

COMPUTAÇÃO EM ASSEMBLEIAS NEURAIS PULSADAS

João Ranhel*

*Departamento de Eletrônica e Sistemas / UFPE, Recife, Brasil

jranhel@ieee.org

Abstract: Neural assembly computing (NAC) is an approach that intends to explain how spiking neural assemblies can represent, process information, memorize, and control outputs (or behaviors) by means of branching and inhibiting neural coalitions. In this article an overview of neural assembly concepts is presented. The aims of this research field are discussed, as well as possibilities for investigation in this research area are pointed out.

Palavras-chave: neural assembly computing, bistable assembly, spiking neural networks, neural coalition.

Introdução

Como neurônios representam objetos e estados do mundo (exterior e interior)? Como o processamento que eles executam sobre tais informações resulta em pensamento, raciocínio, julgamento, decisão, etc.? Essas são questões que há muito intrigam a comunidade científica. Em 1949 [1], D. Hebb propôs que a formação de assembleias neurais (*cell assembly*) é responsável por representar objetos e conceitos [2]. Posteriormente, evidências comprovaram que neurônios codificam informações de forma esparsa (*sparse coding* [3], [4]) em vez de um único neurônio representar um conceito, como proposto na noção da ‘*grandmother cell*’ [5]. “*Recent physiological recordings from sensory neurons have indicated that sparse coding could be a ubiquitous strategy employed in several different modalities across different organisms.*” [6].

Na codificação esparsa um grupo de neurônios representa uma informação por meio da atividade grupal durante um intervalo de tempo. Em outras palavras, uma das hipóteses é que eles formem coalizões pulsando de forma síncrona ou travada no tempo (*time-locked*). Apesar de a ideia ser amplamente aceita, essa área de pesquisa só ganhou impulso a partir do surgimento de técnicas de gravação massiva de atividades neurais, associadas a algoritmos e ferramentas estatísticas, desenvolvidas a partir da década de 1990 (ver [2], [7], *review* em [8]). Pesquisas em cérebros *in vivo* e em atividade estão em franco progresso, envolvendo gravação, identificação de células e/ou grupos, ou a determinação de pertinência entre células e coalizões, etc. Apesar dos avanços, persiste a dificuldade em estipular relações causais entre células e assembleias nas redes neurais biológicas [9]. Neste texto são

sinônimos: *coalizão, assembleia e evento*; porque um evento é tomado como um padrão de disparo num grupo de neurônios, que é a própria definição de assembleia .

Formação de Assembleias – O tempo de atraso na propagação de potenciais de ação em axônios pode não ser um fenômeno indesejado. Ao contrário, a natureza pode ter tirado proveito dessa propriedade para criar uma máquina computacional. Isoladamente, o atraso na propagação não faz muito, mas associado a pesos sinápticos e a mecanismos de plasticidade fazem emergir grupos de células disparando conjuntamente e interagindo uma com as outras. Esse conjunto de fatores cria um tipo de processamento de informação chamado computação por assembleias neurais (*Neural Assembly Computing* - NAC).

Amplamente aceita, a noção de que pesos sinápticos são reforçados à medida que neurônios disparam em conjunto é conhecida como a ‘*regra hebbiana*’. Hebb [1], além de prever o fenômeno das assembleias, previu também o mecanismo que permite tais agrupamentos. Sua teoria pode ser resumida na frase: “*cells that fire together, wire together*”. Tais ideias eram avançadas para a época, ficando para gerações futuras investigar como ocorrem tais representações, como as interações entre coalizões resultam processamento de informações, e como isso resulta em comportamentos.

Ainda que pesquisas evidenciem que representações se deem por meio de assembleias, um fator importante é compreender *como* as redes neurais *processam* tais codificações esparsas de forma que este tratamento resulte em ativação de efeitos, pensamentos, tomadas de decisão, etc. Ou seja, falta investigar de que forma as coalizões interagem entre si de forma a resultar relações causais, controle e computação. Existe uma intuição de que coalizões neurais representam e computam, mas há pouca explicação sobre os mecanismos pelos quais tais operações acontecem. Nas palavras de Buzsáki [8] :

“*A widely discussed hypothesis in neuroscience is that transiently active ensembles of neurons, known as ‘cell assemblies,’ underlie numerous operations of the brain, from encoding memories to reasoning. However, the mechanisms responsible for the formation and disbanding of cell assemblies and temporal evolution of cell assembly sequences are not well understood.*”

Em 2011 foi apresentada a abordagem NAC, cuja proposta é investigar como ocorrem tais processamentos [10], [11]. A abordagem mostra que grupos de neurônios

executam funções lógicas estatísticas ao formarem coalizões, e que as coalizões também formam memórias de curto e longo-prazo ao reverberarem, e ainda que coalizões podem se ramificar e/ou inibir assembleias ativas. A abordagem mostra ainda como tais interações criam máquinas de estados que resultam em processamento de informações.

Neural Assembly Computing

Uma coalizão (assembleia) é um evento de disparos de um grupo de neurônios em padrões síncronos ou travados no tempo. São fenômenos efêmeros que acontecem durante curto intervalo de tempo no qual as células participantes disparam seus potenciais de ação. Porém, qual o sentido de um grupo de células disparar e em seguida tal fenômeno simplesmente desaparecer?

Memória Biestável – Uma hipótese na tentativa de responder tal questão é que coalizões reverberam e formam laços biestáveis para memorizar informação (ver [12]). Laços biestáveis formam memórias de ação instantânea sem envolver mecanismos de plasticidade celular, sináptico ou topológico.




Figura 1 – Raster Plot ilustrando assembleia biestável.

Didaticamente, a Figura 1 ilustra num ‘*raster plot*’ a ocorrência de uma assembleia (P) com três neurônios: P_1 , P_2 e P_3 disparando *time-locked* (i.e. toda vez que P dispara esta relação temporal se repete). Essa coalizão dispara (causa) a assembleia A, que por sua vez dispara a assembleia B que retroalimenta e dispara A, formando uma coalizão biestável A-B (BNA – *Bistable Neural Assembly*). Esse núcleo forma uma memória de um bit. Na prática, usa-se de 10 a 200 neurônios por coalizão; portanto, a figura é apenas ilustrativa e didática.

Funções Lógicas Estatísticas – É possível fazer uma analogia sobre ‘funções lógicas estatísticas’ com as regras de formação de assembleias. De uma forma generalizada, um evento Y pode ser gerado a partir de uma coalizão: $(Y = X)$. Isso significa que assembleias podem disparar outras coalizões diretamente, como P disparando A na Figura 1. Elas também podem inibir e vetar outras assembleias: $(\bar{Y} = Z)$, ou seja, a coalizão Y é inibida (não ocorre) devido à ocorrência do evento Z.

Mais ainda, uma nova assembleia pode ser gerada a partir da interação de dois ou mais eventos, e dois tipos de relações podem acontecer: a disjunção e a conjunção.

Na *disjunção*, qualquer das coalizões, sozinha, pode gerar um novo evento: $(Y = A + B + \dots + N)$, sendo Y

um novo evento formado pela ocorrência de qualquer das coalizões A OR B ... OR N. Isso equivale à função lógica OR, embora seja uma função estatística, porque não é necessário que todos os neurônios da assembleia disparem; apenas a grande maioria deles, um número suficiente que seja capaz de causar o disparo de Y.

Já na *conjunção* é necessário acontecer coincidência no disparo das coalizões: $(Y = A \bullet B \bullet \dots \bullet N)$, sendo Y um novo evento formado a partir da coincidência nos disparos de A AND B ... AND N. Esta equivale à função lógica AND, porém, de natureza estatística, uma vez que nem todos os neurônios precisam disparar; apenas um número suficiente que assegure que a coalizão será interpretada como ativa.

Por outro lado, quando ocorre inibição ou veto pode-se dizer que a função lógica executada pela coalizão é a negação (NOT lógico). As interações e combinações das funções NOT, AND, e OR criam as funções NOR e NAND. Essas funções associadas com as memórias biestáveis (BNA) formam o cerne da abordagem NAC. Sem surpresa, esses elementos são os componentes básicos de criação de qualquer sistema digital.

Em resumo, assembleias podem retroalimentar-se, formando laços biestáveis que reverberam e memorizam o evento que as criou, tornando-se assim uma memória (representação) de curto ou longo-prazo que retém informações, conceitos, estados de mundo; funcionando como *flip-flop*, elemento chave na criação de máquinas de estados finitos e de computadores digitais.

Além disso, cada formação de coalizão pode gerar ramificações e disparar novos eventos (ao executarem as funções OR, AND), ou pode inibir ramos ativos (ao executarem NOT, NOR, NAND). Ramificações tornam-se processos paralelos, vetos obstruem novos eventos ou extinguem ramos ativos. Essa interação entre coalizões resulta em processamento, controle de fluxos de informações, e criação de sequências em cadeias causais de eventos que formam um tipo de ‘algoritmo’ paralelo (mais detalhes sobre esses princípios em [11]).

Controle de Processos – A Figura 2 ilustra como coalizões podem executar processamentos paralelos. A ilustração mostra o excerto de uma máquina de estados bem mais complexa, executando algoritmos paralelos.

Considere um agente (organismo, robô, personagem virtual) com um sensor capaz de gerar eventos internos assim que atinja baixos níveis de energia. Esse evento será chamado FOME. Na figura vê-se que a ocorrência do padrão de disparo FOME é suficiente para disparar duas coalizões biestáveis: a BNA A1-A2 (considere como representando ATENÇÃO) e a BNA F1-F2 (que pode representar FORRAGEAR, buscar alimento). Se A1-A2 reverberam a BNA ATENÇÃO fica ativa, e se F1-F2 reverberam FORRAGEAR fica ativa.

Denomina-se (*branching*) a ação de uma assembleia ao disparar novas coalizões. Cada ramo pode controlar um novo processo paralelo, por exemplo, um ramo pode ativar um estado interno ou ligar um CPG (*central pattern generator* – ver [13]). Note que ATENÇÃO se ramifica em virtude da necessidade de controlar dois tipos de estímulo: visual e olfativo, para que o agente

mantenha atenção a padrões de disparos que indiquem imagens e cheiros de alimentos. Há estudos conhecidos sobre coalizões representando odores em insetos (ver [14], [15]) e outros organismos. Embora simplificado, o exemplo foi inspirado nessas evidências biológicas.

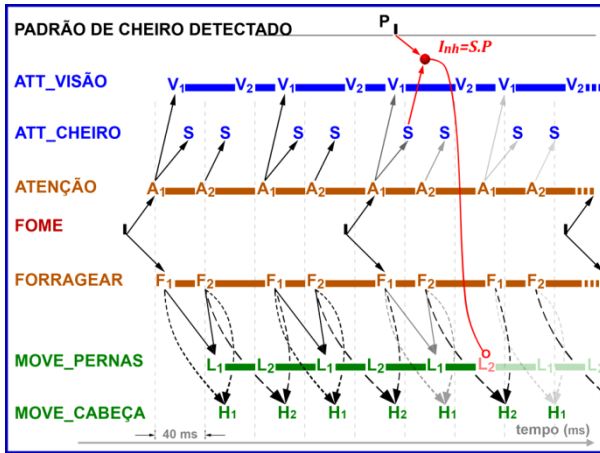


Figura 2: Ramificação e veto de coalizões e eventos.

Considere que ATENÇÃO controla o disparo desses ramos da seguinte maneira: qualquer evento A1 OR A2 pode causar o evento S. Note que S disparado por A1 ou por A2 são coalizões diferentes que executam a mesma função, assim, semanticamente lhe foi atribuído sentido único: atenção ao cheiro. Por outro lado, a BNA ATENÇÃO provoca o disparo de V1 que reverbera com V2, criando a memória biestável V1-V2 que representa atenção visual. Assim, os eventos S colocam o agente em estado de atenção (sensibilizam o agente) a qualquer padrão de cheiro de alimento; enquanto V1-V2 coloca o agente em estado de alerta para sinais visuais.

Paralelo e semelhante aos processos acima, a BNA FORRAGEAR dispara duas ramificações: as BNAs MOVE_PERNAS e MOVE_CABEÇA. Note que a ocorrência da função F1 AND F2 dispara tanto L1 quanto H1, embora sejam eventos espaço/temporais distintos na rede, ou seja, ocorrem em grupos de neurônios e em tempos diferentes. O primeiro tem por consequência disparar o grupo ($L1 = F1 \bullet F2$), que ocorre num tempo t_1 e que reverbera com L2 formando a BNA L1-L2. Esse núcleo de memória pode gerar eventos para CPGs que controlam o movimento das pernas (não ilustrado na figura); assim, o agente começa a se mover pelo ambiente. Já a outra bifurcação gerada por F1 AND F2 dispara dois eventos: ($H1 = F1 \bullet F2$) e ($H2 = F1 \bullet F2$), que ocorrem nos tempos t_2 e tempos t_3 e repetem periodicamente. Essas coalizões (H1 e H2) podem disparar CPGs que controlam o movimento da cabeça (também não ilustrado).

Assim como se ramificam, assembleias precisam ser desmanteladas, caso contrário, a rede neural continuaria executando laços biestáveis indefinidamente. Portanto, vetos e inibições são tão importantes quanto o são as ramificações. Sem desmantelar as BNAs disparadas no algoritmo acima o agente ficaria permanentemente em estado de atenção e continuaria forrageando. No

exemplo, quando o padrão de cheiro P é detectado, uma coalizão inibitória ($Inh = S \bullet P$) desarma a BNA L1-L2. Ou seja, o movimento das pernas é inibido em virtude de o agente ter detectado um padrão de cheiro esperado.

Máquinas de Estados Finitos – O leitor acostumado com termos de engenharia e ciência da computação perceberá que o ‘algoritmo’ descrito acima se parece com uma máquina de estados finitos (FSM – *Finite State Machine*), que é uma abstração usada para modelar um sistema que transita entre um número finito de estados internos. No atual estágio, considera-se projetar as redes NAC como FSM. O desafio é expandir a ideia no sentido de criar autômatos adaptativos, o que significa redes com mecanismos de aprendizado, aproximando NAC do domínio cognitivo.

Materiais e Métodos

O presente trabalho relata investigações sobre aspectos estáticos das assembleias digitais. Considera-se *digital* uma coalizão cuja maioria dos neurônios dispara em conjunto e o estado da coalizão é operante ou não. Nestas investigações, foram realizadas simulações em Matlab, cujos códigos e um breve tutorial se encontram, respectivamente, em [16] e [17].

As simulações se mostram em concordância com hipóteses e propostas teóricas. Em uma das simulações comprovou-se que coalizões biestáveis e núcleos de memória podem ser complexos e não somente reverberações diretas. A Figura 3 ilustra este exemplo, executado em Matlab.




Figura 3: Simulação de coalizões complexas.

Nesta simulação as coalizões ($k0$ até $k8$) têm 20 neurônios cada, que disparam *time-locked*. A assembleia $k0$ dispara inicialmente $k3$ e, após ≈ 20 ms, dispara $k1$. A coalizão $k1$ dispara $k2$ que dispara $k1$ novamente, assim, as duas formam uma BNA que reverbera continuamente. Já $k3$ dispara $k4$, mas $k4$ não realimenta $k3$. De fato, $k4$ dispara $k7$ que dispara $k8$, que então dispara $k5$. Note que $k5$ junto com $k2$ formam uma função AND que dispara $k3$ novamente. Do ponto de vista de $k3$, uma memória biestável é estabelecida, que pode representar um dos estados da máquina. Essa BNA requer o disparo de todo o laço que envolve $k1-k2$ em um ramo, e $k4, k7, k8$ e $k5$ no outro ramo.

Probabilisticamente, é mais fácil desmanchar uma formação biestável complexa como esta do que uma BNA com dois participantes apenas, como $k1-k2$. Na formação complexa é possível inibir qualquer dos eventos: $k4$, $k7$, $k8$, $k5$, a BNA $k1-k2$, ou até mesmo a assembleia $k3$ diretamente. Por outro lado, formações complexas como essa podem gerar mais ramificações, uma vez que cada participante dessa BNA (e.g. $k4$, $k7$, $k8$, $k5$) é potencial candidato a interagir com outras coalizões e dar origem a novas ramificações.

Relevância e Plausibilidade – Desde o início esta investigação tem duas preocupações basais: a primeira é manter a plausibilidade biológica, usando modelos neurais, modelos de plasticidade e processos adaptativos que reflitam fenômenos que ocorrem em redes neurais biológicas. Um dos aspectos relevantes da pesquisa é que a ferramenta de simulação (em desenvolvimento) poderá ser usada em simulações plausíveis em termos biológicos e da neurociência. A segunda é criar para engenharias e ciências afins uma máquina neural considerando pesos sinápticos e tempo de propagação na rede, que ao final se mostra uma nova forma de computar (não no sentido formal das máquinas de Turing, mas como em [18] e [19]), por meio de redes neurais pulsadas com retardo na propagação de *spikes*.

Respeitando princípios de criação de um ambiente de computação em redes biologicamente plausíveis, está em andamento a criação de uma máquina neural com uso nas engenharias e ao mesmo tempo uma ferramenta para simular e analisar fenômenos biológicos, fazer estudos em inteligência artificial (IA), neurociências, robótica, processos cognitivos, dentre outros, que pode também ser do interesse da engenharia biomédica.

No intuito de manter a plausibilidade biológica, foi utilizado o modelo neural desenvolvido por Izhikevich [20], um modelo fenomenológico (neurônios são tratados como sistemas dinâmicos [21]) que reproduz o comportamento de vários tipos de neurônios presentes no córtex de mamíferos [22], e em outros tipos de tecidos neurais. Resultados da escolha desse modelo podem ser observados já na simulação de fundamentos da NAC (ver [10], [11]). Como exemplo, na Figura 3 pode ser observado que os tempos de ocorrência das assembleias são semelhantes aos relatados em literatura de neurociências. No mesmo ambiente de simulação é possível utilizar tipos diferentes de neurônios na formação das coalizões com resultados surpreendentes: simulações mostraram que o tipo de neurônio não é tão importante quanto parece à primeira vista. Ou seja, neurônios diferentes podem ser misturados (mesmo aleatoriamente) e o comportamento do algoritmo das assembleias permanece. Resultados mais conclusivos, contudo, depende de discussão mais aprofundada e de evidências advindas da biologia e neurociência.

Discussão e Futuros Trabalhos

Até o momento foram elaborados e verificados os fundamentos e aspectos ‘estáticos’ da computação por assembleias neurais digitais. A etapa seguinte será

introduzir aspectos ‘dinâmicos’ nas redes. De acordo com levantamento teórico (ver [10]) há duas frentes para abordar a dinâmica em NAC. Uma frente deve analisar a influência dos mecanismos de plasticidade neural sobre a computação realizada nas assembleias. Quatro mecanismos são considerados: plasticidade intrínseca ou homeostática [23], [24]; STDP (*Spike-Timing Dependent Plasticity*) [25]; plasticidade de curto-prazo [26]; e plasticidade estrutural [27], [28]. A outra frente deve analisar a dinâmica da formação e dissolução das coalizões, as respostas das redes a estímulo contínuo (*spike streaming*), ruídos e falhas nos disparos de células, coalizões analógicas, participação de neurônios em múltiplas coalizões; enfim, vários aspectos dinâmicos da NAC e suas implicações na computação que a rede de assembleias realiza.

Os resultados iniciais das investigações de aspectos dinâmicos em NAC têm revelado os meios pelos quais coalizões se ajustam para executar funções analógicas (artigos em andamento). É o primeiro passo no sentido de compreender funções elevadas dos sistemas nervosos, como inteligência, cognição, tomada de decisão, etc.

Por outro lado, não é uma tarefa simples ‘desenhar’ algoritmos paralelos em FSM e distribuir os estados de máquina por coalizões de neurônios nas redes pulsadas. Deve ser lembrado que coalizões são fenômenos efêmeros, assim, máquinas Mealy e Moore podem ser inspiradoras, mas devem ser repensadas na abordagem NAC, uma vez que os estados em NAC não persistem até o próximo pulso de ‘relógio’, como em eletrônica digital. Assim sendo, será de grande auxílio criar uma ferramenta de software para transformar um algoritmo mais abstrato em conexões sinápticas e atrasos nas redes neurais pulsadas, uma espécie de ‘compilador’ para NAC. Em outras palavras, há espaço para o desenvolvimento (senão a necessidade) de ferramentas auxiliares para a abordagem NAC; por exemplo, uma linguagem para descrição de redes de assembleias e um programa para automatizar projetos, com interface mais amigável para permitir utilização por cientistas de outras áreas fora da engenharia e computação.

Como a abordagem leva em conta o retardo dos potenciais de ação, e isso nas redes biológicas é feito naturalmente pelos axônios, a abordagem NAC requer também a memorização e tratamento do histórico dos disparos neurais nos últimos 50 a 100 ms ou mais. Isso demanda capacidade computacional excepcional. Dessa forma, considera-se investigar e desenvolver hardware especializado para processar NAC, um trabalho até certo ponto interdisciplinar para tornar a ferramenta mais abrangente possível, apropriada para utilização em áreas correlatas da engenharia biomédica.

Conclusão

O presente artigo mostra como NAC pode explicar um tipo de computação que ocorre em assembleias de neurônios pulsantes. Nesta abordagem os neurônios não representam (estados ou coisas) por meio da média de disparo, mas sim quando formam coalizões. Mais ainda,

a formação de assembleias, as ramificações, dissoluções, e interações entre elas fazem o próprio controle do fluxo de informações que se propagam pela rede. Note-se que as representações (dados), o controle de fluxo, e as funções lógicas executadas possuem a mesma natureza nesta abordagem: são coalizões efêmeras de neurônios pulsantes. O processamento em NAC é um misto de ramificações (*branching*) e vetos, com sequências causais de ativações e inibições, associados a laços de memória (BNAs).

De uma maneira geral, NAC é uma abordagem para criação de máquinas em redes neurais pulsadas na qual o retardo de propagação dos sinais associados aos pesos sinápticos criam uma forma de representação do mundo externo (e interno) baseada nas formações de coalizões neurais. Tais assembleias podem memorizar e criar ramificações que se transformam no próprio controle do processamento de informações (nos estados internos de uma FSM) que as mesmas coalizões representam.

Aspectos ‘estáticos’ das coalizões ‘digitais’ já foram investigados, publicados, e estão brevemente descritos neste trabalho. Aspectos ‘dinâmicos’ e assembleias ‘analógicas’ estão em fase de investigação e publicação. A sequência requer investigar aspectos que incluem tratamento de fluxo contínuo de estímulos (*spike streaming*). No atual estágio as pesquisas têm sido feitas em redes neurais pulsadas desenhadas como FSM. Desenvolver autômatos adaptativos (que aprendem e se auto-organizam) é outra das novas metas. Ferramentas de simulação levando em conta plausibilidade biológica, ferramentas de automação para projetos topológicos, além da criação de uma linguagem para descrição de redes de assembleias, bem como o projeto de hardware especializado para executar NAC completam a lista de metas possíveis para o futuro dessa abordagem.

Neural Assembly Computing pode não ser a (única) forma como sistemas nervosos computam, mas certamente deve ser uma das formas de computação nas redes neurais naturais pulsadas com retardo na propagação dos pulsos. O aprofundamento das investigações nesta abordagem pode trazer vários benefícios à engenharia e ampliar conhecimentos em biologia, neurociência, medicina e ciências cognitivas. Em primeira análise, NAC pode contribuir em alguns ramos da engenharia biomédica, seja em áreas que já usam redes neurais tradicionais, em equipamentos e instrumentos com IA, na construção de simuladores, seja em novos campos de aplicação.

Agradecimentos

O autor agradece João Paulo Cerquinho Cajueiro e Cacilda Vilela de Lima pela leitura do manuscrito e por importantes contribuições ao texto.

Referências

- [1] Hebb D. O. (2002) *The Organization of Behavior: A Neuropsychological Theory*. Mahwah, NJ: Lawrence Erlbaum Associated, Inc, 2002. Original: New York: Wiley, 1949.
- [2] Nicolelis, M.A. Fanselow, E.E. e Ghazanfar, A. (1997) “Hebb’s

- dream: The resurgence of cell assemblies” *Neuron*, v. 19, n. 2, p. 219–221.
- [3] Connor, C.E. (2005) “Neuroscience friends and grandmothers” *Nature*, v. 435, n. 7045, p. 1036–1037, 2005.
- [4] Quiroga, R.Q. et al. (2008) “Sparse but not ‘grandmother-cell’ coding in the medial temporal lobe” *Trends in Cognitive Sciences*, v. 12, n. 3, p. 87–91.
- [5] Gross, C.G. (2002) “Genealogy of the grandmother cell” *The Neuroscientist*, v. 8, n. 5, p. 512–518.
- [6] Olshausen, B.A. e Field, D.J. (2004) “Sparse coding of sensory inputs” *Current Opinion in Neurobiology*, v. 14, n. 4, p. 481–487.
- [7] Buzsáki, G. (2004) “Large-scale recording of neuronal ensembles” *Nature neuroscience*, v. 7, n. 5, p. 446–451.
- [8] Buzsáki, G. (2010) “Neural syntax: Cell assemblies, synapses, and readers”. *Neuron*, v. 68, n. 3, p. 362–385.
- [9] Santos, V. L. et al. (2011) “Neuronal assembly detection and cell membership specification by principal component analysis” *PLoS ONE*, v. 6, n. 6, p. e20996.
- [10] Ranhel, J. (2012) *Computação por Assembleias Neurais em Redes Neurais Pulsadas*. Tese, Escola Politécnica da USP. URL: <http://www.neuralassembly.org/download/Ranhel_Tese.pdf>.
- [11] Ranhel, J. (2012) “Neural Assembly Computing”. *IEEE - Transactions on Neural Networks and Learning Systems*, v.23, n.6, p. 916-927.
- [12] Ranhel et al. (2011) Bistable memory and binary counters in spiking neural network. *2011 IEEE Symposium on Foundations of Computational Intelligence*. IEEE Press, v. 1, p. 66–73.
- [13] Marder, E.R. et al. (2005) Invertebrate central pattern generation moves along. *Current Biology*, v. 15, n. 17, p. R685–R699.
- [14] Wehr, M. e Laurent, G. (1996) Odour encoding by temporal sequences of firing in oscillating neural assemblies. *Nature*, v. 384, n. 6605, p. 162–166.
- [15] Laurent G. (2002) Olfactory network dynamics and the coding of multidimensional signals. *Nature Review Neurosciences*, v. 3, n. 11, p. 884–895.
- [16] Ranhel, J. (2011) *Arquivo Matlab para simular fundamentos em NAC*. Disponível em: <http://www.neuralassembly.org/download/NAC_Fundamentals.m>. Acesso em 25/08/2012
- [17] Ranhel, J. (2011) *Tutorial sobre simulador de fundamentos em NAC*. 2011. Disponível em: <http://www.neuralassembly.org/download/Tutorial_NAC_Fundamentals.pdf>. Acesso 25/08/12.
- [18] Gramss, T. et al (1998) *Non-Standard Computation: Molecular Computation - Cellular Automata - Evolutionary Algorithms - Quantum Computers*. Weinheim: Wiley-VCH.
- [19] Koch, C. (1999) *Biophysics of Computation: information Processing in Single Neurons*. NY: Oxford University Press.
- [20] Izhikevich, E. (2003) Simple model of spiking neurons. *IEEE Transactions on Neural Networks*, v. 14, n. 6, p. 1569–1572.
- [21] Izhikevich, E. (2007) *Dynamical Systems in Neuroscience: the Geometry of Excitability and Bursting*. Cambridge, Massachusetts: The MIT Press.
- [22] Izhikevich, E. (2004) Which model to use for cortical spiking neurons? *IEEE Transactions on Neural Networks*, v. 15, n. 5, p. 1063–1070.
- [23] Sjöström, P. J. et al. (2008) Dendritic excitability and synaptic plasticity. *Physiological Reviews*, v. 88, n. 2, p. 769–840.
- [24] Turrigiano, G. (2008) The self-tuning neuron: synaptic scaling of excitatory synapses. *Cell*, v. 135, n. 3, p. 422–435.
- [25] Abbott, L. F. e Nelson, S. B. (2000) Synaptic plasticity: taming the beast. *Nature Neuroscience*, v. 3, n. 1, p. 1178–1183.
- [26] Markram, H. et al. (1997) Regulation of synaptic efficacy by coincidence of postsynaptic APS and EPSPS. *Science*, v. 275, n. 5297, p. 213–215.
- [27] Barne, S.J. e Finnerty G.T. (2010) Sensory experience and cortical rewiring. *The Neuroscientist*, v. 16, n. 2, p. 186–198.
- [28] Holtmaat, A. e Svoboda K. (2009) Experience-dependent structural synaptic plasticity in the mammalian brain. *Nature Reviews Neuroscience*, v. 10, n. 9, p. 647–658.