

Aula 1

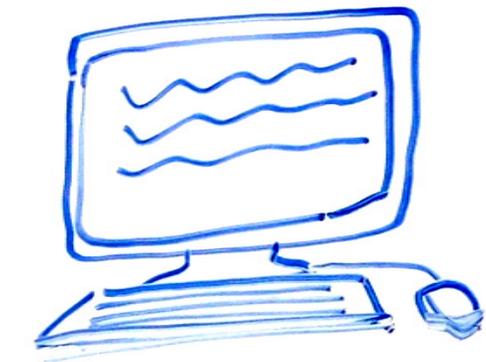
Introdução - RNA

Sumário

- 1- Conceitos Iniciais;
- 2- Neurônio Biológico;
- 3- Neurônio Artificial;
- 4- Funções de Ativação;
- 5- Comparação Neurônio Biológico e Artificial.

1- Conceitos Iniciais

- Computadores podem realizar diversas operações mais rápido do que seres humanos;
- Outras ações o ser humano tem uma melhor capacidade de realização



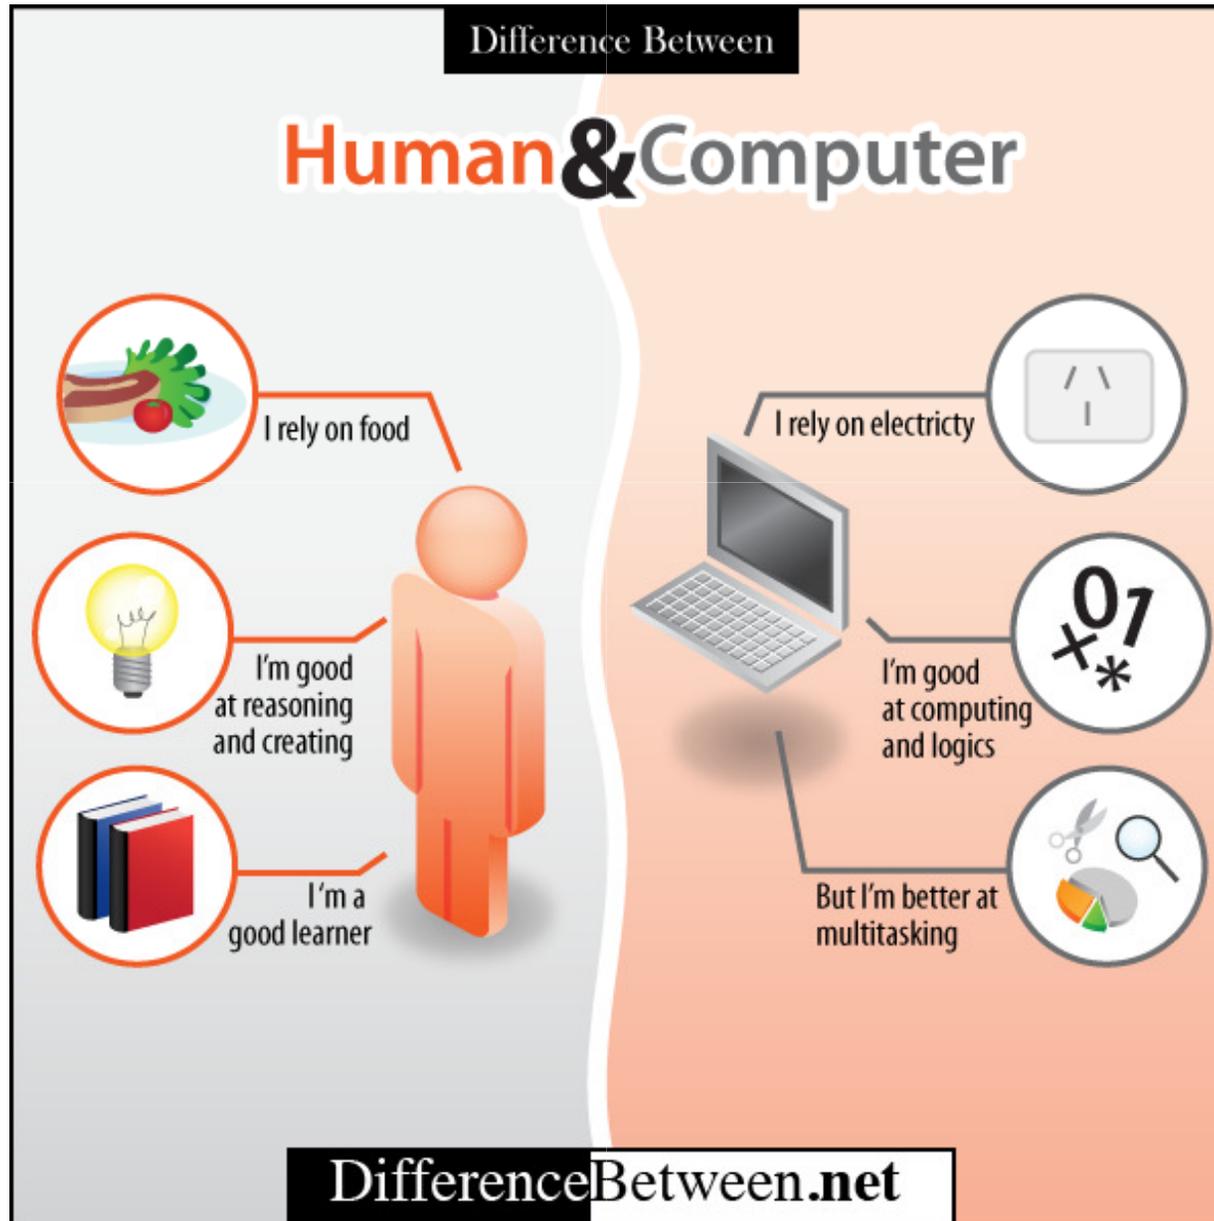
COMPUTER

VS



HUMAN

1- Conceitos Iniciais



1- Conceitos Iniciais

- Os primeiros trabalhos com RNA surgiram na década de 50;
- O tema RNA (ANN – Artificial Neural Network) se tornou um tema popular para pesquisa científica a partir de 1990;
- Exemplos de uso de RNA:
 - 1) Avaliação de imagens captadas por satélite;
 - 2) Classificação de padrões de escrita e fala;
 - 3) Reconhecimento de faces com visão computacional;
 - 4) Sistemas de controle e previsão financeira;
 - 5) Identificação de anomalias e patologias na área médica com base em imagens;
 - 6) Controle automatizado de equipamentos eletrônicos.

1- Conceitos Iniciais

“Redes neurais artificiais são modelos computacionais inspirados no sistema nervoso de seres vivos”

- Possuem capacidade de aquisição e manutenção do conhecimento;
- São caracterizados pela unidade de processamento chamada de neurônio;
- Cada unidade (neurônio) é ligado por meio das sinapses Artificiais;
- Computacionalmente falando são representadas por matrizes e vetores de pesos sinápticos;

1- Conceitos Iniciais

Principais características:

- a) **Adaptação por experiência:** Os pesos sinápticos são ajustados a partir da apresentação sucessiva de exemplos.
- b) **Capacidade de aprendizado:** É possível extrair o relacionamento existente entre as diversas variáveis que compõem a aplicação.
- c) **Habilidade de generalização:** Por meio do processo de treino, a rede é capaz de generalizar o comportamento aprendido para estimar uma solução, até então desconhecida.
- d) **Organização de dados:** A rede é capaz de realizar uma organização interna visando o agrupamento de padrões e particularidades
- e) **Tolerância a falhas:** Devido ao elevado número de interconexões entre os neurônios, a rede se torna um sistema tolerante a falhas quando sensivelmente corrompido;

1- Conceitos Iniciais

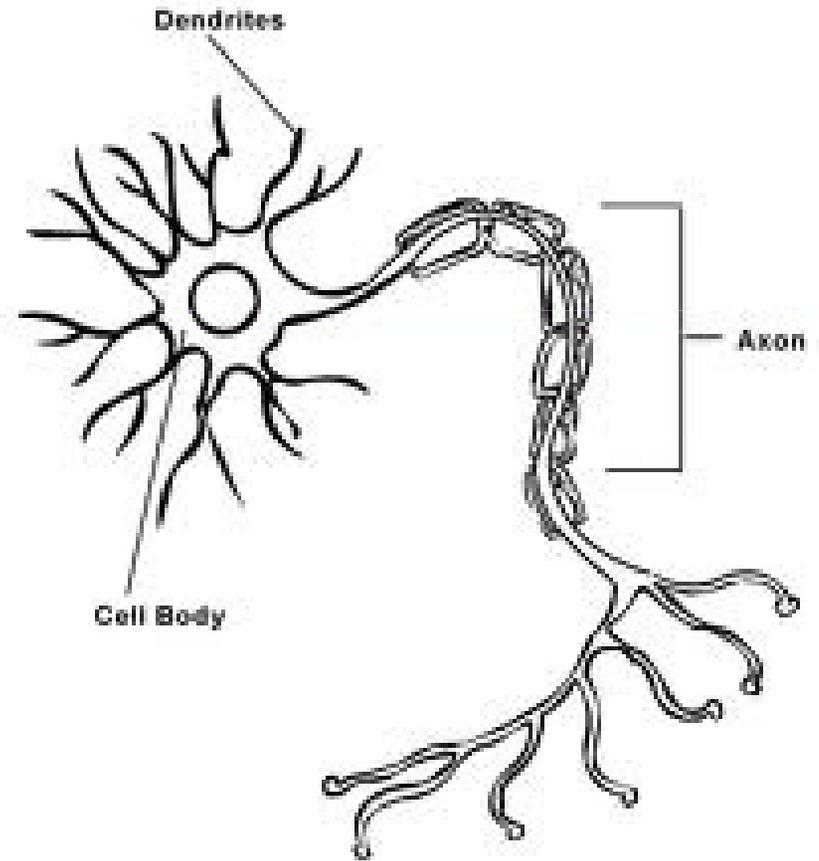
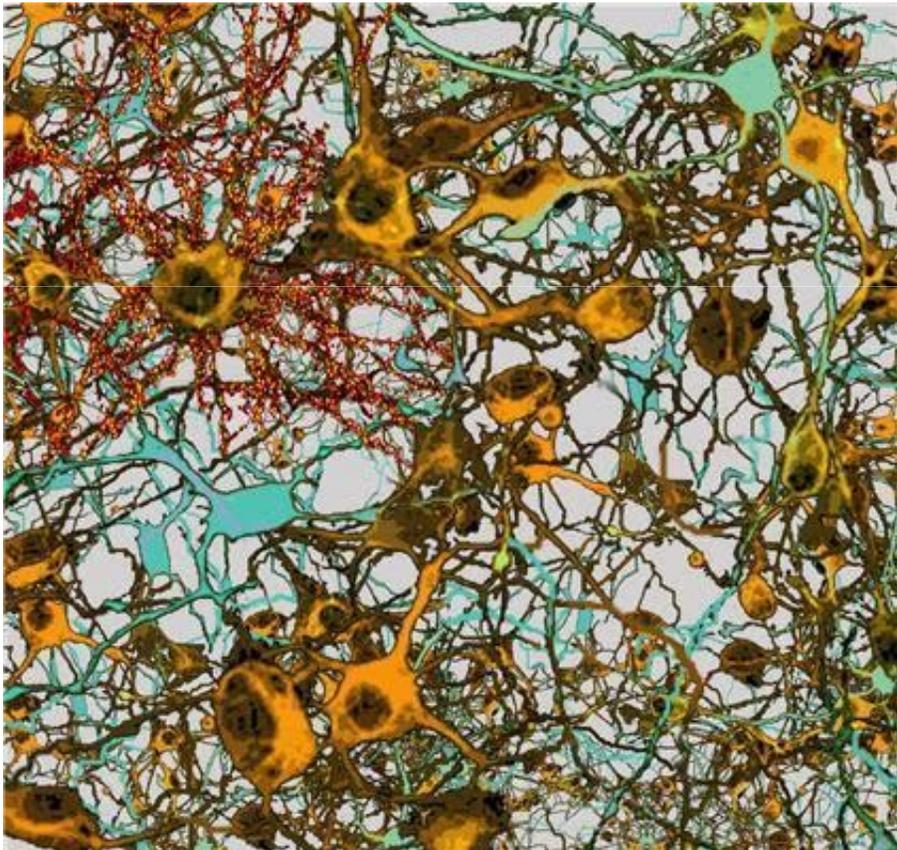
Principais características:

f) Armazenamento distribuído: o conhecimento a respeito do comportamento de um processo é distribuído entre os neurônios, aumentando a robustez do sistema frente a eventuais neurônios inoperantes;

g) Facilidade de prototipagem: a implementação da maioria das arquiteturas neurais pode ser facilmente desenvolvida pois são baseadas em operações matemáticas elementares;

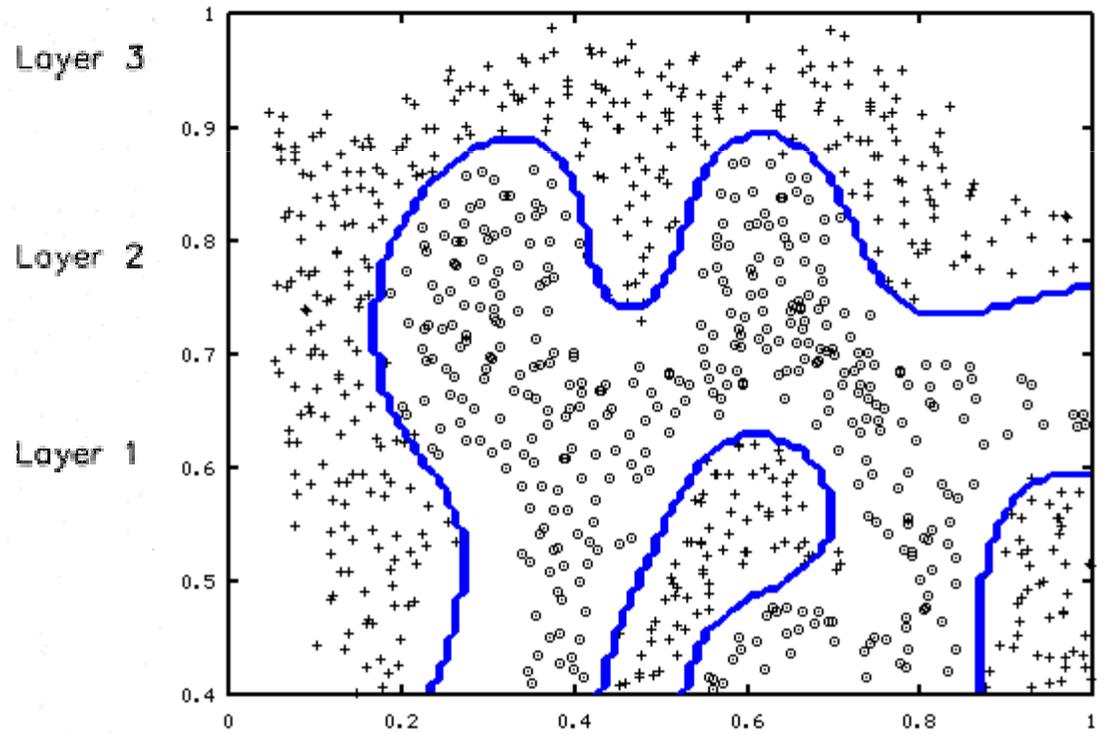
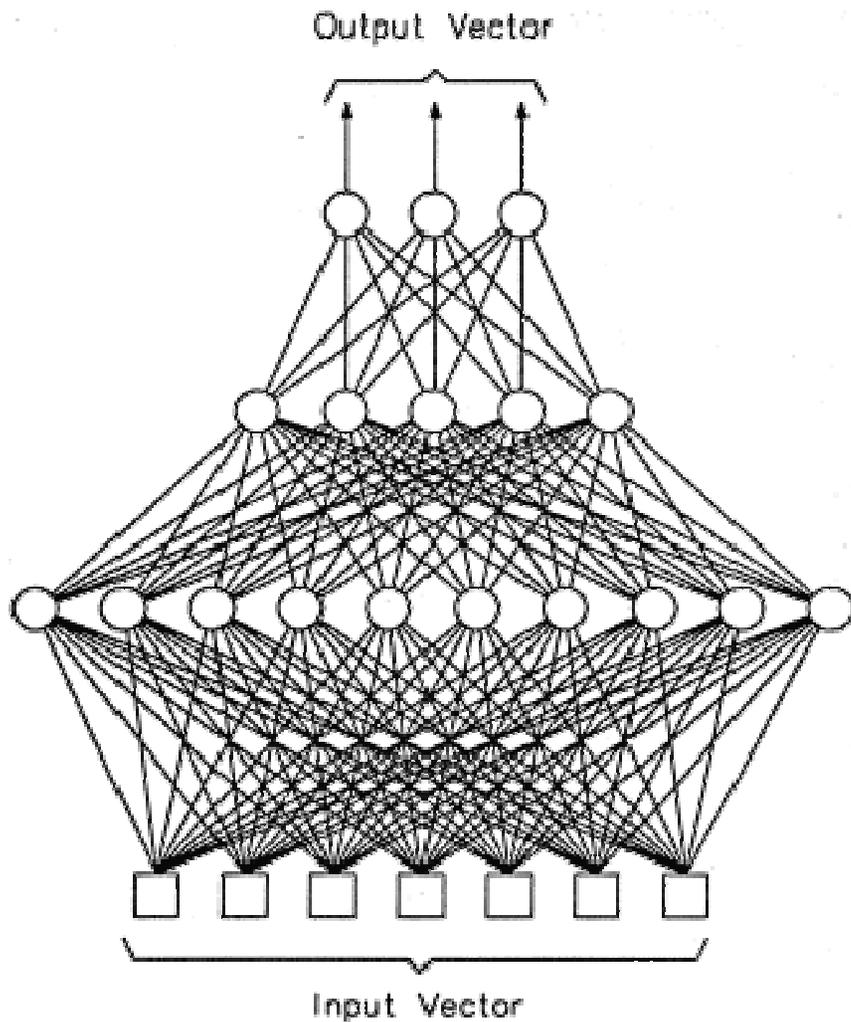
2- Neurônio Biológico

Rede Neural Biológica / Neurônio



3- Neurônio Artificial

Rede Neural Artificial

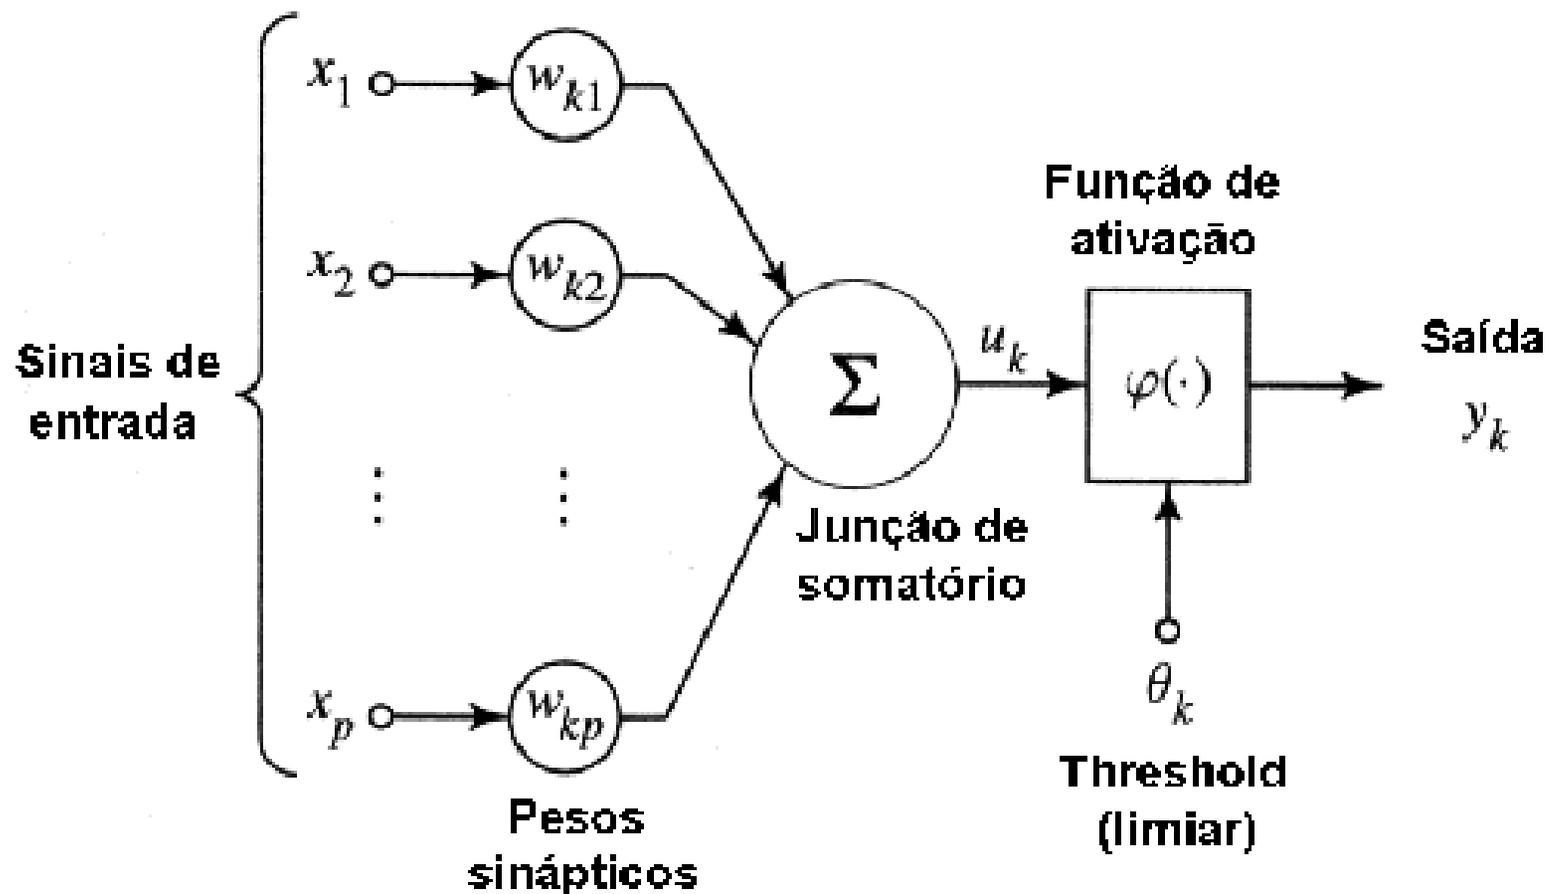


Andrew Ng's machine learning course

barbon@uel.br

3- Neurônio Artificial

Rede Neural Artificial



neurônio de McCulloch-Pitts (Haykin, 1994)

3- Neurônio Artificial

Componentes da Rede Neural Artificial:

a) Sinais de entrada $\{x_1, x_2, \dots, x_n\}$

Sãos os sinais ou medidas externos que representam valores assumidos pelas variáveis da aplicação;

b) Pesos sinápticos $\{w_{k1}, w_{k2}, \dots, w_{kn}\}$

São os valores que servirão para ponderar cada uma das variáveis de entrada da rede, permitindo qualificar a relevância em relação as funcionalidades do neurônio;

c) Combinador Linear (Junção de Somatórios - Σ - *sigma*)

Também chamado de Função Soma, sua função é agregar os sinais de entrada produzindo um valor potencial de ativação.

d) Limiar de ativação (θ - *theta*)

É uma variável que identifica o patamar apropriado para o resultado produzido pelo combinador linear

neurônio de McCulloch-Pitts (Haykin, 1994)

3- Neurônio Artificial

Componentes da Rede Neural Artificial:

e) Potencial de ativação $\{u_n\}$

É o resultado produzido pela avaliação do limiar de ativação e o combinador linear. Caso $u \geq \theta$, então o neurônio produz um potencial excitatório.

f) Função de ativação $\{g(.)$ ou $\varphi(.)$ - *varphi*

Seu objetivo é limitar a saída do neurônio dentro de um intervalo de valores assumidos pela arquitetura da rede.

g) Sinal de saída $\{y_n\}$

Consiste no valor final produzido pelo neurônio em relação a um determinado conjunto de entrada

neurônio de McCulloch-Pitts (Haykin, 1994)

barbon@uel.br

3- Neurônio Artificial

$$y = \varphi \left(\sum_{i=1}^n w_i x_i - \theta \right)$$

neurônio de McCulloch-Pitts (Haykin, 1994)

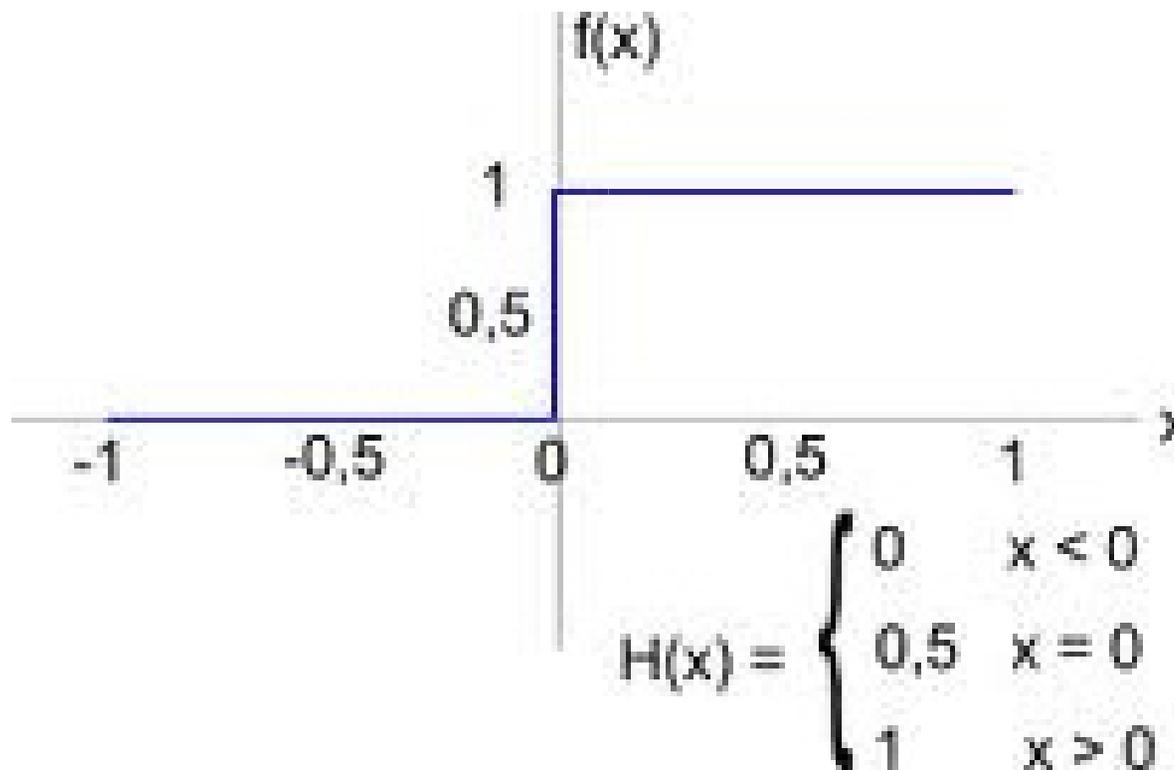
barbon@uel.br

4 - Funções de Ativação

Funções de Ativação Tradicionais:

a) Função Degrau (*heavyside / hard limiter*)

O valor resultante será 0 ou 1.

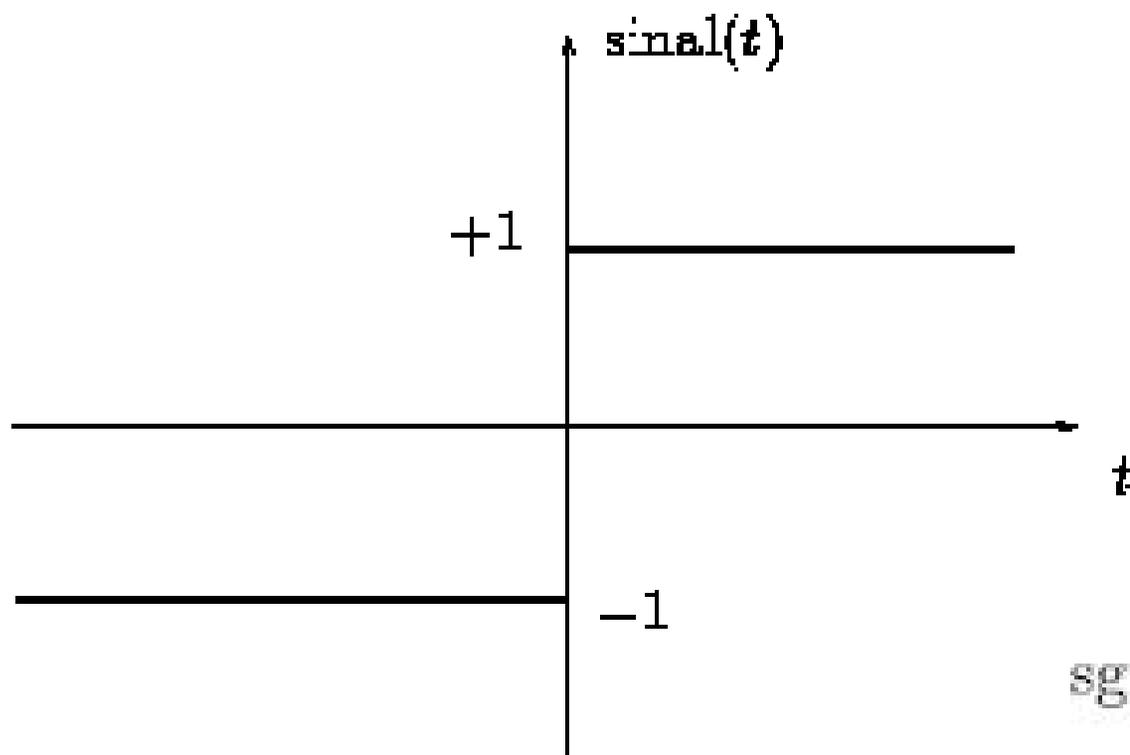


4 - Funções de Ativação

Funções de Ativação Tradicionais:

b) Função Degrau Bipolar ou Função Sinal (*symmetric hard limiter*)

O valor resultante será -1, 0 ou 1.



$$\text{sgn } x = \begin{cases} -1 & : x < 0 \\ 0 & : x = 0 \\ 1 & : x > 0. \end{cases}$$

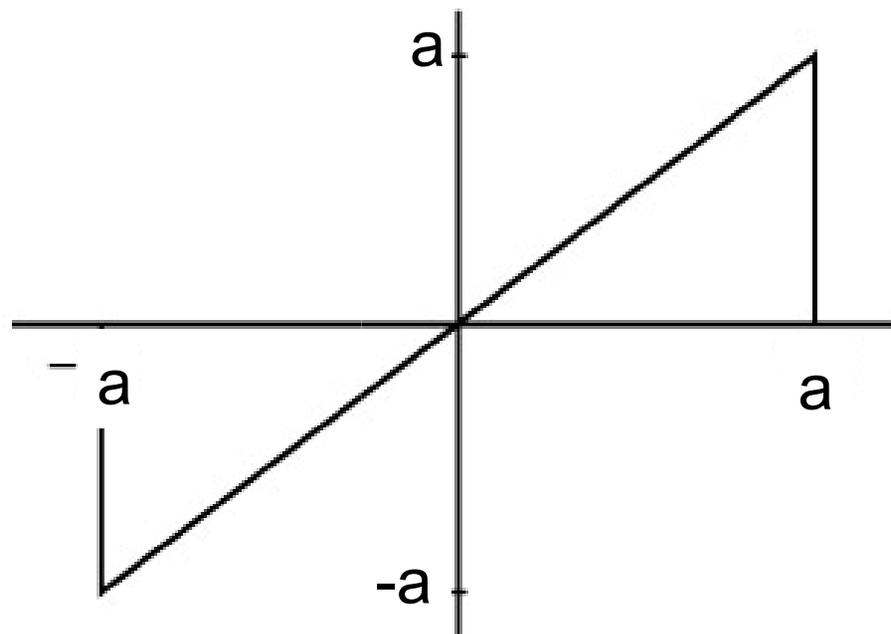
4 - Funções de Ativação

Funções de Ativação Tradicionais:

c) Função Rampa Simétrica

Os valores retornados são iguais aos próprios valores de entrada quando definidos no intervalo $[-a, a]$.

$$g(u) = \begin{cases} a, & \text{se } u > a \\ u, & \text{se } -a \leq u \leq a \\ -a, & \text{se } u < -a \end{cases}$$

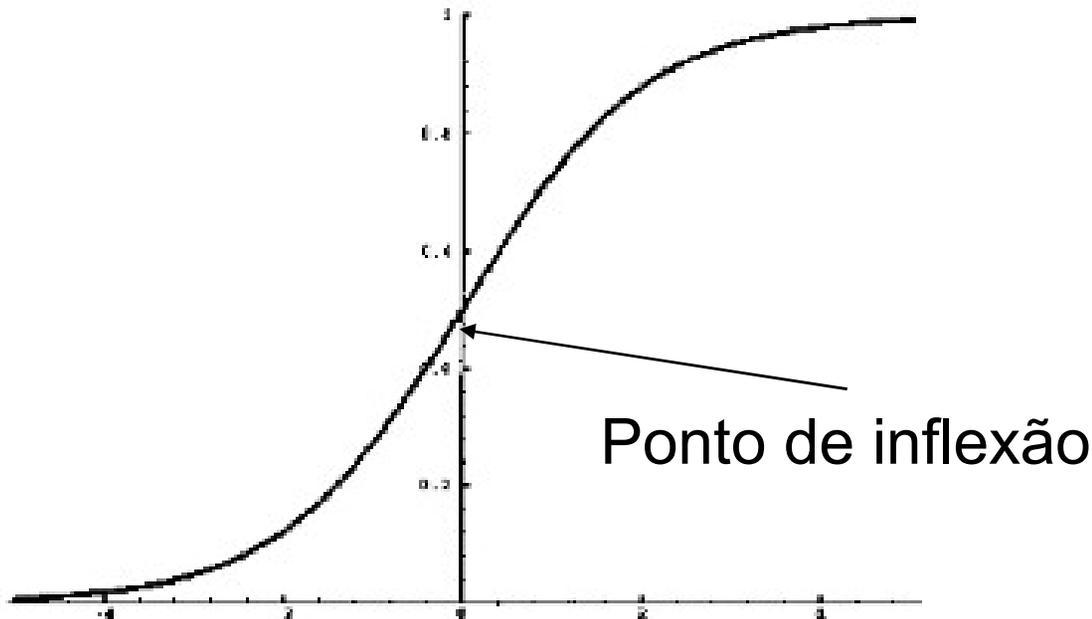


4 - Funções de Ativação

Funções de Ativação Tradicionais:

e) Função Logística

O resultado de saída produzido pela aplicação da função logística assumirá valores reais entre 0 e 1, dado por:



$$g(u) = \frac{1}{1 + e^{-\beta u}}$$

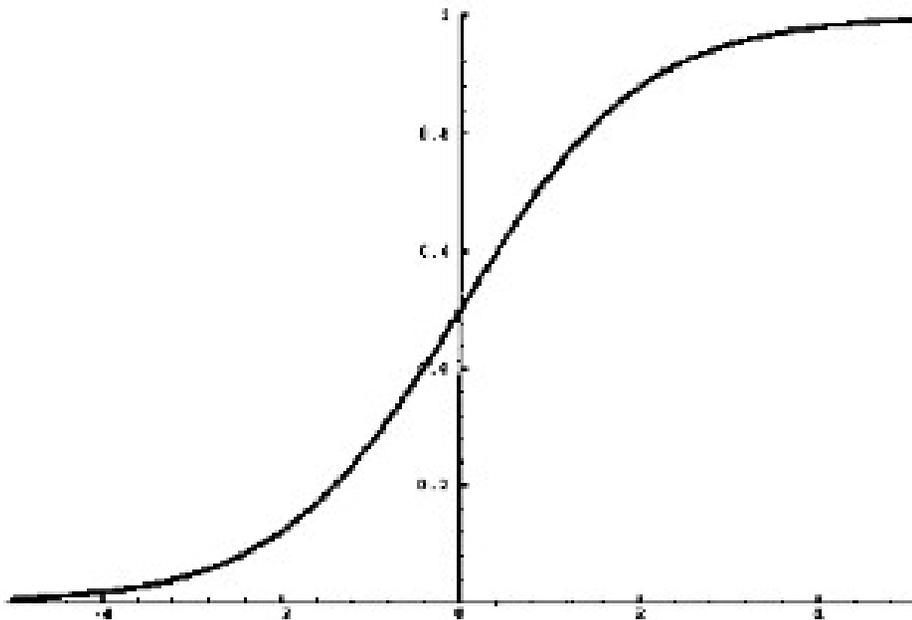
Nível de inclinação

4 - Funções de Ativação

Funções de Ativação Tradicionais:

f) Função Tangente Hiperbólica

O resultado de saída produzido pela aplicação da função logística assumirá valores reais entre -1 e 1, dado por:



$$g(u) = \frac{1 - e^{-\beta u}}{1 + e^{-\beta u}}$$

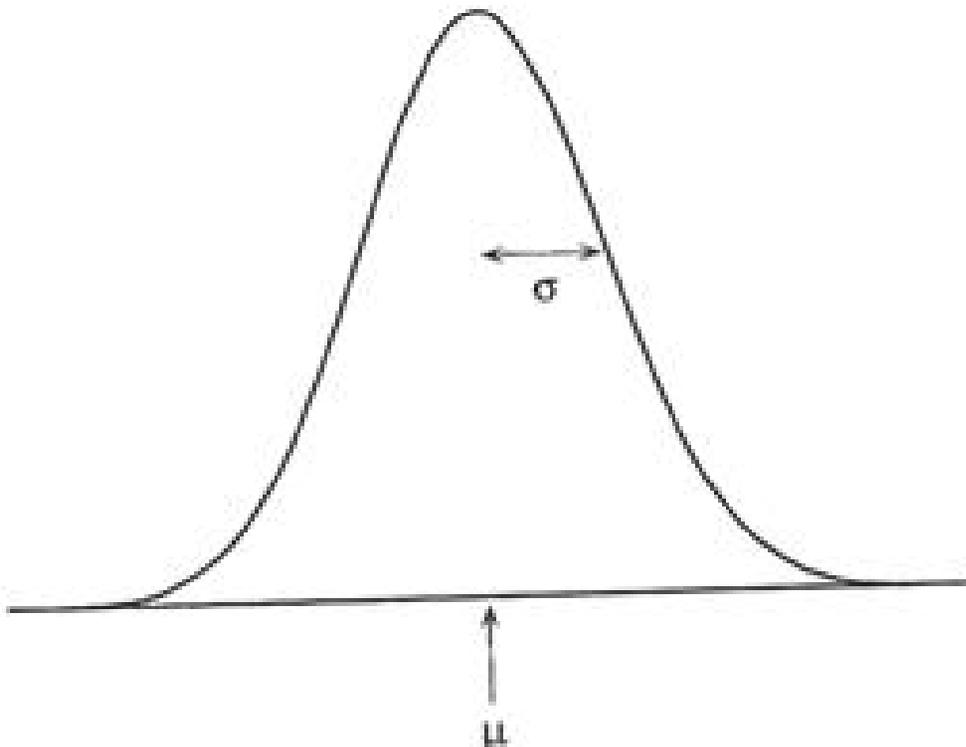
Nível de inclinação

4 - Funções de Ativação

Funções de Ativação Tradicionais:

g) Função Gaussiana

A saída do neurônio produzirá resultados iguais a o potencial de ativação $\{u\}$ quando posicionados a uma mesma distância do centro (média)



$$g(u) = e^{-\frac{(u-c)^2}{2\sigma^2}}$$

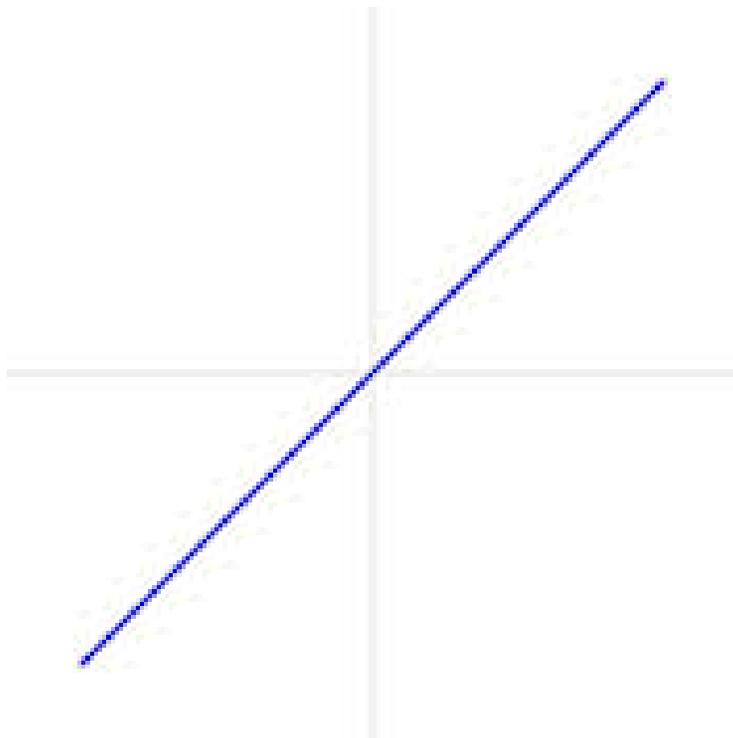
↑
variância

4 - Funções de Ativação

Funções de Ativação Tradicionais:

h) Função linear

A saída do neurônio produzirá resultados idênticos aos valores do potencial de ativação $\{u\}$



$$g(u) = u$$

Comparação Neurônio Biológico e Artificial

Parâmetro	Neurônio Artificial	Neurônio Biológico
Eficiência Energética (Operações/segundos)	10^{-6}J	10^{-16}J
Tempo de Processamento (Operação/neurônio)	10^{-9}s (Ghz)	10^{-3}s
Mecanismo de Processamento	Sequencial	Paralelo

Referências:

Silva, IN da, Danilo Hernane Spatti, and Rogério Andrade Flauzino. "Redes neurais artificiais para engenharia e ciências aplicadas." São Paulo: Artliber (2010).