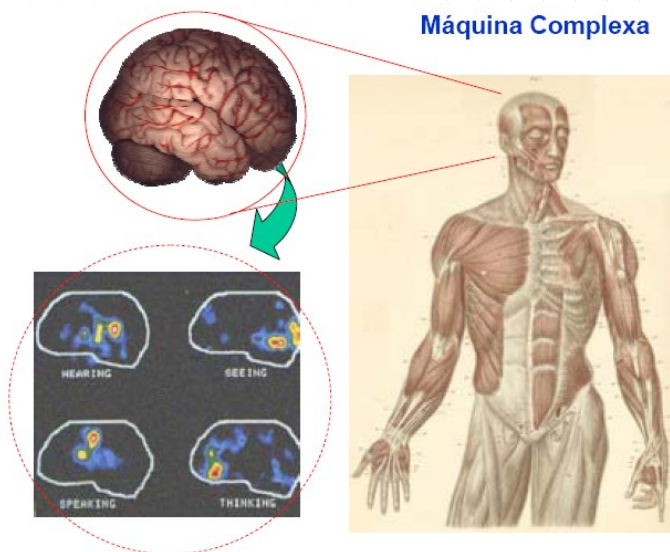



Neural networks do not perform miracles. But if used sensibly they can produce some amazing results.

INTRODUÇÃO

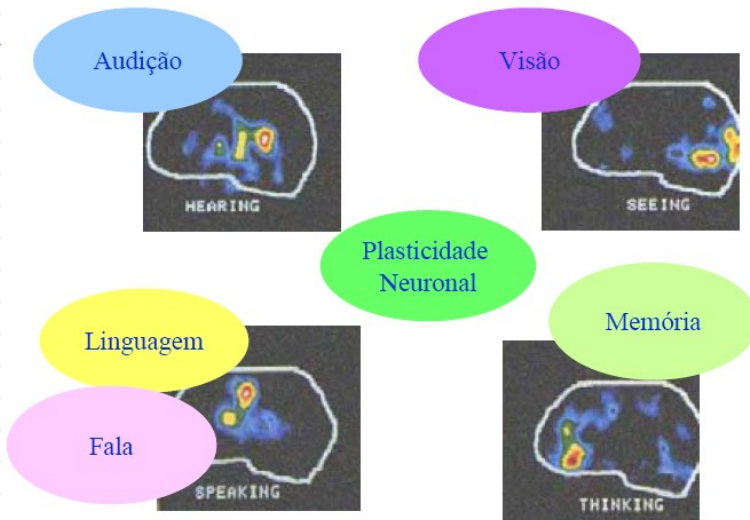
Máquina Complexa



INTRODUÇÃO



INTRODUÇÃO



INTRODUÇÃO

- Motivação
- Objetivo
- Definição
- Características Básicas
- Neurônio Artificial
- Topologia da Rede

MOTIVAÇÃO

Constatação que o cérebro processa informações de forma diferente dos computadores convencionais

Cérebro

velocidade de 1 milhão de vezes mais lenta que qualquer “gate” digital → processamento extremamente rápido no reconhecimento de padrões

Computador

processamento extremamente rápido e preciso de seqüência de instruções → Muito mais lento no reconhecimento de padrões.

Processamento altamente paralelo, 10^{11} neurônios com 10^2 conexões cada.

MOTIVAÇÃO

Organiza os neurônios para executar tarefas muito mais rapidamente do que os computadores digitais:

- 1) Cérebro com o sistema visual humano no reconhecimento de uma face familiar em cena não familiar (mais rápido que os computadores).
- 2) O morcego (cérebro - dimensão de uma ameixa) na extração de informações (distância de um alvo, velocidade relativa, tamanho, dimensões de várias características, azimute e elevação).

MOTIVAÇÃO

- O cérebro constrói as próprias regras através de experiências (conhecimento).

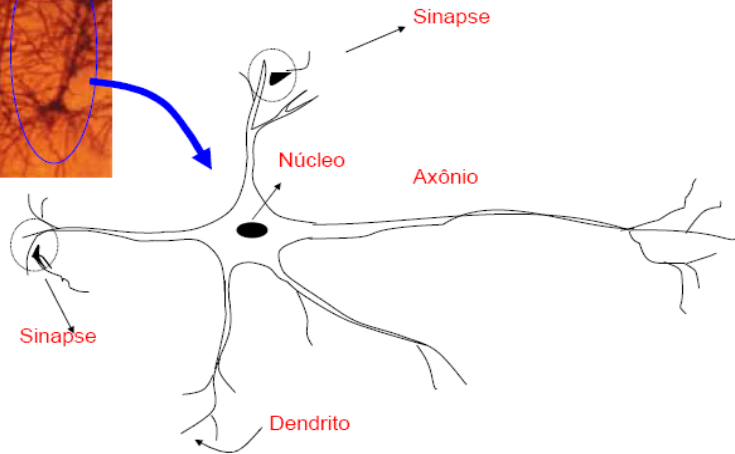
- Experiência - *adquirida com os anos.*

Desenvolvimentos mais marcantes (por exemplo, a escrita) acontecem nos primeiros 2 anos de vida - milhões de conexões sinapses são formadas por segundo - (processo contínuo).

MOTIVAÇÃO

Motivação Rede Neural Artificial: cérebro

Componentes de um Neurônio



MOTIVAÇÃO

Componentes de um Neurônio

❖ Axônio:

- ❑ transmissão de sinais a partir do corpo celular;
- ❑ poucas ramificações e compridos.

❖ Dendritos:

- ❑ conduzem sinais para a célula;
- ❑ têm muitas ramificações (zonas receptoras)

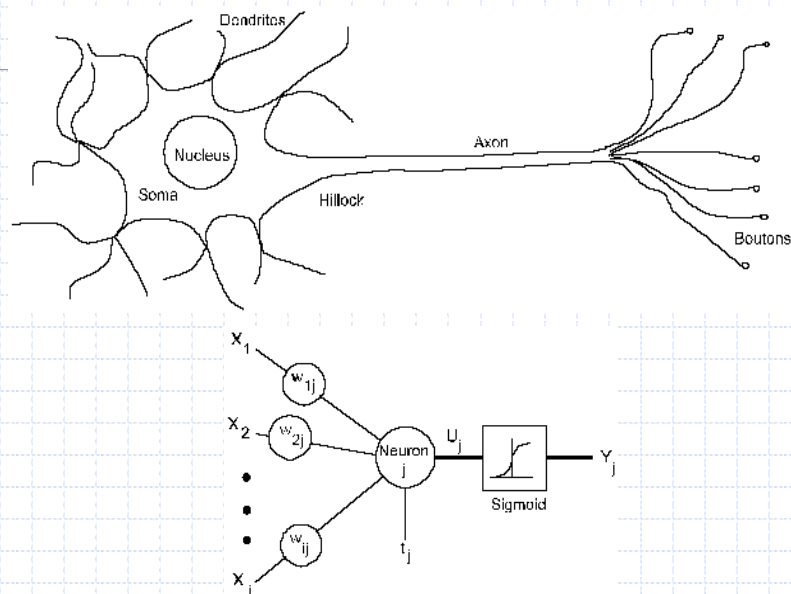
❖ Sinapses:

- ❑ Unidades estruturais e funcionais elementares que medeiam as conexões entre os neurônios.
- ❑ Tipos de Sinapses: Excitação ou Inibição

MOTIVAÇÃO

- ❖ **Plasticidade de um neurônio** - capacidade de adaptação ao ambiente.
- ❖ **Mecanismos de plasticidade** (cérebro de um adulto):
 - ❑ Criação de novas conexões sinápticas
 - ❑ Modificação das sinapses existentes
- ❖ A plasticidade é essencial para as **Redes Neurais Artificiais (RNA)**.

MOTIVAÇÃO



MOTIVAÇÃO

Observação:

- O cérebro tem 10 bilhões neurônios;
- cada neurônio tem 1000 - 10000 conexões;
- 10^{14} sinápses
- Cada pessoa pode dedicar 100000 conexões para armazenar cada segundo de experiência (65 anos ==> 2,000,000,000 segundos)

DEFINIÇÃO

Redes Neurais Artificiais (RNA) são sistemas inspirados nos neurônios biológicos e na estrutura massivamente paralela do cérebro, com capacidade de adquirir, armazenar e utilizar conhecimento experimental.

DEFINIÇÃO

❖ *Processador paralelo distribuído com capacidade natural para armazenar conhecimento experimental para uso posterior.*

❖ Imita o cérebro de duas formas:

- Adquire de conhecimento através de aprendizagem.
- Armazena conhecimento nas conexões inter neurônios (**pesos**).

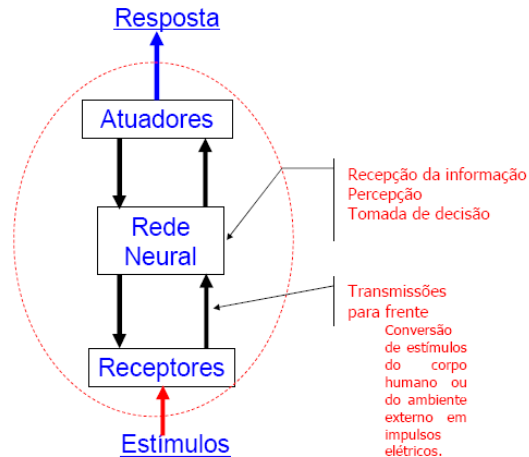
DEFINIÇÃO

❖ Aprendizagem: **Algoritmo modifica os pesos da rede de uma forma ordenada para adquirir uma arquitetura previamente desejada.**

- Também pode modificar a própria **topologia**.

DEFINIÇÃO

Representação em blocos do sistema nervoso (3 estágios)



IDÉIA BÁSICA

Sistemas compostos de diversas unidades simples (neurônios artificiais) ligadas de maneira apropriada, podem gerar comportamento interessante e complexo



Comportamento é determinado pela estrutura dos neurônios, estrutura das ligações (topologia da rede) e pelos valores das conexões (pesos sinápticos)

APLICAÇÕES GERAIS

Associação de Padrões

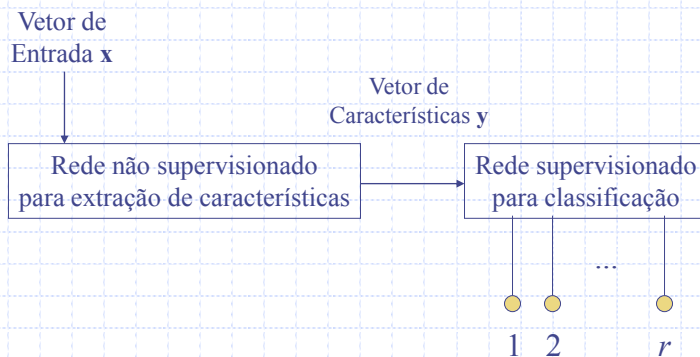
- Uma *memória associativa* é uma memória distribuída inspirada no cérebro, que aprende por associação;
- Associação assume duas formas: *auto-associação* ou *hetero-associação*;
- Duas fases na operação: *armazenamento* e *recordação*



Auto-associativa: $A' \rightarrow A$ Hetero-associativa: $A \rightarrow B$

APLICAÇÕES GERAIS

Reconhecimento de Padrões



APLICAÇÕES GERAIS

Aproximação de Funções

$$\mathbf{d} = f(\mathbf{x})$$
$$\mathcal{S} = \{ \mathbf{x}_i, \mathbf{d}_i \}_{i=1}^M$$

$$\|F(\mathbf{x}) - f(\mathbf{x})\| \leq \epsilon \quad \text{para todos } \mathbf{x}$$

\mathbf{x} : entrada da rede;

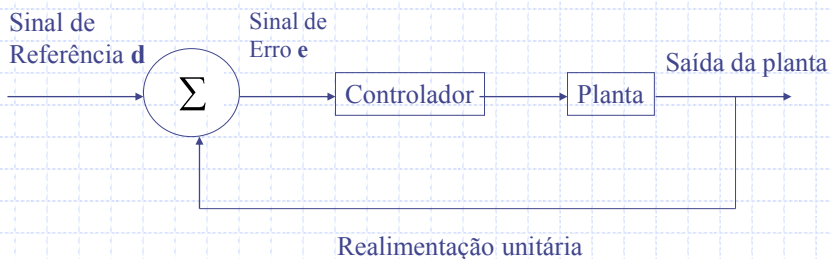
\mathbf{d} : saída desejada

f : função desconhecida;

F : função encontrada pela aprendizagem da rede

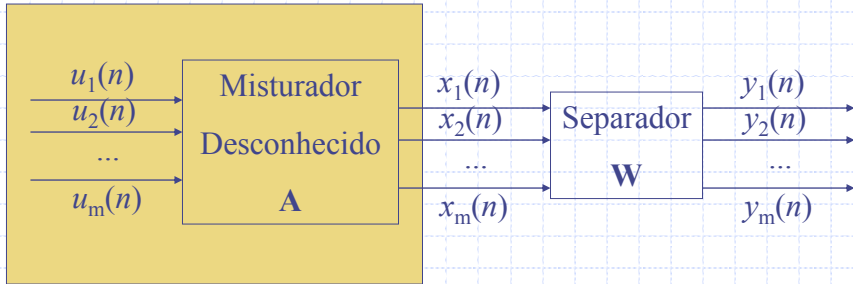
APLICAÇÕES GERAIS

Controle



APLICAÇÕES GERAIS

Filtragem

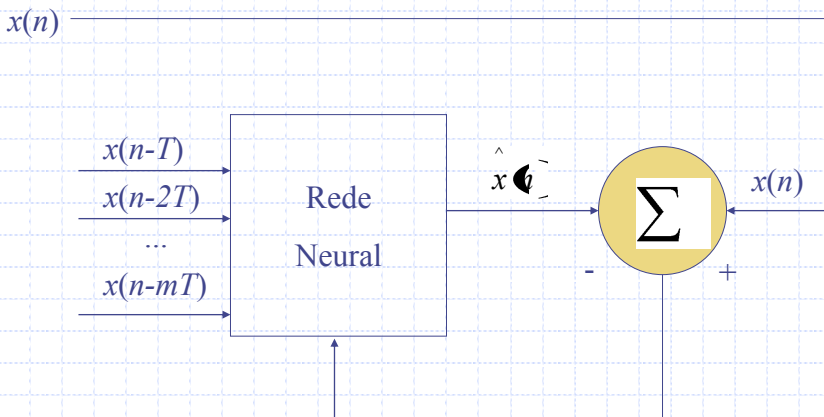


Ambiente desconhecido

Problema da festa de coquetel

APLICAÇÕES GERAIS

Previsão não linear



CARACTERÍSTICAS BÁSICAS

Devido à similaridade com a estrutura do cérebro, as Redes Neurais exibem características similares ao do comportamento humano, tais como:

- Procura paralela e Endereçamento pelo Conteúdo

O cérebro não possui endereço da memória e não procura a informação seqüencialmente.

CARACTERÍSTICAS BÁSICAS

- Aprendizado

A rede aprende por experiência, não necessitando explicitar os algoritmos para executar uma determinada tarefa

- Associação

A rede é capaz de fazer associações entre padrões diferentes

Ex. Cidade - Pessoa, Perfume - Pessoa, Pessoa - Nome

CARACTERÍSTICAS BÁSICAS

- Generalização

Redes neurais são capazes de generalizar seu conhecimento a partir de exemplos anteriores



Habilidade de lidar com ruídos e distorções, respondendo corretamente a padrões novos

CARACTERÍSTICAS BÁSICAS

- Robustez de Degradação Gradual

A perda de um conjunto de elementos processadores e/ou conexões sinápticas não causa o mau funcionamento da rede neural.

Histórico

- ❖ **1911: Ramón y Cajál** – introduz a idéia do neurônio como elementos estruturante básico do cérebro.
- ❖ **1943 : McCulloch e Pitts** - "A Logical Calculus of the Ideas Immanent in Nervous Activity." Bulletin of Mathematical Biophysics, 1943, 5:115-133.
- ❖ **1949 : Donald Hebb** - Postulado para aprendizagem (Regra de Hebb)
- ❖ **1958 : Frank Rosenblatt** - *Perceptron* - classificador de padrões separáveis linearmente

Histórico

- ❖ **1969 : Minsky e Papert** - "Perceptron: na introduction to computational geometry". MIT Press, Massachusetts, 1969. - Perceptron não resolvem problemas não-lineares.
- ❖ **Anos 70** - poucas pesquisas (**Fukushima, Grossber, Kohonen, Paul Werbos**)
- ❖ **1982 : John Hopfield** - Paper enfatizando as propriedades associativas das RNA - Reiniciaram as pesquisas - relação entre redes recorrentes e sistemas físicos
- ❖ **1986 : D.E. Rumelhart, G.E. Hinton e R.J. Williams,** "Learning representations by *back-propagating errors*", *Nature*, 323:533-536, 1986.
==> Retomada pelas pesquisas!

Histórico

Atualmente

- ❖ Aplicações Comerciais
- ❖ Neural Chips
- ❖ RNA biologicamente plausíveis – ligação com neurociência

Principais Revistas e Congressos

Journal:


- ❖ IEEE Transactions on Neural Networks
- ❖ Neural Networks
- ❖ Neural Computation
- ❖ Neurocomputing

Congressos:

- International Joint Conference on Neural Networks (IJCNN)
- International Symposium on Neural Networks (ISNN)
- Brazilian Symposium on Neural Networks (SBRN)

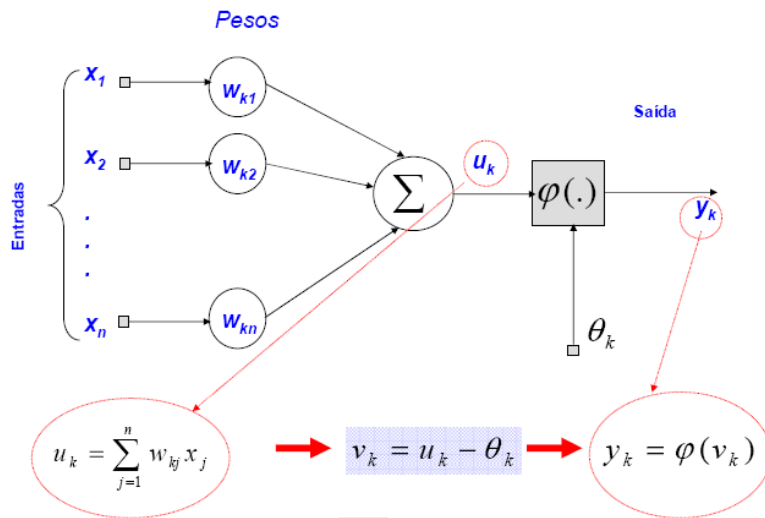
NEURÔNIO ARTIFICIAL

Inspiração Biológica



NEURÔNIO ARTIFICIAL

Modelo de Neurônio Artificial (McCulloch e Pitts, 1943)



NEURÔNIO ARTIFICIAL

Estrutura Básica de um Neurônio Artificial

- Estado de Ativação (Saída): y_k
- Conexões entre Processadores: w_{kj}
 - a cada conexão existe um peso sináptico que determina o efeito da entrada sobre o processador

NEURÔNIO ARTIFICIAL


Estrutura Básica de um Neurônio Artificial

- Soma: $u_k = \sum_j w_{kj} x_j$
 - cada processador soma os sinais de entrada baseado peso sináptico das conexões
- Função de Ativação: $y_k = \varphi(u_k)$
 - determina o novo valor do Estado de Ativação do processador.

NEURÔNIO ARTIFICIAL


Exemplos de função de Transferência - $y = \varphi(v)$

Função Limiar



$$y = \begin{cases} 1, & v \geq 0 \\ 0, & v < 0 \end{cases}$$

Função Sinal




$$y = \begin{cases} +1, & v \geq 0 \\ -1, & v < 0 \end{cases}$$

NEURÔNIO ARTIFICIAL


Exemplos de função de Transferência - $y = \varphi(v)$

Função Rampa



$$y = \begin{cases} 0, & v < 0 \\ v, & 0 \leq v < 1 \\ 1, & v \geq 1 \end{cases}$$


Função Linear




$$y = v$$

NEURÔNIO ARTIFICIAL

Exemplos de função de Transferência - $y = \varphi(v)$



$$y = \frac{1}{(1 + e^{-av})}$$



$$y = \frac{1 - e^{-av}}{(1 + e^{-av})}$$

TOPOLOGIA DA REDE

Redes Feed-Forward

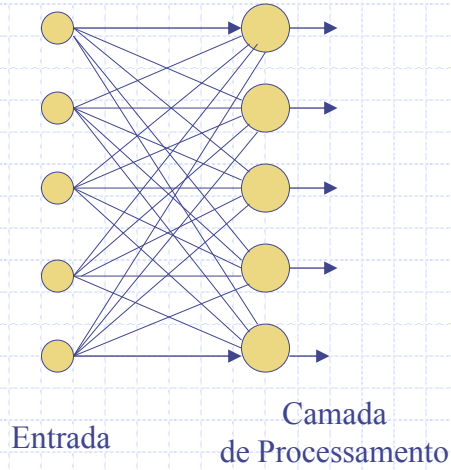
- Rede de uma ou mais camadas de processadores, cujo fluxo de dados é sempre em uma única direção, isto é, não existe realimentação.

Redes Recorrentes

- Redes com conexões entre processadores da mesma camada e/ou com processadores das camadas anteriores (realimentação)


TOPOLOGIA DA REDE

Redes de uma Camada




Redes de Multiplas Camadas

Rede de 3 camadas 5/5/3/4



TOPOLOGIA DA REDE

Rede Recorrente



Why use neural networks?

Neural networks, with their remarkable ability to derive meaning from complicated or imprecise data, can be used to extract patterns and detect trends that are too complex to be noticed by either humans or other computer techniques. A trained neural network can be thought of as an "expert" in the category of information it has been given to analyze. This expert can then be used to provide projections given new situations of interest and answer "what if" questions.

Why use neural networks?

Other advantages include:

Adaptive learning: An ability to learn how to do tasks based on the data given for training or initial experience.

Self-Organisation: An ANN can create its own organisation or representation of the information it receives during learning time.

Real Time Operation: ANN computations may be carried out in parallel, and special hardware devices are being designed and manufactured which take advantage of this capability.

Fault Tolerance via Redundant Information Coding: Partial destruction of a network leads to the corresponding degradation of performance. However, some network capabilities may be retained even with major network damage.

Neural networks versus conventional computers

Neural networks take a different approach to problem solving than that of conventional computers. Conventional computers use an algorithmic approach i.e. the computer follows a set of instructions in order to solve a problem. Unless the specific steps that the computer needs to follow are known the computer cannot solve the problem. That restricts the problem solving capability of conventional computers to problems that we already understand and know how to solve. But computers would be so much more useful if they could do things that we don't exactly know how to do.

Neural networks versus conventional computers

Neural networks process information in a similar way the human brain does. The network is composed of a large number of highly interconnected processing elements (neurones) working in parallel to solve a specific problem. Neural networks learn by example. They cannot be programmed to perform a specific task. The examples must be selected carefully otherwise useful time is wasted or even worse the network might be functioning incorrectly. The disadvantage is that because the network finds out how to solve the problem by itself, its operation can be unpredictable.

Neural networks versus conventional computers

On the other hand, conventional computers use a cognitive approach to problem solving; the way the problem is to solved must be known and stated in small unambiguous instructions. These instructions are then converted to a high level language program and then into machine code that the computer can understand. These machines are totally predictable; if anything goes wrong is due to a software or hardware fault.

Neural networks versus conventional computers

Neural networks and conventional algorithmic computers are not in competition but complement each other. There are tasks more suited to an algorithmic approach like arithmetic operations and tasks that are more suited to neural networks. Even more, a large number of tasks, require systems that use a combination of the two approaches (normally a conventional computer is used to supervise the neural network) in order to perform at maximum efficiency.