

# O Modelo Cortical HTM e sua Aplicação na Classificação de Gêneros Musicais

Pedro Tabacof

**Resumo**—Com os progressos atuais da neurociência se cria a possibilidade de desenvolver modelos precisos e com grande poder computacional capazes de emular a estrutura e o funcionamento do neocórtex cerebral, órgão responsável pela inteligência dos mamíferos. O *Hierarchical Temporal Memory* (HTM) é um modelo cortical que possui capacidade de aprendizado e que pode ser aplicado em problemas de necessário aprendizado de máquina. Neste trabalho é feita a aplicação de uma implementação do HTM capaz de aprendizado supervisionado para realizar a classificação de gêneros musicais, problema com propriedades espaço-temporais, e seu desempenho nessa tarefa é comparado com soluções equivalentes.

**Palavras-Chave**—conexionismo, modelo cortical, hierarchical temporal memory, Numenta, aprendizado de máquina, classificação supervisionada, gêneros musicais, MIDI.

## I. INTRODUÇÃO

A tentativa de entender o funcionamento do cérebro, órgão fundamental para o comportamento inteligente dos animais, para a criação de modelos computacionais é antiga e frutífera. Do modelo binário de McCulloch e Pitts (1943) até a rede de estado de eco de Jaeger e Haas (2004), passando pelo algoritmo de aprendizado de retro-propagação do *multilayer perceptron* apresentado por Rumelhart, Hinton e Williams (1986), o paradigma conexionista fornece um vasto repertório de redes neurais artificiais, com diversas topologias, funções de ativação e formas de aprendizado (Elman *et al.*, 1996). Todos os modelos conexionistas são inspirados biologicamente, assim fazem parte da computação bio-inspirada ou computação natural (Castro, 2006).

Apesar da inspiração biológica, os modelos e algoritmos conexionistas não procuram ser biologicamente realistas, ou seja, não tentam criar um modelo da natureza, apenas procuram abstrair as propriedades que geram determinado comportamento desejado (como a capacidade de aprendizado supervisionado). O algoritmo de retro-propagação, por exemplo, não possui qualquer base biológica, e mesmo assim sua publicação levou a revitalização da área, que se encontrava letárgica desde a prova de Marvin Minsky que o *multilayer perceptron* não teria a capacidade de aprender a operação XOR por meio das técnicas de aprendizado vigentes na época. Uma dessas técnicas era justamente o aprendizado *hebbiano*, que é atualmente reconhecido como uma forma de aprendizado que realmente ocorre nos neurônios reais (Doidge

e Norman, 2007).

Mesmo com o aperfeiçoamento de diversas técnicas de aprendizado de máquina, problemas como o reconhecimento abstrato de conceitos (como entender o que significa “cachorro” em diversos contextos, desde a palavra em um livro até a imagem de um cachorro em um vídeo) ainda são tarefas que somente os seres humanos conseguem resolver (Hawkins, 2004). Nossa capacidade de abstração deriva do nosso relativamente grande neocórtex, parte do cérebro que se situa na camada mais externa dele e que ocupa 75% do seu volume, sendo a adição mais recente da evolução no nosso sistema nervoso central (Striedter, 2005). Apesar de ser um órgão grande e complexo, há enorme regularidade nos seus 1000cm<sup>2</sup> de área, 2mm de largura, 30 bilhões de células e 100 trilhões de sinapses, sendo constituído por colunas corticais e dividido em seis camadas (Mountcastle, 1998; Numenta, 2011).

Essa regularidade, somada ao fato do neocórtex ser um órgão evolutivamente novo, indica que ele pode estar implementando um mesmo algoritmo em toda sua estrutura, com variações decorrentes da conectividade. A distinção anatômica feita por Brodmann em 1909 pode ser originada a partir do processo de desenvolvimento embrionário e infantil, que devido a diferentes entradas e saídas de cada região do neocórtex pode levar especializações funcionais e anatômicas. A plasticidade cerebral observada no experimento com furões filhotes que tiveram seus nervos ópticos redirecionados para a área auditiva do neocórtex e ainda assim conseguiram enxergar algumas coisas demonstra o poder de reorganização cortical, que só pode acontecer se o funcionamento dele não for definido de forma específica inata, e sim de forma genérica (Elman *et al.*, 1996).

A partir dessas descobertas da neurociência, Jeffrey Hawkins propôs um novo modelo de rede neural artificial chamado de *Hierarchical Temporal Memory* (HTM) em seu livro *On Intelligence* (2004) com o objetivo de criar um modelo que fosse tanto biologicamente realista quanto computacionalmente poderoso. O HTM teria a capacidade de aprender e classificar sequências espaço-temporais, podendo ser implementado de forma a ser um classificador supervisionado ou não-supervisionado. Como é um modelo recente e em desenvolvimento (cujo ciclo pode ser visto na figura 1) por uma empresa privada, *Numenta*, criada pelo próprio Hawkins em 2005, há pouca literatura acadêmica acerca de experimentos práticos feitos a partir de

implementações do modelo.

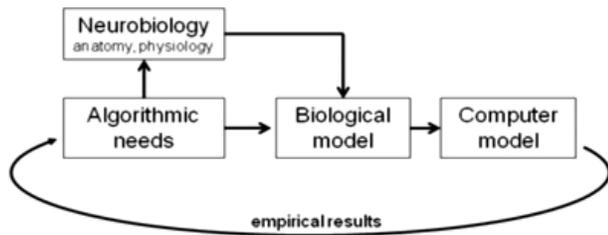


Fig. 1. Ciclo de desenvolvimento da *Numenta*.  
Fonte: Hawkins (2010).

Para testar o poder de classificação do HTM proponho sua aplicação em um problema que já foi resolvido de diversas maneiras e com variados algoritmos: a classificação de gêneros musicais.

O cenário musical tem sofrido fortes mudanças nas duas últimas décadas devido ao advento da internet e a crescente digitalização de obras musicais. No contexto atual, uma grande quantidade de músicas são armazenadas, compartilhadas e comercializadas digitalmente, gerando um aumento no número de bibliotecas musicais. É importante que esses dados sejam organizados de alguma forma, permitindo que haja meios eficientes de pesquisar e obter informações sobre eles, e devido a grande quantidade de informações é interessante que tenha-se um meio de fazer esse agrupamento de maneira automática e eficiente. Uma das maneiras mais comuns de indexar uma música é pelo nome de seu intérprete, ou compositor, ou pelo nome da mesma, que apesar de serem classificações interessantes, nada dizem sobre a música em si. Por outro lado, uma classificação por gêneros musicais envolve extrair traços da música e analisá-los, já informando sobre características dela.

Os seres humanos conseguem facilmente distinguir rock de música erudita, blues de forró, etc, sem qualquer informação além do próprio áudio. Alguns problemas podem surgir quando estamos tratando de subgêneros ou gêneros parecidos, como o rock e o heavy metal, mas de maneira geral conseguimos excelentes taxas de acerto. No entanto, não há nenhuma forma objetiva de definir o que é um gênero musical, muito menos uma técnica matemática para isso, então para a classificação automática se faz necessário algum método de aprendizado de máquina que a faça a partir de informações rítmicas, melódicas, harmônicas e líricas de cada música (Mostafa e Billor, 2009; Correa, Saito e Costa, 2010).

## II. HIERARCHICAL TEMPORAL MEMORY

O HTM é uma rede neural artificial que incorpora um modelo de neurônio mais realista, fazendo a distinção entre sinapses distais e proximais, organizado em colunas corticais de forma a gerar um conjunto de ativação esparsa de seus neurônios em uma região e também a previsão de ativação dos neurônios da hierarquia superior nos próximos instantes de tempo.

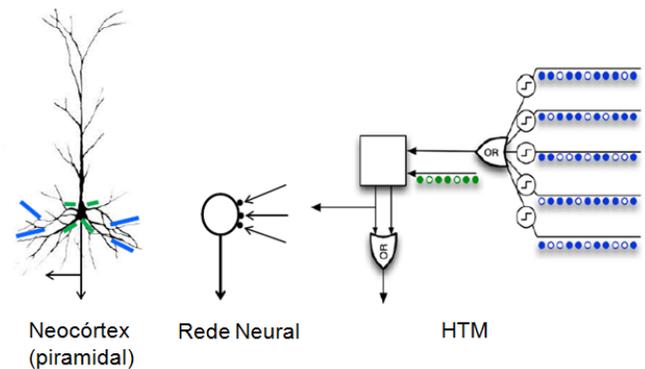


Fig. 2. Comparação entre modelos de neurônios. Na esquerda se vê um neurônio piramidal típico do neocórtex, no meio um neurônio genérico de uma rede neural tradicional e na direita o modelo do neurônio do HTM.  
Fonte: Numenta (2011).

Como pode ser visto pela figura 2, o neurônio do HTM é mais complexo que o de uma rede neural comum na forma em que sua conexão com o resto da rede é feita, mas ainda assim é bem mais simples que um neurônio real do neocórtex. No neurônio real vemos duas marcações em cores: em azul estão marcadas algumas sinapses distais, que se conectam com neurônios de outras colunas corticais de forma horizontal, são numerosas e têm pouca influência elétrica no corpo celular por estar longe dele; em verde estão marcadas algumas sinapses proximais, que se conectam verticalmente com neurônios da mesma coluna, são poucas e têm grande influência no corpo celular (Stuart, Spruston e Häusser, 2000).

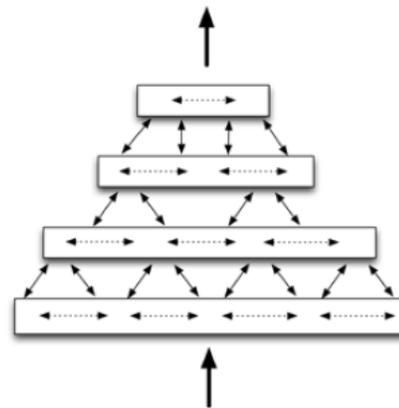


Fig. 3. Visão geral da estrutura hierárquica do HTM. As hierarquias são compostas internamente de colunas corticais e podem realizar integração multimodal. O feedback ainda não foi incorporado ao modelo publicado mais atual.  
Fonte: Numenta (2011).

De forma simplificada pode-se dizer que as sinapses proximais geram o contexto para o neurônio enquanto que as distais fazem uma computação mais específica dentro desse contexto. O HTM tenta incorporar essa diferença no seu modelo, assim cada neurônio possui uma sinapse proximal e várias distais, sendo que aquela recebe input da hierarquia inferior enquanto que estas recebem input dos neurônios da mesma hierarquia. Cada sinapse é binária e para o neurônio ser ativado basta que a soma das sinapses ativas ultrapasse um limiar, definido na aprendizagem ou no design da rede. Cada sinapse possui também um valor de permanência, que varia de

0 a 1, e determina se ela está habilitada ou não, sendo que para determinar este valor é utilizado o aprendizado *hebbiano*. O limiar acima do qual uma sinapse se ativa é definido na implementação do sistema (Numenta, 2011).

A figura 3 demonstra a organização de uma rede HTM, sendo que cada retângulo é composto por várias regiões constituídas de colunas, cada uma com um número fixo de neurônios, sendo que a disposição das regiões pode ser tanto unidimensional (visto acima) como bidimensional (ver figura 4). A ideia é que a estrutura hierárquica possibilite que seja extraído da entrada invariantes espaço-temporais, ou seja, que a rede tenha a capacidade de abstrair um conceito de alto-nível a partir de vários elementos de baixo-nível caso ocorra coerência temporal entre eles. Por exemplo, se uma hierarquia observa uma pessoa dançando, quem quer que ela seja, uma parte da hierarquia superior deve ser capaz de entender que “dança” está acontecendo de forma invariante no tempo.

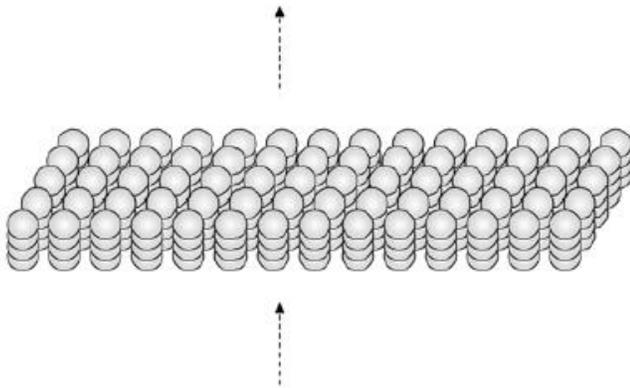


Fig. 4. Uma região bidimensional do HTM com quatro neurônios por colunas.  
Fonte: Numenta (2011).

Todas colunas de cada região do HTM recebem a mesma entrada, vinda da hierarquia inferior, por meio das sinapses proximais de cada neurônio da coluna. Cada neurônio também recebe conexões horizontais de outros neurônios da mesma região por meio de suas sinapses distais contendo informação acerca da previsão deles do que irá acontecer nos próximos instantes de tempo. O que acontece então é que há uma previsão constante: se o input vertical confirmar a previsão que um determinado neurônio iria se ativar nos próximos instantes do tempo, somente ele se ativa e a conexão entre as sinapses distais se fortalece. Se a previsão falhar a conexão se enfraquece. Se houve uma surpresa, ou seja, uma coluna recebeu input para se ativar mas nenhum neurônio dela estava previsto para isso, então toda os neurônios das colunas se ativam. A figura 5 demonstra a ativação de alguns neurônios devido à previsões corretas horizontais (em preto) e a ativação de colunas inteiras que não tinham qualquer tipo de previsão nos seus neurônios (em cinza). Apesar de não estar representado nessa figura, é preciso notar que as colunas competem entre si pelo input de forma a criar uma representação esparsa da entrada (Numenta, 2011).

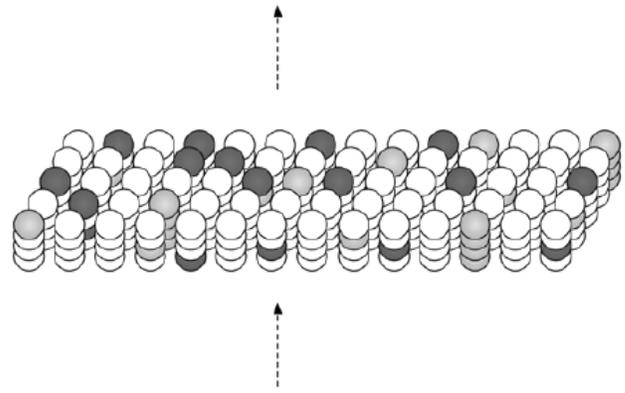


Fig. 5: Região bidimensional do HTM com neurônios pretos ativados pela confirmação da previsão horizontal e cinzas ativados diretamente pelo input vertical. Note que a ativação não é esparsa, como ocorre na prática.  
Fonte: Numenta (2011).

### III. MÉTODO EXPERIMENTAL

Como no trabalho feito por Francisco *et al.* (2011), em que participei como um dos autores, escolhi cinco gêneros da música ocidental para serem utilizados na base de dados: música erudita, hard rock/heavy metal, RAP, blues e MPB/bossa nova. São gêneros populares, com uma distinção razoável entre si, mas abrangentes o suficiente para o problema ser não-trivial. Apesar de algumas diferenças óbvias que podem ser observadas de forma mais direta (música erudita tem pouca percussão), para distinguir hard rock/heavy metal de blues, por exemplo, é necessário uma análise principalmente rítmica, pois as propriedades melódicas, harmônicas e líricas são parecidas. Para diferenciar blues de MPB/bossa nova, por outro lado, é preciso observar a harmonia e melodia.

A maior parte da literatura utiliza o formato de arquivo MIDI para ser utilizado na classificação de gêneros musicais, como pode ser evidenciado pelos trabalhos desenvolvidos por Cataltepe, Yaslan e Sonmez (2007), Mostafa e Billor (2009) e Correa, Saito e Costa (2010). O formato MIDI está em decadência graças ao maior poder de armazenamento e processamento dos computadores e dispositivos móveis atuais, mas ele já foi bem popular nos primórdios da internet por ser simples e compacto, então ainda existe um grande acervo de música MIDI na internet. Dessa forma, utilizei a mesma base de dados que o trabalho de Francisco *et al.* (2011), obtendo uma base de dados com um total de 500 músicas, 100 de cada gênero descrito acima.

No padrão MIDI cada música começa com um cabeçalho com descrições gerais, contendo entre outras coisas a divisão do tempo, o volume e o número de faixas da música. Cada faixa em geral representa um único instrumento musical e é composta por diversos eventos temporais que definem o que instrumento referido irá tocar na música. Entre os eventos possíveis existe evento para definir o instrumento da faixa (no MIDI temos 128 instrumentos melódicos e 61 instrumentos percussivos), começar nova nota musical (em determinado tempo, volume e frequência), finalizar nota, modificar timbre do instrumento, modificar volume da faixa, etc. Além disso, há também os meta-eventos, que podem modificar ou incluir informações extras como questões de copyright, letras ou até

mesmo a batida da música. Cada evento ou meta-evento sempre estará associado a um canal (de 0 a 15), sendo que os instrumentos rítmicos só podem ser expressos no canal 10. Diferente das notas melódicas, as notas rítmicas não possuem variação de frequência. Por fim, o tempo de cada evento não é o tempo real, e sim um *delta time* que pode ser convertido para o real por meio de uma transformação matemática utilizando a batida e divisão de tempo definida no cabeçalho.

A partir disso foi feito um extrator de dados capaz de percorrer uma música inteira coletando informações relevantes dela. Na primeira ideia, repetindo o procedimento de Francisco *et al.* (2011), o extrator percorre cada faixa da música, identificando quantas notas cada instrumento tocou e qual é o tempo de duração total da música. A partir daí, divide-se o número de notas tocadas por cada instrumento pelo tempo e temos a frequência em notas por segundo do instrumento na música, valor que reflete a preponderância dele na canção. Dessa forma para cada música teremos um vetor de características com 189 elementos reais, que pode ser utilizado no aprendizado e na classificação.

Na segunda ideia o extrator percorre somente o canal 10 (que contem as informações rítmicas da música) e coloca em um vetor todas notas percussivas que são tocadas em sua ordem de aparição, desconsiderando o tempo entre elas. Como a quantidade de notas de uma música não é limitada, o extrator só pega no máximo as 100 primeiras notas, ou seja, para cada música temos 100 vetores com 61 elementos cada ordenados de forma temporal. Este limite foi definido de forma arbitrária para que a entrada tivesse um tamanho factível e o tempo de processamento fosse da ordem de minutos no máximo para treinar e testar a rede. Esses 100 vetores representam a transição de instrumentos rítmicos, num formato parecido de uma máquina de estados (ex. bumbo → cimbal → caixa → prato → bumbo), que pode fornecer informações relevantes sobre a batida da música.

Utilizando a implementação fornecida pelo site da Numenta ([www.numenta.com](http://www.numenta.com)), de forma independente forneci como entrada os vetores de característica extraídos a partir das duas ideias descritas acima, com a topologia da rede variando de forma a atingir melhor taxa de acerto na classificação. Como não existe muita referência sobre implementações e aplicações do HTM, tive que fazer uma busca por força bruta para encontrar os melhores parâmetros da rede, partindo de valores ditos como recomendados pelo manual (Numenta, 2011).

Considerando que a base de dados de onde o conjunto de treinamento e teste serão extraídos é a mesma, para fazer o teste de acerto do classificador de forma a obter um resultado coerente e sem overfitting foi utilizada a técnica de validação cruzada 80-20. Para cada gênero musical são selecionadas 80 músicas de treinamento e 20 de teste de forma completamente aleatória, e isso é repetido 5 vezes de forma que todas as músicas tenham sido testadas pelo menos uma vez. Assim, obtemos 5 resultados de classificação diferentes, tirando daí uma média e um desvio padrão. A escolha do fator ser 80-20 é principalmente computacional: mais músicas de treinamento e menos de teste iria demandar um tempo muito maior de execução mas sem acrescentar muitas informações do poder

classificatório da rede, incluindo sua capacidade de generalização (Kohavi, 1995).

#### IV. RESULTADOS E DISCUSSÃO

Na primeira ideia explicada no item III temos para cada música um único vetor contendo a frequência de notas por segundo de cada um dos seus 189 possíveis instrumentos. Assim, é um tipo de entrada puramente espacial, sem nenhuma correlação temporal explícita entre os dados. Como explicado no item II, o HTM tem poder classificatório espaço-temporal, então para implementar um classificador utilizando o HTM para esse tipo de dado é preciso configurá-lo sem as propriedades temporais. Para fazer isso, basta manter um neurônio por coluna, que assim a saída vai depender unicamente da entrada no momento (Numenta, 2011).

O melhor resultado atingido foi com uma rede com 95 colunas na primeira hierarquia e 5 colunas na segunda, com fatores de agrupamento 35 e 66, respectivamente, e fatores de coincidência 390 e 305, respectivamente (esses dois fatores determinam alguns parâmetros utilizados no aprendizado, ver George e Jaros (2007) para mais informações). Utilizando a validação cruzada obtemos:

<b>Round 1</b>	73%
<b>Round 2</b>	84%
<b>Round 3</b>	79%
<b>Round 4</b>	72%
<b>Round 5</b>	80%
<b>Média</b>	77,6%
<b>Desvio Padrão</b>	5,0%

Fig. 6. Tabela com o resultado da classificação supervisionada do HTM utilizando a frequência de notas por segundo de cada instrumento como vetor de características e 5 rounds de validação cruzada.

Para efeito de comparação, utilizando a mesma extração de características, base de dados, e forma de validação o trabalho de Francisco *et al.* (2011) obteve no melhor de seus casos um taxa de acerto de 82,0% com desvio padrão de 4,4% utilizando o algoritmo SVM multiclases com kernel polinomial. Como o SVM é considerado um dos classificadores espaciais mais poderosos atualmente, e que as duas taxas de acerto possuem intersecção devido a seus desvios padrões, vemos que o poder classificatório do HTM neste caso foi praticamente o mesmo do SVM, demonstrando que para fins espaciais o HTM pode ser uma escolha viável. Apesar disso, considerando o trabalho que se teve para escolher os parâmetros e topologia da rede, devido à falta de literatura acadêmica, há uma dificuldade muito maior no seu uso para resolver problemas classificatórios do que se teria utilizando um algoritmo mais famoso, como o próprio SVM ou o *multilayer perceptron*.

A segunda ideia, que pretendia utilizar somente informações rítmicas da música, foi infrutífera: mesmo variando os parâmetros e topologia da rede, a taxa de acerto nunca passou de 30%. Como o esperado pela aleatoriedade é 20%, este resultado é muito fraco. Para explicar a falta de sucesso dessa

abordagem é preciso se lembrar que o vetor de características utilizados nessa classificação contem somente as notas tocadas pela percussão na sua ordem de aparição, desconsiderando o tempo entre elas. Como o tempo e a batida são importantes na caracterização de um gênero, fica-se evidente que não dá para utilizar somente a “máquina de estados” da percussão nesse tipo de problema. Além disso, como cada música gerou 100 vetores de 61 elementos, a entrada ficou muito grande gerando a um tempo de execução lento, dificultando a variação de parâmetros da rede. Uma abordagem utilizando o tempo exato entre uma nota e outra não é possível de ser feita com a implementação atual do HTM neste momento, de acordo com Numenta (2007), mas possivelmente poderá ser feita numa próxima implementação.

O resultado obtido utilizando a primeira ideia está dentro da faixa de resultados apresentada pela literatura, que varia de 70% a 90% utilizando de 3 a 5 gêneros diferentes, como podemos ver em Cataltepe, Yaslan e Sonmez (2007), Panagakakis, Benetos, Kotropoulos (2008) e Mostafa e Billor (2009). Em Correa, Saito e Costa (2010), para um exemplo mais concreto, foram utilizadas cadeias de Markov para representar a estrutura rítmica de cada música no formato MIDI. Depois disso, uma transformação estatística (LDA) foi aplicada e o resultado foi classificado utilizando um algoritmo Bayesiano linear. Com quatro gêneros diferentes (rock, reggae, blues e bossa nova) e 280 músicas na base de dados, testando com hold-out 50-50, foi atingido o melhor resultado de 74,3% de acerto.

## V. CONCLUSÃO

O HTM é um novo modelo de rede neural, cujo processo de desenvolvimento depende das descobertas da neurociência, e portanto nunca vai estar completamente definido. A implementação atual, feita pela *Numenta*, ainda não possui algumas características fundamentais do neocórtex, como o grande volume de canais de feedback nem a capacidade de processamento temporal fino. A *Numenta* anunciou que iria publicar em 2012 um novo modelo com um melhor poder classificatório para problemas que requerem ajustes temporais específicos, como o da classificação de gêneros musicais, mas ainda assim eles não tem planos para incorporar o feedback em seu modelo.

Mesmo assim, o HTM apresenta um bom poder classificatório espacial, chegando próximo ao do SVM neste problema, um ótimo desempenho para um modelo novo e desenvolvido por somente uma entidade não-acadêmica. Futuramente é possível que o HTM seja um dos algoritmos mais populares de aprendizado de máquina e consiga resolver problemas que nenhum outro consegue, mas hoje ele é só mais uma opção dentre dezenas, sem nenhuma vantagem específica (além do modelo elegante do neocórtex) e com algumas desvantagens (pouca literatura; dificuldade de design da rede). Portanto, a recomendação do autor é que se fique atento para novidades da *Numenta* e que se espere por mais trabalhos acadêmicos e comerciais antes de pensar em utilizar o HTM em uma aplicação mais importante.

## APÊNDICE

A implementação do HTM pode ser baixada a partir do site da *Numenta* ([www.numenta.com](http://www.numenta.com)). O software utilizado pelo autor e sua base de dados MIDI pode ser pedida através do e-mail pessoal do autor ([tabacof@gmail.com](mailto:tabacof@gmail.com)).

## BIBLIOGRAFIA

- [1] L. N. de Castro. *Fundamentals of Natural Computing: Basic Concepts, Algorithms, and Applications*, Chapman & Hall/CRC, June 2006.
- [2] Z. Cataltepe, Y. Yaslan, A. Sonmez. *Music Genre Classification Using MIDI and Audio Feature*. EURASIP Journal on Advances in Signal Processing, 2007, 36409, 8pp.
- [3] C. C. Correa, J. H. Saito, L. F. Costa. *Musical genres: beating to the rhythms of different drums*. New Journal of Physics, nº12, 2010, 053030, 37pp.
- [4] N. Doidge. *The Brain That Changes Itself*. United States: Viking Press. pp.427, 2007.
- [5] J. L. Elman, E. A. Bates, M. H. Johnson, A. Karmiloff-Smith, D. Parisi, K. Plunkett. *Rethinking Innateness: A connectionist perspective on development*, Cambridge MA: MIT Press, 1996.
- [6] D. George and B. Jaros. (2007). *The HTM Learning Algorithms* [Online]. Disponível: [http://numenta.com/htm-overview/education/Numenta\\_HTM\\_Learning\\_Algos.pdf](http://numenta.com/htm-overview/education/Numenta_HTM_Learning_Algos.pdf)
- [7] D. R. Francisco, M. K. Matsumoto, P. Feniman, P. Tabacof. (2011). *Classificador automático de gêneros musicais* [Online]. Disponível: [http://www.students.ic.unicamp.br/~ra082493/relatorio\\_midi.pdf](http://www.students.ic.unicamp.br/~ra082493/relatorio_midi.pdf)
- [8] J. Hawkins, S. Blakeslee. *On Intelligence*. St. Martin's Griffin, 2005.
- [9] H. Jaeger and H. Haas. *Harnessing Nonlinearity: Predicting Chaotic Systems and Saving Energy in Wireless Communication*. Science 2 April 2004: Vol. 304. no. 5667, 78-80.
- [10] R. Kohavi. *A study of cross-validation and bootstrap for accuracy estimation and model selection*. Proceedings of the Fourteenth International Joint Conference on Artificial Intelligence 2 (12): 1995, 1137-1143.
- [11] W. McCullock, W. Pitts. *A Logical Calculus of Ideas Immanent in Nervous Activity*. Bulletin of Mathematical Biophysics 5 (4): 1943, 115-133.
- [12] M. Mostafa.; N. Billor, *Recognition of Western style musical genres using machine learning techniques*. Expert Systems with Applications, nº36, 2009, 11378-11389pp.
- [13] V. Mountcastle, *Perceptual neuroscience: the cerebral cortex*, Cambridge, MA: Harvard University Press, 1998.
- [14] Numenta. (2007). *Problems that Fit HTM* [Online]. Disponível: <http://numenta.com/htm-overview/education/ProblemsThatFitHTMs.pdf>
- [15] Numenta. (2011). *Hierarchical Temporal Memory - including HTM Cortical Learning Algorithms* [Online]. Disponível: [http://numenta.com/htm-overview/education/HTM\\_CorticalLearningAlgorithms.pdf](http://numenta.com/htm-overview/education/HTM_CorticalLearningAlgorithms.pdf)
- [16] I. Panagakakis, E. Benetos e C. Kotropoulos, *Music Genre Classification: A Multilayer Approach*. ISMIR, Session 5a, 2008, 583-588pp.
- [17] D. E. Rumelhart, G. E. Hinton, R. J. Williams. *Learning representations by back-propagating errors*. Nature 323 (6088): 8 October 1986, 533-536.
- [18] G. F. Striedter. *Principles of Brain Evolution*. Sinauer Associates, Sunderland, MA, 2005.
- [19] G. Stuart, N. Spruston, M. Häusser, *Dendrites*, second edition. New York: Oxford University Press, 2008.