# REDES NEURAIS ARTIFICIAIS: APRESENTAÇÃO E UTILIZAÇÃO DO ALGORITMO PERCEPTRON EM BIOSSISTEMAS

# ARTIFICIAL NEURAL NETWORKS: INTRODUCTION AND USE OF PERCEPTRON ALGORITHM IN BIOSSYSTEMS

Alfredo BONINI NETO[1]

Carolina dos Santos Batista BONINI[2]

## RESUMO

Redes Neurais Artificiais são modelos computacionais inspirados na maneira como um organismo vivo manipula as informações recebidas e com isso, possuem capacidade de aprendizado, adaptabilidade e generalização do conhecimento. Além disso, o modelo de processamento de uma Rede Neural Artificial é baseado no paralelismo, assemelhando-se como o cérebro lida com as informações recebidas por seus neurônios. O presente trabalho descreve o estudo da rede neural artificial Perceptron como um classificador linear para diferenciar dois tipos de frutas (laranja (*citrus sinensis Osbeck*) e tangerina '*Ponkan*' (*citrus reticulate Blanco*)) utilizando dois processos básicos desempenhados por uma rede neural artificial, as fases de treinamento ou aprendizado e operação. O objetivo principal é mostrar o funcionamento dessas fases.

**Palavras-chave:** Neurônio artificial, Classificação de grupos, Treinamento, Operação.

## ABSTRACT

Artificial Neural Networks are computational model inspired by way living organisms manipulate the information received, and with that, presents learning capability, adaptability and generalization of knowledge. Moreover, the operation of an Artificial Neural Network is based on parallelism, resembling as the brain deals with information received by the neurons. The present work describes the study of artificial neural network Perceptron as a linear classifier to distinguish two types of fruits (orange (*citrus sinensis Osbeck*) and tangerine '*Ponkan*' (*citrus reticulate Blanco*)) using two basic processes performed by an artificial neural network, the phases of training or learning and operation phase. The main objective is to show the functioning of these phases.

**Key words:** Artificial neuron, Classification of groups, Learning, Operation.

[1] Departamento de Matemática - Faculdades de Dracena/UNIFADRA
alfredobonininetto@hotmail.com
[2] Faculdades de Engenharia de Ilha Solteira - UNESP

## INTRODUÇÃO

As redes neurais artificiais (RNAs) são sistemas computacionais adaptativos inspirados nas características de processamento de informação semelhante ao neurônio biológico de organismos inteligentes (Haykin, 1999). Constituído de unidades de processamento simples, que têm a propensão natural para armazenar conhecimento experimental e torná-lo disponível para o uso. Essas redes permitem produzir saídas adequadas para entradas que não estavam presentes durante o treinamento.

Esses sistemas se assemelham ao cérebro humano de forma que o conhecimento de ambos são adquiridos a partir de seu ambiente através de um processo de aprendizagem e pela força de conexão entre os neurônios, no cérebro, e as redes, nos sistemas, denominados pesos sinápticos, os quais são utilizados para armazenar o conhecimento adquirido (BRAGA, et. al, 2007).

Baseado na relação das redes neurais artificiais com os neurônios biológicos, em que nos neurônios biológicos há os dendritos que recebem as informações, o corpo celular que soma e assimila essa informação e o axônio que transmite tal informação resultada pelos impulsos nervosos, assim ocorrendo a conexão entre os neurônios pela sinapse (representados na figura 1).

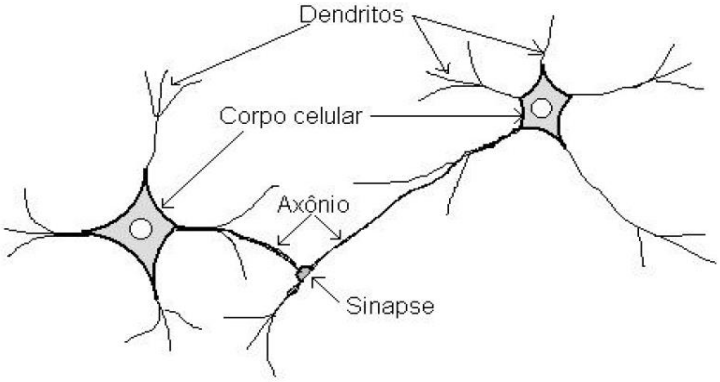


Figura 1. Representação de um neurônio biológico

Portanto, em meio a essa comparação, as redes neurais artificiais devem conter entradas, que seriam as informações, os pesos que seriam determinantes da sinapse, a assimilação dessa informação e uma saída obtida de tal processo (Mcculloch e Pitts, 1943), figura 2.

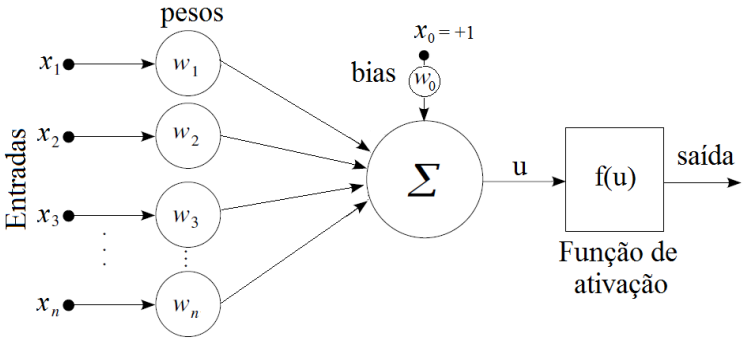


Figura 2. Modelo artificial de neurônio biológico.

onde o $\sum$ representa o somatório dos produtos das entradas pelos respectivos pesos, ou seja, $u = \sum_{i=1}^{n} \mathbf{x}_i \, \mathbf{W}_i + \text{bias}$ e f(u) é a função de ativação para obter a saída, existem várias funções de ativação como mostrado na tabela 1:

Tabela1: Tipos de funções de ativação.

| Função relé (degrau) | Função lógica | Função sigmoide (1) | Função sigmoide (2) |
|---|---|---|---|
| 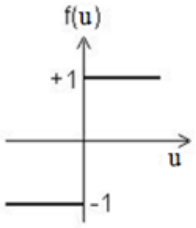  | 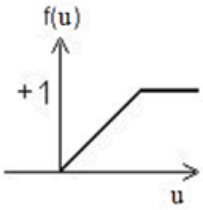  | 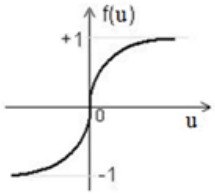  | 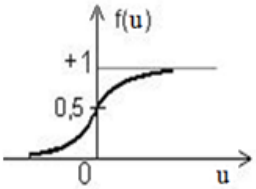  |
| $f(u) = \begin{cases} +1 & \text{se } u \geq 0 \\ -1 & \text{se } u < 0 \end{cases}$ | $f(u) = \begin{cases} \lambda u & \text{se } 0 \leq u \leq t \\ +1 & \text{se } u > t \end{cases}$ | $f(u) = \frac{(1 - e^{-\lambda u})}{(1 + e^{-\lambda u})}$ | $f(u) = \frac{1}{(1 + e^{-\lambda u})}$ |

$\lambda =$ inclinação, $\lambda$ e $t$ constantes reais

As RNAs são classificadas da seguinte forma: Redes recorrentes (feedforward) e redes não recorrentes. As redes recorrentes são aquelas que contêm laços de realimentação, ou seja, contém conexões das saídas de uma determinada camada para a entrada da mesma ou de camadas anteriores e redes não recorrentes, são aquelas que não possuem laços de realimentação, caracteriza-se estruturalmente por estar disposta em camadas (Minussi, 2003), figura 3 e 4.

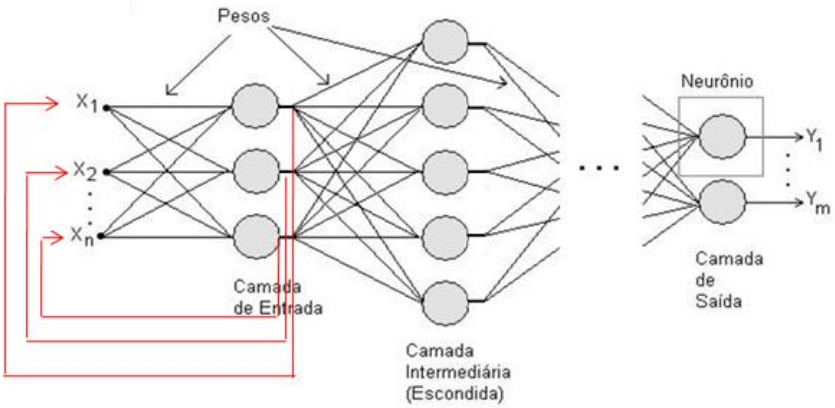


Figura 3: RNA recorrente

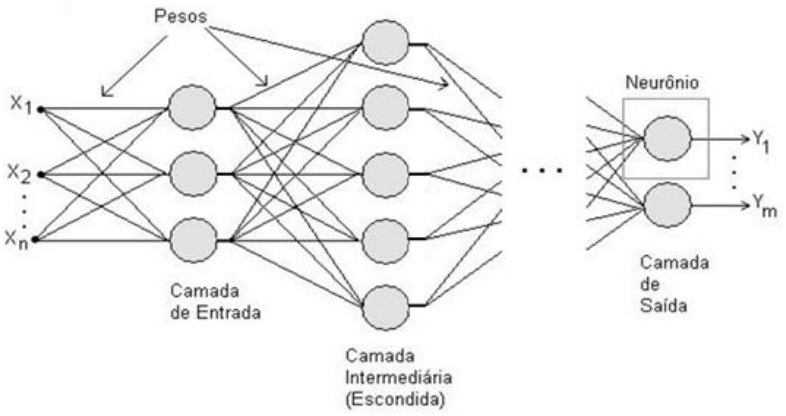


Figura 4: RNA não recorrente

Com a evolução das pesquisas foram criados alguns tipos de redes neurais artificiais. No trabalho apresentado foi utilizado o algoritmo *Perceptron* de uma camada, que é utilizado um classificador linear.

OBJETIVO

Neste trabalho foi estudado o algoritmo *Perceptron* – fase de treinamento para obtenção dos pesos, que em seguida foram aplicados na fase de operação para classificar dois tipos de frutas (laranja (*citrus sinensis Osbeck*) e tangerina 'Ponkan' (*citrus reticulate Blanco*)).

ALGORITMO PERCEPTRON

Inventado em 1957 por Frank Rosenblatt nos EUA, o algoritmo *Perceptron* é a forma mais simples de rede neural artificial sendo utilizado como classificador linear, o qual consiste de um único neurônio com pesos sinápticos ajustáveis e bias. É limitado a realizar classificações de apenas dois grupos.

Simula um neurônio com entradas e pesos que, ajustados teriam a capacidade de aprender a se comportar de determinada forma. Porém, para que as saídas sejam as desejadas é necessário que haja o ajustamento dos pesos para a fase de operação ser adequada. A fase treinamento ocorre da seguinte maneira: o usuário fornece as entradas e as saídas esperadas e os pesos recebem valores iniciais (normalmente próximos de zero), as entradas são multiplicadas aos pesos e depois tudo é somado e avaliado com um valor de limite, caso esta soma seja maior que este valor, o resultado é 1, caso contrário, -1 (função degrau).

Fase de Treinamento

A propriedade mais importante das redes neurais é a habilidade de aprender e com isso melhorar seu desempenho. Isso é feito através de um processo iterativo de ajustes aplicados a seus pesos **W** que correspondem ao treinamento. Existem dois tipos de treinamento, supervisionado e o não supervisionado (Minussi, 2003).

Treinamento Supervisionado consiste no ajuste de pesos de uma rede neural para fornecer saídas desejadas. O treinamento supervisionado necessita de um de vetor de entrada e vetor alvo representando a saída desejada, figura 5.

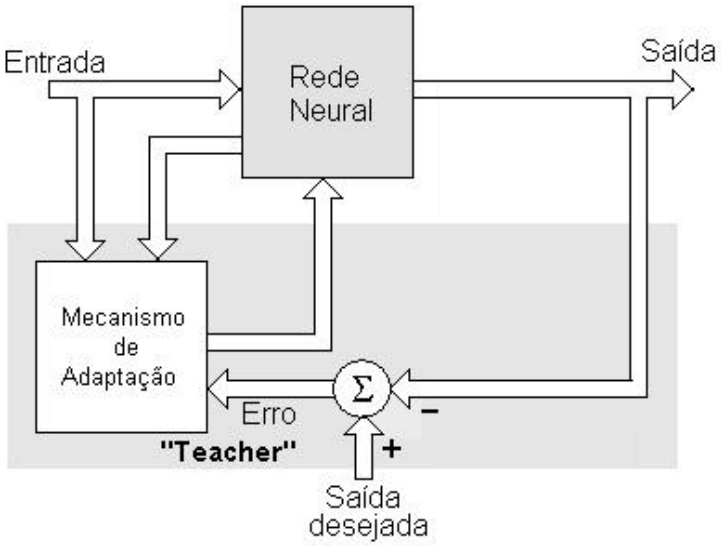


Figura 5: Treinamento supervisionado

Treinamento não supervisionado consiste no ajuste de pesos de uma rede neural, levando-se em conta somente o conjunto de padrões de entrada (treinamento auto-organizável), conforme a figura 6.

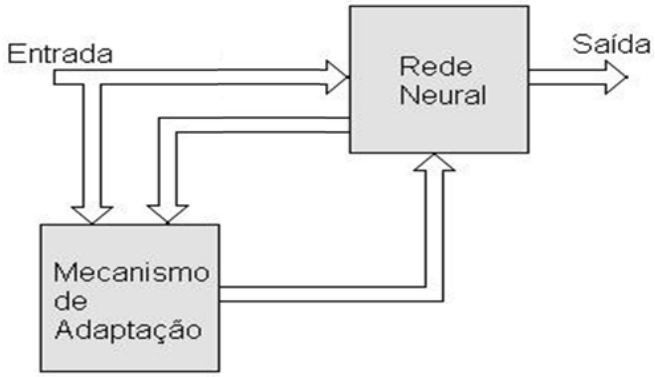


Figura 6: Treinamento não supervisionado

O programa utilizado neste trabalho para o treinamento da rede foi desenvolvido pelo software OCTAVE, que é um software livre e de fácil aquisição. A seguir é apresentado o fluxograma do algoritmo *Perceptron* para treinamento, figura 7.

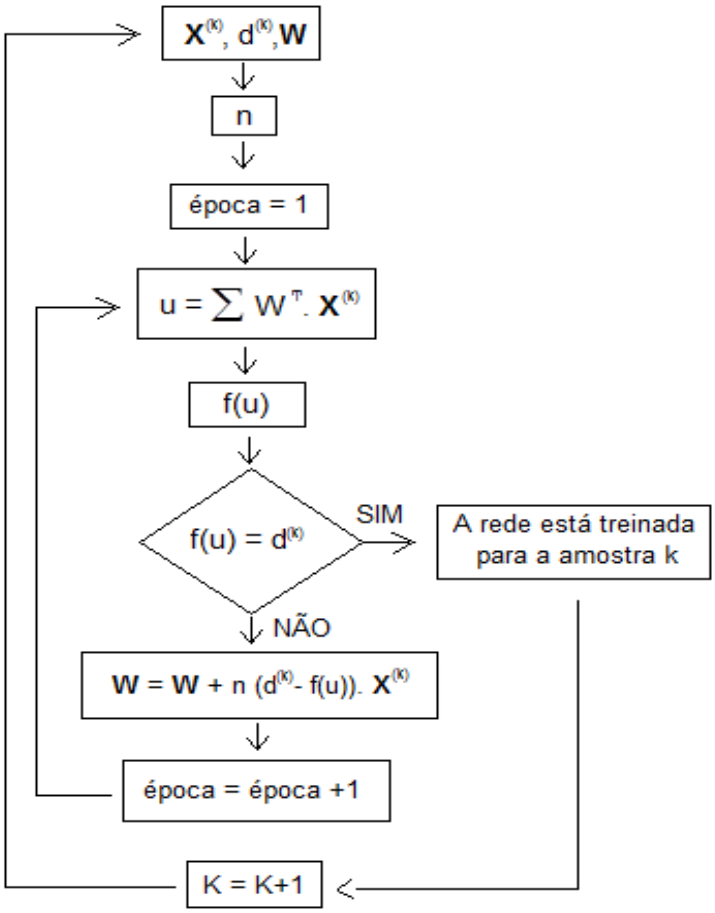


Figura 7. Fluxograma do algoritmo *Perceptron* – fase de treinamento

Em que **X** = entradas; **W** = pesos da rede (para o início do treinamento são aleatórios); d = saídas desejadas; n = taxa de aprendizagem e $f(u)=\begin{cases}1 \text{ se } u \geq 0 \\ -1 \text{ se } u < 0\end{cases}$ é a função de ativação degrau.

Portanto, os pesos são ajustados pela seguinte fórmula:

$$\mathbf{W}_{novo} = \mathbf{W}_{anterior} + \mathrm{n}[\mathrm{d}^{\mathrm{k}} - \mathrm{f(u)}]\mathbf{x}^{\mathrm{k}}$$

onde $\mathbf{W}_{novo}$ é o novo peso, que é ajustado levando em conta: o peso anterior $\mathbf{W}_{anterior}$ e o erro. O erro é calculado pela diferença entre o valor esperado ($d^k$) e o valor encontrado f(u), multiplicado pela entrada associada e por um valor chamado de taxa de aprendizado. A taxa de aprendizado n é geralmente um valor pequeno que incrementará os novos valores dos pesos para o próximo ajuste.

Neste trabalho como saída desejada utilizamos o valor 1 para a fruta tangerina e o valor -1 para a fruta laranja, tendo como entradas três atributos ($x_1$, $x_2$ e $x_3$) = [P (fósforo), pH (acidez) e Ca(Cálcio)] para cada amostra, tabela 2.

Fase de Operação

Após ser definida a reta de separação da rede *Perceptron*, através do processo de treinamento, a rede estará apta a classificar padrões de acordo com a sua aplicação anteriormente estabelecida. Portanto, na fase de operação ou execução, o *Perceptron* produz para cada amostra, as respectivas saídas desejadas, e, além disso, se torna capaz de classificar amostras que não fizeram parte da fase de treinamento, isto é, a

rede possui a habilidade de generalizar o conhecimento adquirido. A seguir é apresentado o fluxograma do algoritmo *Perceptron*- fase de operação, desenvolvido também pelo software OCTAVE, figura 8.

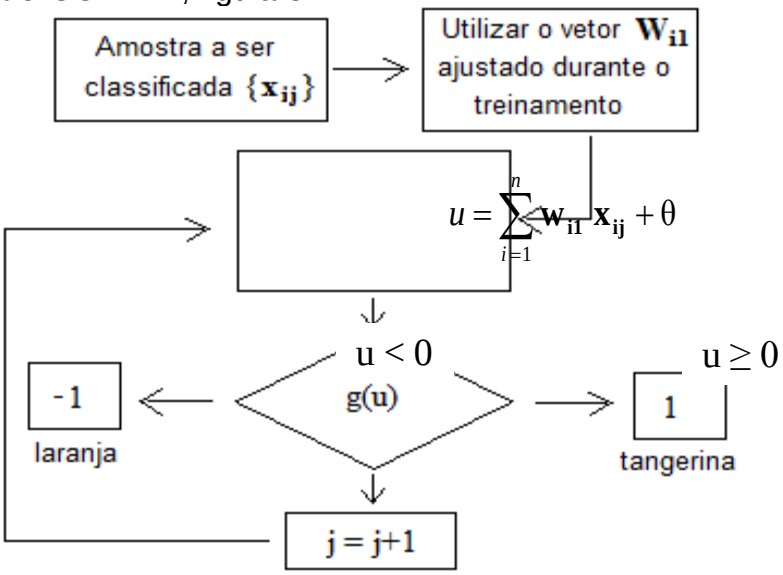


Figura 8. Fluxograma do algoritmo *Perceptron* – fase de operação.

onde:

$\mathbf{W_{i1}} = [w_{01}, w_{11}, w_{21}, ...., w_{n1}]'$, $\mathbf{x_{ij}} = [x_{0j}, x_{1j}, x_{2j}, ...., x_{nj}]'$, $\text{bias} = \theta = w_{01}\, x_{0j}$, onde $x_{0j} = 1$ e $g(u) = \begin{cases} 1 \text{ se } u \geq 0 \\ -1 \text{ se } u < 0 \end{cases}$ é a função de ativação degrau que é a mesma no processo de treinamento.

RESULTADOS

Para este trabalho foram utilizadas três entradas ($x_1$, $x_2$ e $x_3$), em que $x_1$ representa o P (fósforo), $x_2$ representa o pH (acidez) e $x_3$ representa o Ca (Cálcio) que são os atributos das frutas utilizadas para a classificação. Para o processo de treinamento foram utilizados 4 amostras e para cada amostra a saída desejada (1 para tangerina e -1 para laranja), conforme a tabela 2.

Tabela 2. Valores dos atributos em *mg* para as 4 amostras utilizadas no treinamento.

| Tipo de fruta | Tang. | Tang. | Lar | Lar. |
|---|---|---|---|---|
| P | 0,1 | 0,5 | 0,6 | 0,3 |
| pH | 0,4 | 0,7 | 0,9 | 0,7 |
| Ca | 0,7 | 0,1 | 0,8 | 0,2 |
| Saída Desejada ($d^k$) | 1 | 1 | -1 | -1 |

Foi tomado para a taxa de aprendizagem n=0,05. Os pesos **W** obtidos na fase de treinamento utilizando o algoritmo apresentado na

figura 7 podem ser vistos na tabela 3, onde foram feitos 2 testes. Pode ser observado que foram utilizadas 38 épocas para obter os pesos do teste 1 e 54 épocas para o teste 2.

Tabela 3. Valores dos pesos obtidos pela RNA – *Perceptron* na fase de treinamento.

| | Época | $W_0$ | $W_1$ | $W_2$ | $W_3$ |
|---|---|---|---|---|---|
| Teste 1 | 38 | -6 | 0,8 | -8,6 | -3,6 |
| Teste 2 | 54 | -0,241 | 0,680 | -0,778 | 0,015 |

Os **W** ajustados são comprovados na tabela 4, onde se verifica que para os testes, as saídas obtidas na fase de operação utilizando o algoritmo apresentado na figura 8, mostrando a classificação dos grupos. As 4 primeiras amostras são as mesmas da fase de treinamento, as outras 4 amostras são aleatórias, ou seja, que não fizeram parte do processo de treinamento.

Tabela 4. Saídas das 8 amostras ($A_i$) na fase de operação para os **W** ajustados obtidos na fase de treinamento.

| | | $A_1$ | $A_2$ | $A_3$ | $A_4$ | $A_5$ | $A_6$ | $A_7$ | $A_8$ |
|---|---|---|---|---|---|---|---|---|---|
| Hca | P | 0,1 | 0,5 | 0,6 | 0,3 | 0,2 | 0,5 | 0,3 | 0,2 |
| | p | 0,4 | 0,7 | 0,9 | 0,7 | 0,3 | 0,8 | 0,6 | 0,6 |
| | C | 0,7 | 0,1 | 0,8 | 0,2 | 0,6 | 0,8 | 0,4 | 0,3 |
| | Saída obtida (Teste 1) | | | | | | | | |
| | u | 0.12 | 0.02 | -4.14 | -0.5 | .42 | -3.36 | -0.36 | -0.08 |
| | f(u) | 1 | 1 | -1 | -1 | 1 | -1 | -1 | -1 |
| | Saída obtida (Teste 2) | | | | | | | | |
| | u | 0.0083 | 0.037 | -0.039 | -0.096 | .152 | -0.029 | -0.015 | -0.085 |
| | f(u) | 1 | 1 | -1 | -1 | 1 | -1 | -1 | -1 |
| | Tipo de fruta | | | | | | | | |
| | | Tang. | Tang. | Lar. | Lar. | Tang. | Lar. | Lar. | Lar. |

CONCLUSÃO

As redes neurais artificiais são tipicamente usadas em reconhecimento de padrões, onde informação das características da classe analisada é apresentada à rede e a tarefa é categorizar o padrão característico da entrada como pertencente a uma ou mais classes.

O trabalho apresentou o algoritmo *Perceptron* - fase de treinamento, em que os pesos ajustados para a classificação de dois tipos de frutas foram obtidos, e o algoritmo *Perceptron* na fase de operação, que conseguiu classificar a tangerina e a laranja. Portanto, conclui-se que o algoritmo *Perceptron* consegue classificar tipos de frutas e também pode ser utilizada para classificar outros tipos de grupos.

REFERÊNCIAS

Haykin S., Neural Networks: a comprehensive foundation. New York: MacMillan. College Publishing Co., 1999.

BRAGA, A. de P.; CARVALHO, A. P. de L. F. de; LUDERMIR, T. B. Redes Neurais Artificiais – Teoria e Aplicações. 2.ed. Rio de Janeiro: LTC, 2007. p. 1-20

Mcculloch W. S. e Pitts, W. A. Logical Calculus of the Ideas Immanent in Nervous Activity, *Bulletin of Mathematical Biophysics*, 1943, No. 9, pp. 127-147.

Minussi C. R. Redes Neurais: Introdução e principais conceitos. Faculdade de Engenharia de Ilha Solteira. Notas de aula – UNESP. 2003.