

Proposta de Modelo Semiótico Baseado em Máquinas de Boltzmann Restritas

Conrado Silva Miranda
Laboratório de Mobilidade Autônoma
Faculdade de Engenharia Mecânica
Universidade Estadual de Campinas
E-mail: miranda.conrado@gmail.com

Resumo—O surgimento e a grande capacidade de modelos de redes gerativas tem alterado a perspectiva de pesquisadores de sistemas inteligentes. No entanto, seu uso ainda encontra-se limitado a aplicações específicas. Além disso, existe um interesse de construir sistemas inteligentes utilizando a semiótica, com esta dando base para o funcionamento do sistema. Este trabalho apresenta a arquitetura de um sistema semiótico baseado em máquinas de Boltzmann restritas com grande capacidade de abstração.

Index Terms—Máquina de Boltzmann Restrita, Semiótica

I. INTRODUÇÃO

Redes neurais artificiais são modelos que visam aproximar o comportamento dos neurônios biológicos no cérebro. Visando identificar padrões e classificar as entradas, estas redes são usualmente *bottom-up*, partindo dos dados de entrada para os rótulos ou padrões determinados. Para tal, elas geralmente usam o algoritmo de *backpropagation*, que visa propagar erro nas camadas de saída para as de entrada. No entanto, este modelo não funciona bem quando se utiliza múltiplas camadas [5]. Para tal, modelos gerativos foram desenvolvidos, não se preocupando apenas com a capacidade de perceber padrões em dados, mas com a capacidade da rede de gerar os dados apresentados na entrada. As abordagens atuais visam a utilização de *auto-encoders* que serão descartados [9] ou redes que mantêm a capacidade gerativa durante a operação [5].

Dentre os modelos gerativos existentes, a máquina de Boltzmann restrita tem sido utilizada com muito sucesso em diferentes aplicações [11, 6, 1], sendo uma simplificação em cima das máquinas de Boltzmann [4] e similar à rede de Hopfield [7], utilizada para geração de memória.

A máquina de Boltzmann restrita tem como objetivo treinar uma rede capaz de ter estados mentais, semelhante ao que acontece com a mente humana. Para explorar essa capacidade, Hinton [6] criou uma rede para identificação de dígitos numéricos, mostrada na Figura 1. Esta rede é capaz de identificar dígitos manuscritos. Para tal, as camadas são treinadas de tal maneira que as unidades de nível superior encontram-se em regiões do espaço associadas ao estado mental que ocorre ao observar um determinado dígito. Após o treinamento com os rótulos, os estados mentais são associados a rótulos, permitindo a identificação dos dígitos observados. Além disso, devido à capacidade gerativa, pode-se escolher um dado rótulo




Figura 1. Exemplo de rede multi-camada, usada para detecção de dígitos. [6]



Figura 2. Dígitos gerados pela rede fixando-se o rótulo. [6]

para incitar um estado mental da máquina de tal maneira que ela gere imagens semelhantes às existentes na entrada, comprovando que o estado que ela se encontra está associado a imagens corretas. A figura 2 mostra sequências de dígitos gerados pela máquina para cada um dos rótulos. Esta capacidade gerativa torna-se essencial quando queremos entender o funcionamento das unidades não diretamente observáveis.

Como estes modelos visam descrever o funcionamento da mente humana, uma análise semiótica do modelo se necessária para compreender mais profundamente o funcionamento e limitações do mesmo, além de como modificá-lo para aumentar a capacidade. A semiótica é o estudo da representação, possuindo diversas vertentes distintas, sendo as atualmente influentes no contexto de sistemas inteligentes a semiótica de Peirce [8] e a de Eco [3]. A semiótica peirciana será utilizada na análise e desenvolvimento presentes neste trabalho, uma vez que ela apresenta grande similaridade com o modelo da máquina de Boltzmann restrita, além de ser mais abrangente

do que a proposta por Eco.

Este trabalho está dividido em 5 partes: esta seção apresentou a justificativa deste trabalho, ressaltando a importância do tipo de modelo analisado; a seção II descreve o funcionamento das máquinas de Boltzmann restritas e seu treinamento; a seção III apresenta o modelo semiótico de Peirce, que será utilizado; a seção IV realiza a análise das máquinas de Boltzmann restritas e descreve como utilizar o modelo para gerar um sistema com capacidade semiótica; e finalmente a seção V finaliza o trabalho, apresentando uma breve descrição do modelo desenvolvido.

II. MÁQUINAS DE BOLTZMANN RESTRITAS

Máquinas de Boltzmann [4] são modelos estocásticos gerativos baseados em energia de cada estado observável. Apesar de existirem variações do modelo original, incluindo capacidade de trabalhar com sequências [11], com múltiplas camadas [6] ou com variáveis contínuas [1], descreveremos aqui o funcionamento do modelo básico binário, chamado de máquina de Boltzmann restrita (RBM) [10].

Nos modelos baseados em energia, cada estado x possui uma função de energia E que faz com que cada estado tenha uma probabilidade $p(x)$ de ser escolhido. No entanto, o estado x pode não ser completamente observado, possuindo um conjunto h de variáveis latentes. Com estas variáveis, a probabilidade de um estado observável x é dada pela seguinte expressão:

$$p(x) = \frac{e^{-\mathcal{F}(x)}}{\sum_x e^{-\mathcal{F}(x)}}, \quad \mathcal{F}(x) = -\log \sum_h e^{-E(x,h)}$$

Para um conjunto de dados \mathcal{D} , a função de verossimilhança logarítmica e a função de perda são, respectivamente:

$$\mathcal{L}(\theta, \mathcal{D}) = \frac{1}{N} \sum_{x^{(i)} \in \mathcal{D}} \log p(x^{(i)})$$

$$l(\theta, \mathcal{D}) = -\mathcal{L}(\theta, \mathcal{D})$$

cujos gradientes estocásticos são dados por

$$-\frac{\partial \log p(x)}{\partial \theta} = \frac{\partial \mathcal{F}(x)}{\partial \theta} - \sum_{\tilde{x}} p(\tilde{x}) \frac{\partial \mathcal{F}(\tilde{x})}{\partial \theta} \quad (1)$$

O primeiro termo do gradiente tem a função de aumentar a probabilidade para os dados de treinamento, enquanto o segundo visa reduzir a probabilidade dos modelos gerados pela rede. O segundo termo pode ser reescrito como $E_p \left[\frac{\partial \mathcal{F}(x)}{\partial \theta} \right]$, cujo valor é difícil de ser calculado, mas permite o uso de amostragem para aproximá-lo. Para o caso particular das RBMs, a técnica da Cadeia de Markov de Monte Carlo apresenta-se como uma alternativa viável.

A arquitetura de uma RBM é apresentada na Figura 3, sendo um grafo não-dirigido completo bipartido, onde um nó de cada camada pode ser definido como constante e tendo funcionalidade de *bias*. Sendo v e h os vetores denotando os nós observados e os escondidos, respectivamente, sua função de energia é dada por

$$E(v, h) = -h'Wv$$

onde W representa os pesos entre as camadas. Além disso, os nós de uma partição são condicionalmente independentes, dados os valores dos nós da outra partição, e as probabilidades de ativação de um nó é dada pela função sigmoideal aplicada à sua entrada. Assim, as probabilidades são definidas da seguinte maneira:

$$p(h|v) = \prod_i p(h_i|v), \quad p(h_i = 1|v) = \text{sigm}(W_i v)$$

$$p(v|h) = \prod_j p(v_j|h), \quad p(v_j = 1|h) = \text{sigm}(W_j^T h)$$




Figura 3. Exemplo de máquina de Boltzmann restrita. [4]

Para amostrar o modelo, executa-se uma cadeia de Markov até convergência, usando a amostragem de Gibbs como operador de transição. A cadeia, apresentada na Figura 4, possui sua evolução dada pelas expressões:

$$h^{(n+1)} \sim \text{sigm}(W^T v^{(n)})$$

$$v^{(n+1)} \sim \text{sigm}(W h^{(n+1)})$$

onde conforme $n \rightarrow \infty$, $(v^{(n)}, h^{(n)})$ se tornam amostras precisas de $p(v, h)$, uma vez que a influência da condição inicial do sistema se torna nula.




Figura 4. Amostragem de estados de uma RBM. [4]

O ajuste dos pesos do modelo se dá, portanto, pela equação

$$\Delta w_{ij} = \alpha \left(\langle v_i^{(0)} h_j^{(0)} \rangle - \langle v_i^{(\infty)} h_j^{(\infty)} \rangle \right) \quad (2)$$

onde α é a taxa de aprendizado e $\langle v_i^{(n)} h_j^{(n)} \rangle$ é a frequência com que v_i e h_j estão ativos no n -ésimo passo da amostragem de Gibbs. Como é impraticável realizar tantos passos, usualmente realiza-se apenas 1 passo da amostragem ($n = 1$). Apesar de não esperar a convergência, esta técnica apresenta resultados muito bons e um custo computacional muito menor, justificando seu uso [5].

III. MODELO SEMIÓTICO DE PEIRCE

O modelo semiótico de Peirce é essencialmente triádico, fazendo com que o signo possua 3 elementos integrantes. Seus três elementos são o próprio signo, que representa algo para

alguém, o interpretante, sendo este um signo criado na mente pelo signo original, e o objeto, que é a coisa representada pelo signo (CP2.228). Esta relação está representada na Figura 5, onde o signo S está ligado a seu objeto O, que o determinou, e a seu interpretante I, que será gerado em alguma mente. Além de criar o interpretante, o signo deve garantir que este também esteja em relação com seu objeto, deixando de ser signo se isto não ocorrer.




Figura 5. Modelo sêmico de Peirce.

Como o interpretante criado pelo signo também é um signo, ele deve ser capaz de criar seu próprio interpretante, que estará em relação com o mesmo objeto. Se em algum momento esta série é rompida, o signo perde sua característica de signo, que é a capacidade de gerar um interpretante. Esta geração do interpretante não é necessariamente imediata, fazendo com que a capacidade de gerar um interpretante no futuro, quando se fizer necessário, seja suficiente para manter a característica de signo (CP2.92).

Pela necessidade da capacidade de um signo de gerar interpretante, sem a qual ele deixa de ser signo, a sequência de geração de interpretantes não pode ter fim. Se houvesse um fim, este último signo não seria signo e a cadeia estaria corrompida (CP2.303). Esta característica é mostrada na Figura 6, onde existe uma sequência de interpretantes $I(n)$ sendo gerado por um interpretante $I(n-1)$ e gerando um interpretante $I(n+1)$, até um hipotético interpretante I_f , denominado interpretante final. Como dito, este interpretante é hipoteticamente impossível de ser alcançado, mas a sequência de interpretantes converge para ele. A este processo de geração progressiva de interpretantes é dado o nome de semiose, sendo esta semiose infinita uma característica marcante na semiótica peirciana.

Peirce descreve dois tipos de objeto: dinâmico e imediato. O objeto dinâmico é o objeto existente no mundo real e não diretamente perceptível pelo intérprete, sendo sua percepção realizada através de um objeto imediato, que é o objeto como o signo o representa (CP4.536). Este objeto imediato é mais restrito do que o dinâmico, uma vez que pode apresentar características que o signo não é capaz de representar (CP8.314). Assim, a percepção do intérprete fica limitada aos aspectos apresentados pelo objeto imediato, devendo este usufruir da experiência colateral para adquirir mais informações sobre o objeto dinâmico (CP8.177).

O signo, quando analisado pela sua relação com o objeto representado, pode ser classificado em três categorias: ícone, índice e símbolo. Peirce define ícone da seguinte maneira: "Um Ícone é um Signo que se refere ao Objeto que denota




Figura 6. Modelo de semiose de Peirce.

apenas em virtude de seus caracteres próprios, caracteres que ele igualmente possui" (CP2.247). Dessa forma, o signo é um ícone por possuir semelhanças com o objeto denotado. Tendo-se em mente que o objeto para Peirce não necessariamente é algo material, palpável, mas pode ser qualquer coisa que um signo possa representar, e ele possui as mesmas características do objeto, a mente responde à presença do signo da mesma maneira que responderia à presença do objeto, no aspecto ou qualidade por ele representado (CP4.447).

Os índices diferem dos ícones no passo que estes dependem de relações de similaridade com o objeto referenciado. Peirce apresenta duas definições muito claras sobre o índice: "Índice: um signo ou representação que se refere a seu Objeto não tanto em virtude de uma similaridade ou analogia qualquer com ele, nem pelo fato de estar associado a caracteres gerais que esse objeto acontece ter, mas sim por estar numa conexão dinâmica (espacial, inclusive) com o Objeto" (CP2.305) e "O Índice é um signo cuja significação de seu Objeto se deve ao fato de ele ter uma relação genuína com aquele Objeto, sem se levar em conta o interpretante. É o caso, por exemplo, [...] [d]uma batida na porta como indicativa de um visita" (CP2.92). Assim, a relação do índice com seu objeto se dá por alguma relação espaço-temporal com o mesmo, na qual o índice indica a existência do objeto, chamando a atenção do interprete para ele (CP2.257). A conexão dinâmica apresentada pelo índice possui duas facetas: a do objeto ao qual está conectado no espaço-tempo e da conexão com os sentidos ou memória da pessoa a quem serve o signo (CP2.305).

O símbolo, ao contrário do ícone e do índice, não traz relação a priori com o objeto representado, sendo dependente de uma regra ou hábito para gerar seu interpretante, ou seja, é um signo porque será usado e interpretado como tal. Para se conectar com seu objeto, é necessário um índice, ou seja, uma instância espaço-temporal que traz ao pensamento uma experiência particular (CP4.56) e que, por um hábito, esta experiência será interpretada como símbolo. Peirce apresenta o exemplo de uma palavra, pois uma palavra será a mesma palavra todas as vezes que ocorrer, possuindo o mesmo significado todas as vezes e sendo portanto um símbolo, mas

uma ocorrência particular da palavra depende de um índice, pois o símbolo é um geral e não é capaz de representar casos individuais (CP4.56).

IV. MODELO SEMIÓTICO BASEADO NAS MÁQUINAS DE BOLTZMANN RESTRITAS

Esta proposta possui como base o modelo de Deacon [2], representado na Figura 7. Neste modelo, os tipos de signo descritos na seção III possuem uma relação hierárquica, onde um signo de um nível superior é composto por relações entre signos do nível inferior. Para construir as formas mais elevadas, deve-se primeiro operar nas formas de menor ordem para substituí-las ou representá-las, fazendo com que os signos superiores que substituem os inferiores sejam interpretantes destes. Portanto, iniciaremos com a análise do ícone.




Figura 7. Relações entre os tipos de signo, segundo Deacon.

Em uma RBM, temos escolha dos tipos de dados a serem colocados nos nós visíveis, sendo os dados aqui denominados v . Consideremos que os dados possuem alguma semelhança com um objeto, como semelhança visual no caso de uma imagem ou fonética no caso de sons. Os dados são portanto uma codificação do objeto, onde esta semelhança não é direta mas acontece por alguma função de transformação, capaz de transformar um objeto imediato do objeto dinâmico referenciado em dados e dados em possíveis objetos imediatos, da mesma natureza dos objetos imediatos que geram os dados, do mesmo objeto dinâmico, como o caso de microfones e auto-falantes. A Figura 8 apresenta uma ilustração do requisito da função de transformação descrita. Nela, um objeto dinâmico O_d gera um objeto imediato O_i que, através da função de transformação, gera os dados D que serão apresentados ao modelo. A codificação deve ser feita de tal maneira que, utilizando-se dados D' semelhantes aos dados D , gera-se um objeto imediato O_i' , o qual poderia ter sido gerado por O_d diretamente. No caso sonoro, O_i seria o som original e D os dados capturados pelo microfone, enquanto D' seriam os dados utilizados pelo auto-falante para gerar o som O_i' de tal maneira que um intérprete humano seja capaz de dizer que O_i e O_i' poderiam ter sido criados a partir de O_d .




Figura 8. Relação entre objeto imediato e dados.

Quando os dados visíveis são utilizados para se determinar os valores dos nós escondidos, em uma RBM já treinada, temos neste instante uma outra representação do mesmo objeto dinâmico, denominada h . Para mostrar que esta nova representação h do objeto também se dá por semelhança, devemos ser capazes de gerar um possível objeto imediato da mesma forma descrita anteriormente para os dados v . Devido à capacidade gerativa da RBM, podemos utilizar a representação h para gerar valores v' da camada visível e aplicar a mesma função de transformação. Como o princípio de funcionamento do modelo é ser capaz de gerar dados semelhantes aos apresentados durante o treinamento, temos que uma representação h gerada a partir de dados v é capaz de gerar dados v' , de tal maneira que $v \approx v'$ e, conforme a Figura 8, $D \approx D'$.

Como tanto os dados v e h são capazes de representar um objeto existente, comprovada pela geração de um objeto imediato possível de ser gerado pelo mesmo objeto dinâmico, eles são candidatos a serem signos, devendo para isto ter o potencial de gerar um interpretante. Como v é capaz de gerar h e h é capaz de gerar v , pela construção do modelo, se ambos forem signos, eles poderão gerar interpretantes que também são signos, satisfazendo portanto todos os requisitos para serem signos. Além disso, eles possuem similaridade com o objeto referenciado, como descrito anteriormente, sendo portanto ícones do objeto representado. Devido à essa característica das RBMs de serem capazes de gerar interpretantes do mesmo objeto, ela é semelhante à semiose apresentada na Figura 6.

Na descrição, supomos que a RBM já estava treinada da maneira adequada para gerar dados da maneira desejada. Para que esta hipótese continue válida, devemos mostrar como a RBM é capaz de fazer isso durante seu treinamento. A partir da equação (1) e de sua descrição, podemos realizar descrever de forma semiótica esta expressão. Dado um ícone na entrada, queremos que o interpretante por ele gerado se assemelhe a máximo ao ícone original, de forma que a sequência de interpretantes sejam semelhantes entre si, o que justifica o primeiro termo. O segundo termo representa um distanciamento do interpretante do ícone de todos os outros possíveis ícones por ele gerado, que não são semelhantes ao ícone original. Estes dois termos fazem com que a sequência de interpretantes mantenha a relação de similaridade presente no ícone da entrada, justificando o argumento de que o interpretante está relacionado com o mesmo objeto. A partir da equação (2), temos que o ajuste é feito aumentando-se a semelhança do interpretante gerado com o ícone original e reduzindo-se a similaridade com o interpretante final que seria gerado pela sequência. Como esse interpretante final não pode ser atingido de fato, a realização de um determinado número de passos de semiose é suficiente para fazer este ajuste de maneira adequada. Assim, ao fim do treinamento, a RBM é capaz de gerar sequência de interpretantes semelhantes entre si, dando base para a hipótese de que os dados gerados são semelhantes ao original.

Com isto, temos que o modelo simplista da RBM é capaz

de realizar aprendizado icônico, chamadas portanto de RBMs icônicas. Para ter uma capacidade de representação superior, podemos empilhar um conjunto de RBMs devidamente treinadas, onde cada camada aumenta o refino do modelo [6]. Devido a esta capacidade, as RBMs descritas posteriormente podem possuir um ou múltiplos níveis, sem haver distinção.

Uma vez determinado como realizar o aprendizado icônico e semiose em cima de ícones, buscamos como fazer o mesmo com índices. Utilizando a ideia de Deacon, presente na Figura 7, o índice é uma abstração construída em cima de ícones. Caso dois ícones tenham relação espacial, ela pode ser percebida em uma única captura, caso o órgão sensorial tenha tal capacidade, ou de maneira sequencial, como na movimentação dos olhos quando todo o ambiente não pode ser capturado de uma vez. Já na relação temporal, temos a possibilidade desta relação ser sequencial, na qual a relação ocorre por um seguir o outro, ou simultânea, por acontecerem ao mesmo tempo. Portanto, tanto a relação temporal quanto a espacial dependem da capacidade de se perceber mais de uma coisa ao mesmo tempo ou da capacidade de perceber que os ícones acontecem em sequência.

Para adicionar a capacidade de processar ícones simultâneos às RBMs, pode-se adicionar uma nova RBM, como mostrado na Figura 9. Nela, temos duas RBMs icônicas, treinadas potencialmente com tipos distintos de ícones, servindo como entrada para uma RBM indexical, que deve estabelecer a relação entre os interpretantes gerados pelos ícones percebidos. O interpretante gerado na camada escondida é um índice porque estabelece a conexão entre os interpretantes icônicos da camada inferior. Na ausência de entradas de uma de suas RBMs icônicas, o índice é capaz de gerar objetos imediatos semelhantes aos que estariam presentes juntamente com o ícone presente na RBM com entrada. Assim, se fosse treinada ouvindo uma nota e vendo uma cor, caso a nota estivesse presente sem a cor correspondente, a RBM seria capaz de gerar a cor, mostrando que ela está no mesmo estado mental que estaria caso a cor estivesse presente. Tal característica é apresentada por Hinton [6], onde a mesma rede é capaz de identificar o número correspondente a uma imagem de um dígito e gerar dígitos associados a um número.

O mesmo formato de RBM indexical é capaz de tratar com dados temporais. A utilização de RBMs para predição, na qual uma das RBMs icônicas não possui capacidade gerativa, está ilustrada na Figura 10. Este modelo é similar ao apresentado para relação de ocorrência simultânea, devendo apenas uma das redes inferiores estarem deslocadas temporalmente. Apesar do modelo ser treinado para predição, ele ainda possui a característica gerativa das RBMs, sendo capaz de determinar ícones prováveis de terem ocorrido antes do ícone atualmente percebido.

Uma vez determinado o uso de ícones e índices na rede, pode-se questionar se a mesma é capaz de aprendizado simbólico. O aprendizado de rótulos apresentado por Hinton no formato mostrado na Figura 1 é simbólico, mas houve a necessidade de um árbitro externo que define os rótulos para cada entrada. Para obter um aprendizado simbólico sem

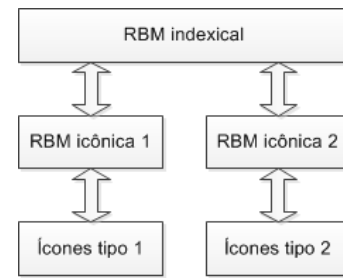


Figura 9. RBM indexical




Figura 10. Exemplo de rede temporal. [11]

supervisor, podemos nos basear no modelo de construção de referência simbólica a partir de relações indexicais, mostrado na Figura 11. Os passos enumerados na figura e sua maneira de implementação usando RBMs são:

- 1) Construir relações indexicais entre os objetos de referência e os signos. Este passo já é realizado pelo de RBM indexical apresentado anteriormente.
- 2) Uma relação sistemática entre estímulos indexicais é percebida e aprendida com índices adicionais (ligações entre os signos). Da mesma maneira que a RBM indexical utilizou RBMs icônicas como fonte de dados e é capaz de elaborar relações entre os ícones, o uso de RBMs indexicais como entrada de uma outra RBM indexical deve ser capaz de perceber a relação entre os índices produzidos. Esta nova classe de RBM será denominada RBM simbólica.
- 3) Uma reversão das setas indexicais numa estratégia de se basear na relação entre os signos (setas escuras) para escolher objetos indiretamente através de suas relações (setas correspondentes no sistema inferior). A reversão das setas corresponde a utilizar o objeto (ou seu ícone) para gerar o signo correspondente, passando pela RBM icônica, indexical e alcançando a simbólica, correspondendo ao estado mental mais abstrato possível. Uma vez determinado o estado mental da RBM simbólica, ela pode ser utilizada para gerar os outros signos relacionados com o mesmo estado mental, sendo estes signos de abstração inferior ou não.

Desta forma, a cadeia de RBMs é capaz de realizar semiose semelhante à descrita por Peirce, com todos os tipos de

símbolo. Para ilustrar seu funcionamento, descreveremos um exemplo de como o sistema aprenderia o significado da palavra "colher", tanto dita quanto escrita. Este exemplo tem caráter apenas ilustrativo, não tendo sido testado.

- 1) Considerando a rede completamente inexperiente, ela primeiramente deve aprender o funcionamento dos seus sentidos básicos. Para isso, as RBMs icônicas irão aprender o som da palavra, o formato do objeto e o formato da escrita. As outras camadas podem ser treinadas em paralelo ou não, dependendo da capacidade do sistema de perceber que é inexperiente, podendo ser medida através da variação dos pesos Δw_{ij} das redes.
- 2) A partir do momento que se consegue reconhecer os ícones de maneira aproximada, aprende-se a relação indexical entre eles. Dependendo da construção do sistema, apenas uma RBM indexical é necessária, mas pode-se usar um número arbitrário para construção do sistema. Uma possível combinação seria uso de uma RBM indexical para detectar relação entre os elementos visuais (forma do objeto e da escrita) e de outra para perceber a relação entre elementos visuais e sonoros. Assim, esta rede percebe a relação entre o som "colher" e o objeto, por exemplo.
- 3) Uma RBM simbólica é construída em cima das RBMs indexicais existentes. Pode haver mais de uma RBM simbólica, mas elas devem estar conectadas entre si de alguma maneira. Esta RBM simbólica percebe a relação de ocorrência entre os índices e gera a abstração necessária para o símbolo, de tal maneira que ao se ouvir ou ler a palavra "colher", o sistema se encontrará em estado mental semelhante àquele que estaria caso tivesse visto o objeto.

V. CONCLUSÃO

Neste trabalho, realizamos um estudo da máquinas de Boltzmann restritas (RBM) sob o ponto de vista da semiótica peirciana. Mostramos que no seu formato mais simples ela executa semiose utilizando apenas signos icônicos, além de apresentar uma metodologia para se determinar se um interpretante satisfaz a restrição de que deve manter a relação de representação com o mesmo objeto.

Apresentamos também maneira de se estender o modelo simples, permitindo que ele realize semiose com índices e símbolos, além de ícones. Esta construção foi comparada com sistemas já existentes que também usam as RBM de maneira semelhante, sendo o modelo apresentado mais genérico. O modelo se baseia na metodologia descrita por Deacon para aprendizado de signos mais complexos a partir dos ícones.

Finalmente, um exemplo de aplicação é descrito mas não testado. Acreditamos que esta metodologia levará ao resultado esperado, com um sistema capaz de realizar semiose em todos os níveis. No entanto, a implementação e teste deste tipo de sistema ainda é um ponto a ser estudado em trabalhos futuros.




Figura 11. Passos para construção de relações de referência simbólica. [2]

REFERÊNCIAS

- [1] H Chen. Continuous restricted Boltzmann machine with an implementable training algorithm. *Vision, Image and Signal Processing, IEE*, 2003.
- [2] T.W.W. Deacon. *The Symbolic Species: The Co-evolution of Language and the Brain*. W. W. Norton, 1998.
- [3] U. Eco, A. DE PADUA DANESI, and G.C.C. DE SOUZA. *TRATADO GERAL DE SEMIOTICA*. Coleção estudos. Perspectiva, 2000.
- [4] G. E. Hinton. Boltzmann machine. 2(5):1668, 2007.
- [5] Geoffrey E. Hinton. Learning multiple layers of representation. *Trends in cognitive sciences*, 11(10):428–34, October 2007.
- [6] Geoffrey E. Hinton, Simon Osindero, and Yee-Whye Teh. A fast learning algorithm for deep belief nets. *Neural computation*, 1554:1527–1554, 2006.
- [7] J. J. Hopfield. Hopfield network. 2(4):1977, 2007.
- [8] Charles Sanders Peirce. *Collected Papers*. Harvard University Press, 1933. Edited by Charles Hartshorne and Paul Weiss (citado como CP seguido de volume e parágrafo).
- [9] Rajat Raina, A Battle, H Lee, and B Packer. Self-taught learning: Transfer learning from unlabeled data. *on Machine learning*, 2007.
- [10] P Smolensky. Information processing in dynamical systems: Foundations of harmony theory. 1986.
- [11] I. Sutskever and G. E. Hinton. Learning multilevel distributed representations for high-dimensional sequences. *Proceeding of the Eleventh*, 2007.