de modalité comporte 400 neurones (20×20) et ses paramètres de la fonction de voisinage ont les valeurs suivantes : $a_{ca} = 5$, $A_{ca} = \frac{1.5}{8}$, $b_{ca} = 60$, $B_{ca} = \frac{1}{8}$. Ces valeurs des paramètres du système MS-CNFT ont été fixées expérimentalement après un grand nombre de tests, en s'appuyant sur des évaluations visuelles de la qualité des associations multimodales apprises. L'évolution du système MS-CNFT ne dépend pas que de ces paramètres mais dépend également de la taille des cartes et de certaines constantes associées aux connexions entre les neurones.

Pour l'exemple de simulation que nous présentons dans ce paragraphe, nous avons choisi d'éliminer une entrée pendant la phase de rappel pour chaque combinaison d'entrées sensorielles. Le tableau 1 présente l'entrée sensorielle absente pour chaque combinaison.

C_1	C_2	C_3
ES_1	ES_3	ES_2

TABLE 1 – L'entrée sensorielle absente pour chaque combinaison de la base d'apprentissage

3.5.2 Résultats

La figure 10 présente un "raster plot" qui montre l'activité de tous les neurones pendant toute la simulation, correspondant à un peu plus de 5s de temps virtuel. Chaque neurone est représenté par son numéro sur l'axe des ordonnées. Les neurones de la carte associative et les neurones de chaque carte de modalité sont séparés par des traits horizontaux. L'axe des abscisses représente le temps en *ms*. Cette figure montre tous les instants de décharge des neurones. Les points concentrés représentent les bulles d'activité. Les bulles, auxquelles nous nous intéressons, sont entourées par des cercles colorés. Chaque combinaison d'entrées a sa propre couleur de bulles d'activité associative et modale (C_1 : bleu, C_2 : mauve, C_3 : vert). Les bulles modales encerclées correspondent aux bulles de références et aux bulles régénérées par le système pendant les phases de rappel. Ces bulles peuvent être repérées sur les bandes des cartes modales (CM0, CM1, CM2). Les itérations d'apprentissage et les itérations de rappel sont séparées par des traits verticaux. La première itération d'apprentissage, appelée *REF*, représente les positions de référence de toutes les bulles d'activité modales qui correspondent aux entrées sensorielles de C_1 , C_2 et C_3 . Nous notons les itérations de rappel par R_1, R_2, R_3, R_4 et R_5 . Nous remarquons que le système MS-CNFT régénère les bulles absentes aux positions correctes dans les dernières phases de rappel. Pour C_1 , il régénère une bulle correcte dans R_5 . Pour C_2 , il régénère une bulle correcte dans R_5 . Pour C_3 , il régénère une bulle correcte dans R_3, R_4 et R_5 .

D'après les positions des bulles d'activité pendant les phases de rappel présentées dans cet exemple de simulation, le système arrive à mémoriser et à reconstruire correctement les entrées sensorielles. Ces résultats positifs sont obtenus après la réalisation

d'un grand nombre d'expériences de réglage des paramètres du système (les paramètres de la fonction de voisinage de la CNFT et les paramètres d'apprentissage). Cela montre que l'application de la loi STDP avec un système multimodal de cartes CNFT impulsives est possible. Néanmoins, nous n'avons toujours pas de moyen automatique pour fixer les valeurs des paramètres du système d'une manière à réduire au maximum l'erreur pendant la phase du rappel. Jusqu'à maintenant, nous ne pouvons pas décider *automatiquement* quand et pour quelle durée le système doit apprendre ⁶.

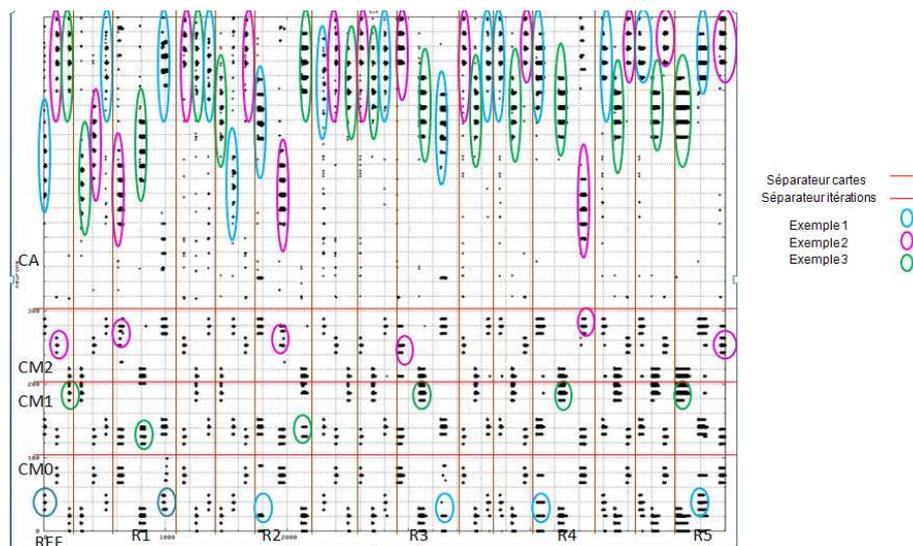


FIGURE 10 – L'activité des neurones du système MS-CNFT durant un exemple de simulation. Exemple 1 : C_1 , stimulation absente sur CM0. Exemple 2 : C_2 , stimulation absente sur CM1. Exemple 3 : C_3 , stimulation absente sur CM2.

4 Discussion

Dans cet article nous avons présenté un nouveau système neuromimétique que nous avons appelé MS-CNFT. C'est une combinaison de systèmes neuronaux précédemment établis [10, 7, 6] qui sont les neurones impulsifs, les cartes CNFT, le modèle multimodal et la loi d'apprentissage STDP. Dans notre cas, les cartes CNFT sont des cartes bidimensionnelles constituées d'un ensemble de neurones impulsifs interconnectés. Les connexions entre les neurones d'une même carte sont caractérisées par une fonction de voisinage, identique pour tous les neurones, ayant un effet excitateur pour les neurones les plus proches d'un neurone actif et inhibiteur pour les plus éloignés. Dans notre travail, nous avons exploité cette propriété de voisinage des cartes CNFT et le modèle d'activité des neurones impulsifs pour faire émerger une forme d'activité collective appelée "bulles d'activité". Le but de notre travail était de doter un système multimodal de cartes CNFT impulsives d'une capacité d'association d'un ensemble d'informations venant d'entrées différentes par stimulations externes et qui sont sémantiquement corrélées. Ces entrées et leurs associations sont représentées dans le système MS-CNFT par des bulles d'activité. Nous avons étudié les conditions

6. ce qui correspond aux paramètres D_{app} , m et n

de convergences du système qui mènent à un état de stabilité le préparant à faire émerger cette association et à l'apprendre.

Pour appliquer et évaluer cet apprentissage, nous avons développé un scénario de mémorisation et de rappel. Ce scénario consiste en premier lieu à mémoriser, par apprentissage, la configuration du système lors de l'association des entrées et en deuxième lieu à omettre ou bruiteur une ou plusieurs entrées que le système doit reconstruire, ce que nous avons appelé le phénomène de rappel. La loi d'apprentissage que nous avons appliquée est la loi STDP. C'est une loi hebbienne qui renforce les connexions entre les neurones selon la proximité temporelle de leur activité. Cette propriété temporelle aide le système à mémoriser les corrélations locales et globales de son activité neuronale lors des stimulations. Nous avons conçu un modèle de la loi STDP adapté à notre système MS-CNFT inspiré du modèle de David Meunier [6]. Le chronogramme d'activité ("raster plot") des neurones du système, présentant l'application d'une instance du scénario de mémorisation et de rappel, montre bien que le système est capable de se rappeler la position des bulles d'activité manquantes et par la suite d'apprendre des régularités d'information avec la loi STDP.

Avec la loi STDP, pour deux neurones connectés, plus leur activité temporelle est corrélée plus la connexion est renforcée. Cette propriété provoque parfois l'auto-entretien de l'activité des neurones. Cette conséquence peut mener le système à un état de saturation. Pour éviter ce problème, nous avons introduit une phase de neutralisation. Pour augmenter la performance du rappel et éviter la saturation du système, il faut également trouver une combinaison convenable des valeurs des paramètres du système : la durée et le nombre de répétition de la phase d'apprentissage, la durée de neutralisation... Autrement dit, il s'avère nécessaire d'introduire un deuxième mécanisme qui évalue implicitement le rappel du système MS-CNFT et gère en fonction de cette évaluation les différentes phases du système. Nous estimons, selon une étude préliminaire, que la loi d'apprentissage par renforcement est applicable dans ce cas. Avec cette loi, le système apprenant est considéré comme un agent qu'il faut récompenser ou pénaliser selon son évolution vers un but bien déterminé. Cette approche a prouvé son efficacité dans un cadre similaire dans les travaux de Florian [2] pour entraîner un réseau de neurone impulsions multi-couches. L'exploration approfondie de cette approche est une perspective de ce travail.

Une deuxième perspective indispensable est le choix de la méthode d'évaluation de l'erreur. La méthode d'évaluation que nous avons présentée dans cet article est sous forme d'une analyse qualitative visuelle des chronogrammes d'activité des neurones. L'évaluation de l'erreur de l'apprentissage reste difficile à représenter et à interpréter. Pour définir l'erreur et pouvoir l'exploiter dans l'amélioration de l'apprentissage, des fonctions de calcul quantitatif, telle que la distance euclidienne entre la position de l'entrée sensorielle absente et la position de la bulle d'activité rappelée, peuvent être élaborées. Nous pouvons également tester la robustesse du système MS-CNFT en introduisant des perturbations comme le bruit dans les cartes de modalité ou en changeant le nombre de ces cartes sensorielles.

Références

- [1] J. DRIVER et T. NOESSELT, *Multisensory interplay reveals crossmodal influences on 'sensory-specific' brain regions, neural responses, and judgments*, *Neuron*, vol. 57, no. 1, pp. 11–23, January 2008.

- [2] R. V. FLORIAN, *Reinforcement learning through modulation of spike-timing-dependent synaptic plasticity*, *Neural Comput.*, vol. 19, no. 6, pp. 1468–1502, 2007.
- [3] W. GERSTNER et J. SJOSTROM, *Spike-timing dependent plasticity*, *Scholarpedia*, vol. On line, 2010.
- [4] C. KAYSER et N. K. LOGOTHETIS, *Do early sensory cortices integrate cross-modal information ?*, *Brain Structure and Function*, vol. 212, no. 2, pp. 121–132, septembre 2007.
- [5] L. LAPICQUE, *Recherches quantitatives sur l'excitation électrique des nerfs traitée comme une polarisation*, *J. Physiol. Pathol. Gen.*, vol. 9, p. 620 :635, 1907.
- [6] D. MEUNIER, *Une modélisation évolutionniste du liage temporel*, Thèse de doctorat en informatique, Université Lyon 2, Ecole Doctorale "Cerveau et Cognition", oct 2007. Advisor : Hélène Paugam-Moisy, External reviewers : Marc Schoenauer and Catherine Tallon-Baudry.
- [7] A. REGHIS, *Un réseau de neurones pour des associations multimodales*, Mémoire de master en informatique, Université Henri-Poincaré Nancy-I, juin 2003.
- [8] E. REYNAUD, *Modélisation connexionniste d'une mémoire associative multimodale*, Thèse de doctorat en informatique, Institut National Polytechnique de Grenoble, octobre 2002.
- [9] N. P. ROUGIER et J. VITAY, *Emergence of attention within a neural population*, *Neural Networks*, 2005.
- [10] J. VITAY, *Emergence de fonctions sensorimotrices sur un substrat neuronal numérique distribué*, Thèse de doctorat en informatique, Université Henri-Poincaré Nancy-I, Juin 2006.