

MODELOS DE COMPUTAÇÃO NEURAL ARTIFICIAL: REDES TRADICIONAIS X REDES PULSADAS

Diego Henrique Pagani¹, Josué Pereira de Castro², Adriana Postal³

^{1,2,3}Universidade Estadual do Oeste do Paraná

dhpagani@gmail.com¹, josue.castro@unioeste.br², adriana.postal@unioeste.br³.

O objetivo deste trabalho é realizar um estudo comparativo entre dois modelos de redes neurais artificiais: o modelo *Multilayer Perceptron* (MP) e o modelo chamado de *Spiking* ou Pulsado. Como o modelo pulsado é relativamente recente, suas características ainda não são totalmente conhecidas, mesmo considerando modelos mais simples de rede, como o *Perceptron*. Este estudo tem por objetivo comparar os dois modelos de *Perceptron* e estabelecer os principais pontos positivos e negativos de seu funcionamento, utilizando para isto uma tarefa que consiste em classificar a base de dados Iris (Fisher, 1993). Até o momento da elaboração deste resumo o modelo tradicional de RNA está implementado e testado.

Uma Rede Neural Artificial (RNA) é um sistema de processamento de informações baseado nas redes neurais biológicas. Uma RNA é formada por uma ou mais estruturas funcionais simples, chamadas neurônios. Quando há mais de um neurônio, a comunicação entre eles é feita por meio de conexões, chamadas sinapses, através das quais a resposta de um neurônio é repassada como entrada para outro. Cada conexão associa-se a um peso, que em conjunto com todas as outras conexões da RNA representam o conhecimento armazenado na rede. A partir dessas definições originaram-se vários

modelos de rede com os mais diversos objetivos (Fausset, 1994).

O modelo de RNA mais simples chama-se *perceptron*, o qual consiste de um neurônio somador que recebe uma ou várias entradas e possui apenas uma saída. Cada entrada é multiplicada por um valor que representa o peso da ligação. Após o cálculo de todas as entradas ponderadas, todos os valores são somados e é aplicada uma função de ativação que avalia se o neurônio deve disparar ou não. Um único neurônio *perceptron* é capaz de reconhecer problemas linearmente separáveis.

Com o avanço nas pesquisas na área, o modelo de *perceptron* foi estendido para vários neurônios, dividindo-os em pelo menos três camadas:

- **Entrada:** é responsável por encaminhar os dados de entrada à camada intermediária. É a única que não realiza nenhum cálculo.
- **Intermediária ou Escondida:** tem a função de extrair as características globais a partir dos neurônios da camada de entrada. A adição de camadas ocultas em RNAs do tipo *perceptron* permite que elas aumentem seu poder de classificação sendo capazes de resolver problemas que não são linearmente separáveis. Entretanto, segundo Fausset

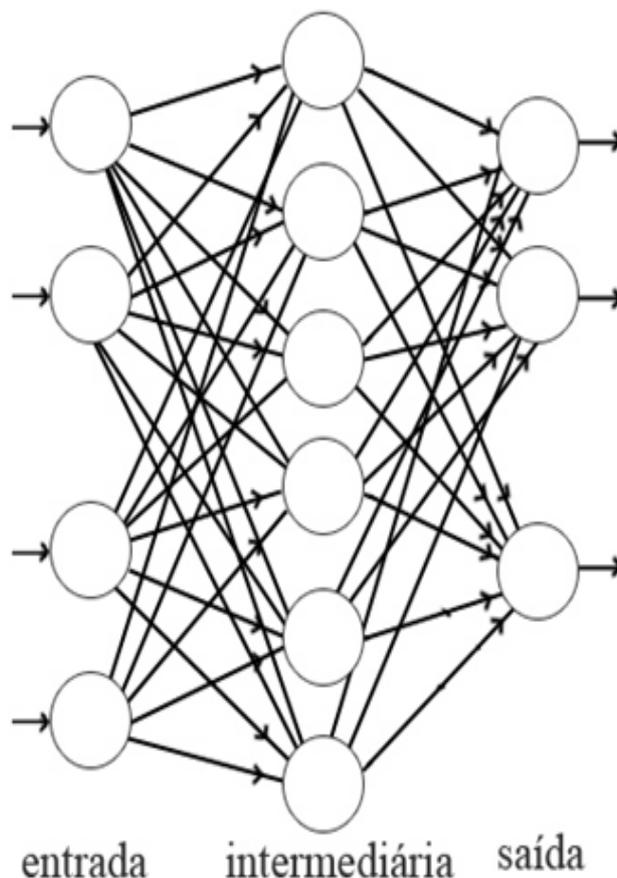
(FAUSSET, 1994), apenas uma camada oculta é necessária para a maioria dos problemas.

- **Saída:** constitui-se no padrão de resposta global correspondente ao padrão de entrada, ou seja, a camada de saída representa a resposta da rede para o estímulo específico recebido pela camada de entrada.

As Redes Neurais Pulsadas utilizam uma hipótese das RNAs ditas tradicionais: esta nova abordagem usa como codificação de informação na forma de taxa de pulsos (*rate code*). Os experimentos e estudos de Gerstner (Gerstner, 1999) assumem que a codificação de informação no cérebro ocorre na forma de taxa de pulsos e conseguem justificar os resultados obtidos por meio de observações. Vários modelos matemáticos foram inspirados pelas hipóteses de taxa de pulsos, além de experimentos e estudos no campo da neurociência (Jaskowiak, 2008). Todos estes dados fizeram que esta hipótese de codificação tivesse sucesso nos últimos tempos.

Vários modelos RNAs tradicionais utilizam a hipótese de codificação de informação por meio da taxa de pulsos produzida pelos neurônios, entretanto não há parâmetros que incrementem ao modelo alguma informação temporal. A noção de atraso que existe nas redes de Hopfield não possui influência direta no processamento de informação deste modelo de rede, ou seja, não há influência do tempo na informação (Jaskowiak, 2008).

Estudos realizados revelam que a codificação baseada em taxas de pulsos não seria rápida o suficiente para proporcionar a



realização de certos tipos de operações e um

Figura 1 – Esquema representando as três camadas da RNA Multilayer Perceptron

dos principais argumentos foi dado por Thorpe e Imbert (Thorpe e Imbert, 1989): Primatas podem realizar processamento e classificação de padrões visuais (reconhecimento de objetos e classificação) em tempos próximos a 100ms. Este intervalo de tempo não seria o suficiente para que os neurônios pudessem realizar uma estimativa da taxa de disparos, pois muitos neurônios não conseguiriam gerar mais de um disparo. Para dizer isto, os autores usam a lógica de que os estímulos na retina passam por volta de 10 camadas de neurônios, o que deixaria cerca de 10ms de processamento para cada camada de neurônios envolvida no processamento (Jaskowiak, 2008).

Com base nestes argumentos, de Thorpe e Imbert, surgiu interesse por parte de pesquisadores de encontrar alguma forma de processamento, como RNAs, mas que fossem inspirados em neurônios biológicos de maneira mais realística. Com a definição de tais modelos e através de simulações, espera-se ter modelos capazes de realizar computações de maneira tão eficiente quanto as realizadas no cérebro (Jaskowiak, 2008).

A RNA foi implementada utilizando a plataforma MATLAB® para implementação da RNA do tipo *Multilayer Perceptron* (MP) para realizar a classificação da base de dados Iris. Esta base contém 150 amostras de dimensões de sépalas e pétalas, às quais são utilizadas para classificar as amostras em três categorias distintas de flores (*Iris Setosa*, *Iris Versicolour* e *Iris Virginica*). A figura 1 mostra um exemplo de como foi modelada a RNA.

O modelo MP implementado está organizado da seguinte maneira: a camada de entrada contém quatro neurônios, a intermediária (escondida) contém seis e a de saída três neurônios. O número de neurônios em cada camada foi determinado da seguinte maneira:

a) **Camada de entrada:** foi determinado pelos dados disponíveis na base Iris (duas dimensões das sépalas e pétalas, totalizando quatro dados de entrada);

b) **Camada oculta:** como não há um modo exato de se calcular a quantidade ideal de neurônios na camada oculta, este número foi determinado empiricamente;

c) **Camada de saída:** como existem três categorias de flores, foram utilizadas saídas binárias em que apenas um neurônio é ativado para cada classe.

Os pesos das conexões são iniciados randomicamente. Para realizar o ajuste dos pesos da RNA foi utilizado o algoritmo *Backpropagation*. Este algoritmo de treinamento foi escolhido por existir também uma versão equivalente deste algoritmo para redes pulsadas (Bohte, 2003).

As funções de ativação que foram utilizadas são de dois tipos: bipolar sigmoidal para os neurônios da camada oculta e para os neurônios da camada de saída utilizou-se uma função linear, à qual foi aplicada arredondamento para se obter uma saída inteira. O computador usado nos testes apresenta a seguinte configuração: Processador Intel Pentium 4 Dual Core, com 3.00 Gb de memória RAM, utilizando Windows 7 Professional e o software MATLAB® na versão 2012a.

A metodologia de testes adotada consistiu em realizar 300 baterias de testes, com limite de 10.000 épocas de treinamento com 16 amostras de cada classe de flor. Entre todas as baterias, a melhor foi a que obteve uma taxa de acerto de 97,3% utilizando-se de 2807 épocas de treinamento, custando 125,01 segundos para o ajuste dos pesos. Este resultado pode ser considerado ótimo, notando que as classificações incorretas ocorreram em amostras que se sobrepunham no espaço dimensional. Nos casos em que esta sobreposição não existia a rede classificou corretamente as amostras.

O próximo passo desta pesquisa é realizar a implementação do outro modelo de rede, a utilizando arquitetura *Spiking* e realizar os mesmos testes aplicados à rede MP, com o objetivo de comparar as arquiteturas e avaliar o desempenho e qualidade de solução de ambas.

Referências

BOHTE, S. *Spiking Neural Networks*. Tese. Amsterdam: Academiegebouw of Leiden, University, Março, 2003.

FAUSETT, L. *Fundamentals of Neural Networks*. 1. ed. New Jersey: Prentice Hall, 1994.

FISHER, R. *Iris Data Set*. In: UC Irvine Machine Learning Repository. Disponível em: <<http://archive.ics.uci.edu/ml/datasets/Iris>> Acesso em, 28 jul. 2012.

GERSTNER, W. *Pulsed Neural Networks*. 1 ed. MIT Press: Cambridgem USA, 1999.

HAYKIN, S. *Redes Neurais - Princípios e prática*. 2. ed. Porto Alegre: Bookman, 2001.

JASKOWIAK, P. A. *Um estudo sobre Redes Neurais Pulsadas*. Trabalho de conclusão de Curso. Cascavel: Universidade Estadual do Oeste do Paraná, Dezembro, 2008.

SIMON, T. J. *Pulsed Neural Networks*. 1 ed. MIT Press: Cambridgem USA, 1999.

THORPE, S. J.; IMBERT, M. *Biological constraints on connectionist modelling*. Amsterdam: Elsevier (North-Holland), 1989.