



# Sistemas Inteligentes

## UNIDADE 2 – Redes Neurais Artificiais (Introdução às RNA's)

Prof. Ivan Nunes da Silva



### 1. *Sistemas Inteligentes*

*O que são e qual sua constituição?*

- Conjunto de ferramentas computacionais que tentam **simular** alguns **mecanismos inteligentes** encontrados na natureza (seres humanos).
- É Constituído por 5 grandes áreas:
  - Redes Neurais Artificiais.
  - Sistemas de Inferência Nebulosos.
  - Computação Evolutiva (Alg. Genéticos).
  - Inteligência Coletiva (*Swarm*).
  - Agentes Autônomos.
  - + **Áreas Emergentes (Sistemas Imunológicos, Vida Artificial, Neurociências, etc.).**



## 2. Redes Neurais Artificiais (RNA)

*Definição do ponto de vista de engenharia*

- São modelos computacionais inspirados nos **mecanismos de aprendizagem** do cérebro humano.
- São modelos computacionais que tentam **emular a forma** com que o cérebro **resolve problemas**.



3

## 2. Redes Neurais Artificiais (RNA)

*Principais características das RNA (I)*

- **Adaptação por Experiência**  
Parâmetros internos da rede são ajustados a partir da apresentação sucessiva de exemplos (amostras e medidas).
- **Capacidade de Aprendizado**  
Aplicação de método de treinamento possibilita a rede extrair o relacionamento existente entre variáveis que compõem a aplicação.
- **Habilidade de Generalização**  
Após o treinamento, a rede é capaz de generalizar o conhecimento adquirido, possibilitando estimação de soluções que eram desconhecidas.
- **Tolerância a Falhas**  
Devido ao elevado nível de interconexões entre neurônios artificiais, a rede torna-se um sistema tolerante a falhas quando parte de sua estrutura interna for sensivelmente corrompida.
- **Armazenamento Distribuído**  
O conhecimento dentro da rede é realizado de forma distribuída entre as sinapses dos neurônios artificiais, permitindo-se então robustez frente a eventuais neurônios que se tornaram inoperantes.
- **Facilidade de Prototipagem**  
A implementação da maioria das arquiteturas neurais pode ser facilmente prototipadas em hardware ou em software.

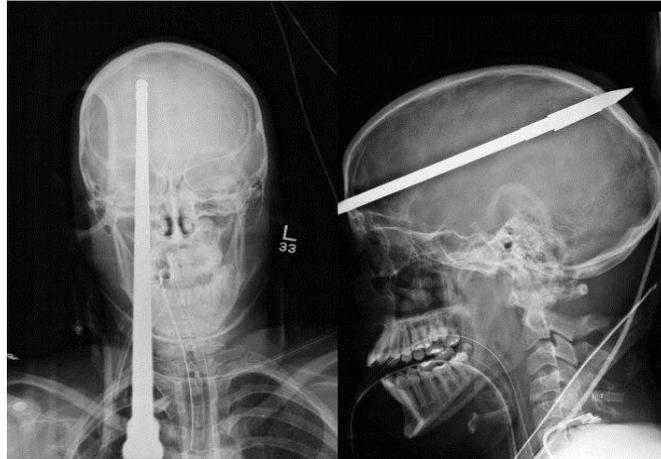


4

## 2. Redes Neurais Artificiais (RNA)

### Principais características das RNA (II)

#### Exemplo: Tolerância a Falhas & Armazenamento Distribuído



5

## 3. Potenciais Aplicações de RNA

### Aproximador de Funções & Controle de Processos

#### ● Aproximador de Funções

Mapeiam o relacionamento entre variáveis de um sistema a partir de um conjunto conhecido de seus valores representativos.

Envolvem normalmente o mapeamento de processos cuja modelagem por técnicas convencionais são de difícil obtenção.

Necessitam de domínio específico para variáveis de entrada.

**Exemplo de aplicações:** resolução de diversos tipos de problemas (em diferentes áreas do conhecimento).

#### ● Controle de Processos

Consistem em identificar ações de controle que permitam o alcance dos requisitos de qualidade, de eficiência e de segurança do processo.

**Exemplo de aplicações:** controles empregados em robótica, aeronaves, elevadores, eletrodomésticos, satélites, etc.

6

### 3. Potenciais Aplicações de RNA

#### Classificação de Padrões & Agrupamento de Dados

- **Classificação de Padrões**

O objetivo desta aplicação consiste de associar um padrão de entrada (amostra) para uma das classes previamente definidas.

O problema a ser tratado possui um conjunto discreto e conhecido das possíveis saídas desejadas.

**Exemplos de aplicações:** reconhecimento de imagens, voz, escrita, etc.

- **Sistemas de Previsão**

O objetivo consiste em estimar valores futuros de um processo levando-se em consideração diversas medidas prévias observadas em seu domínio.

**Exemplos de aplicações:** previsão de demanda de energia, previsões de mercados financeiros, previsões climáticas, séries temporais, etc.

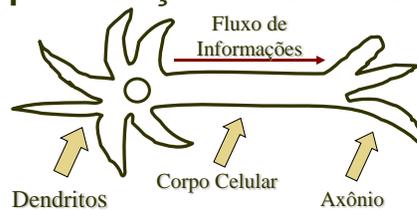


7

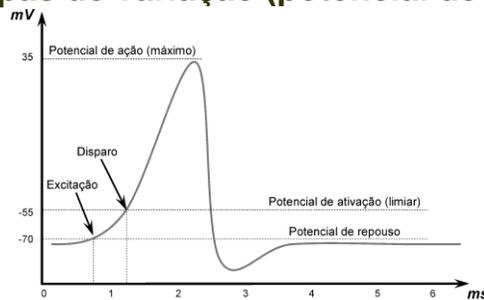
### 4. Neurônio Biológico

#### Características da célula nervosa

- **Representação do neurônio biológico:**



- **Etapas de variação (potencial de ação):**

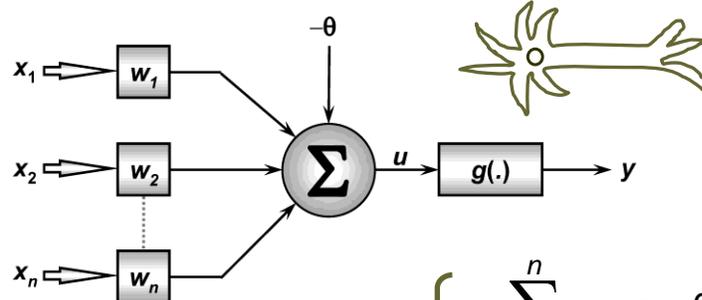


8

## 5. Neurônio Artificial

### Representação do neurônio artificial

#### ● Modelo matemático do neurônio artificial:



- Sinais de entrada  $\rightarrow \{x_1, x_2, \dots, x_n\}$
- Pesos sinápticos  $\rightarrow \{w_1, w_2, \dots, w_n\}$
- Combinador linear  $\rightarrow \{\Sigma\}$
- Limiar de ativação  $\rightarrow \{\theta\}$
- Potencial de ativação  $\rightarrow \{u\}$
- Função de ativação  $\rightarrow \{g\}$
- Sinal de saída  $\rightarrow \{y\}$

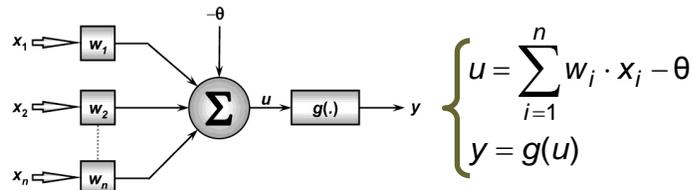
$$\begin{cases} u = \sum_{i=1}^n w_i \cdot x_i - \theta \\ y = g(u) \end{cases}$$

9

## 5. Neurônio Artificial

### Resumo do funcionamento do neurônio artificial

#### ● Passos para obtenção da resposta (saída):



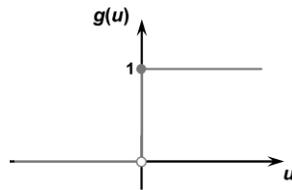
- i. Apresentação de um conjunto de valores que representam as variáveis de entrada do neurônio.
- ii. Multiplicação de cada entrada do neurônio pelo seu respectivo peso sináptico.
- iii. Obtenção do potencial de ativação produzido pela soma ponderada dos sinais de entrada, subtraindo-se o limiar de ativação.
- iv. Aplicação de uma função de ativação apropriada, tendo-se como objetivo limitar a saída do neurônio.
- v. Compilação da saída a partir da aplicação da função de ativação neural em relação ao seu potencial de ativação.

10

## 6. Funções de Ativação Neural

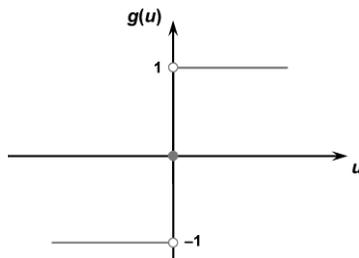
### Funções parcialmente diferenciáveis (I)

- Função Degrau (Heavyside):



$$g(u) = \begin{cases} 1, & \text{se } u \geq 0 \\ 0, & \text{se } u < 0 \end{cases}$$

- Função Degrau Bipolar (Sinal):



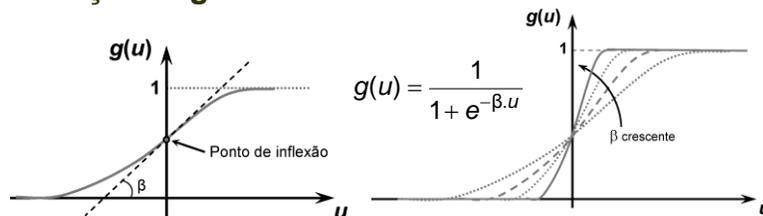
$$g(u) = \begin{cases} 1, & \text{se } u \geq 0 \\ -1, & \text{se } u < 0 \end{cases}$$

11

## 6. Funções de Ativação Neural

### Funções totalmente diferenciáveis (I)

- Função Logística:



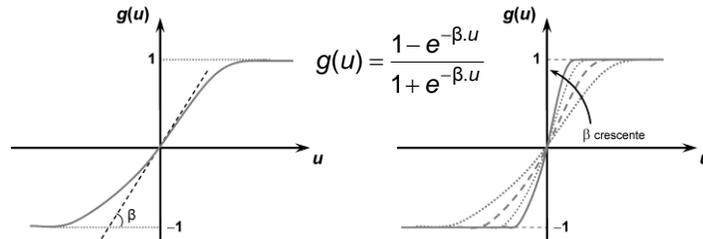
- Parâmetro  $\beta$  é uma constante real relacionada à inclinação da função logística frente ao seu ponto de inflexão.
- Resultado de saída assumirá sempre valores reais entre zero e um.
- Formato geométrico tende a ser similar àquele da função degrau quando  $\beta$  for muito elevado (tender ao infinito).

12

## 6. Funções de Ativação Neural

### Funções totalmente diferenciáveis (II)

#### ● Função Tangente Hiperbólica:



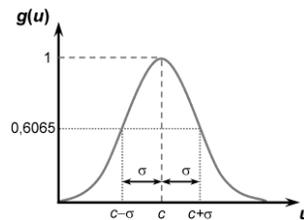
- Parâmetro  $\beta$  está também relacionado à inclinação da função logística frente ao ponto de inflexão.
- Resultado de saída assumirá sempre valores reais entre -1 e 1.
- Formato geométrico tende a ser similar àquele da função degrau bipolar quando  $\beta$  for muito elevado (tender ao infinito).

13

## 6. Funções de Ativação Neural

### Funções totalmente diferenciáveis (III)

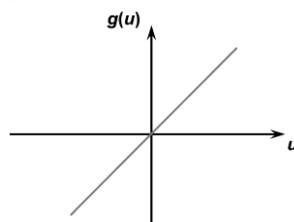
#### ● Função Gaussiana:



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

- Parâmetro  $c$  define o centro (média) da função.
- Parâmetro  $\sigma^2$  especifica a variância (espalhamento).

#### ● Função Linear (Identidade):



$$g(u) = u$$

- Produz resultados idênticos aos valores do potencial de ativação  $\{u\}$ .

14

## 7. Arquiteturas de RNA's

### Arquitetura, Topologia e Treinamento

- **Arquitetura de Redes Neurais:**

Define a forma como os seus diversos neurônios estão arranjados, ou dispostos, uns em relação aos outros.

Os arranjos são essencialmente estruturados através do direcionamento do fluxo sináptico.

- **Topologia de Redes Neurais:**

Define as diferentes formas de composições estruturais que uma rede poderá assumir, frente a uma determinada arquitetura.

**Exemplo:** dada uma determinada arquitetura, uma das redes pode ser composta de 10 neurônios e a outra de 20 neurônios.

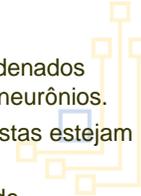
- **Processo de Treinamento:**

Consiste da aplicação de um conjunto de passos ordenados com o intuito de ajustar os pesos e os limiares de seus neurônios.

Visa então sintonizar a rede para que as suas respostas estejam próximas dos valores desejados.

Exprime o próprio algoritmo de aprendizagem da rede.

15



## 7. Arquiteturas de RNA's

### Estruturação de camadas

- **Camada de Entrada:**

Responsável pelo recebimento de informações (dados), sinais, características ou medições advindas do meio externo.

Valores recebidos são geralmente normalizados em relação aos valores limites produzidos pelas funções de ativação.

Esta normalização implica numa melhor precisão numérica frente às operações matemáticas realizadas pela rede.

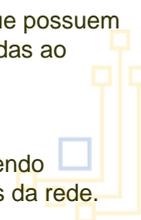
- **Camadas Escondidas, Intermediárias, Ocultas ou Invisíveis:**

São aquelas camadas compostas de neurônios e que possuem a responsabilidade de extrair as características associadas ao processo ou sistema a ser inferido.

- **Camada de Saída:**

Esta camada é também constituída de neurônios, sendo responsável por produzir/apresentar os resultados finais da rede.

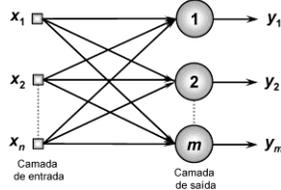
16



## 7. Arquiteturas de RNA's

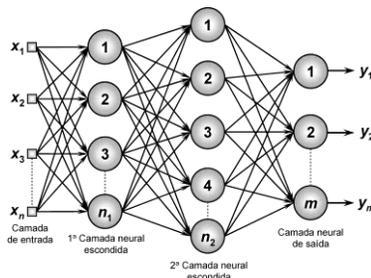
### Arquiteturas FeedForward (Alimentação à frente)

#### ● Camada Simples:



- ❖ Constituída de uma camada de entrada e única camada de neurônios, que é a própria camada de saída.
- ❖ Fluxo de informações segue sempre numa única direção (unidirecional).
- ❖ **Exemplos de arquiteturas:** Perceptron, ADALINE.
- ❖ **Aplicações:** classificação de padrões, filtragem linear.

#### ● Camadas Múltiplas:



- ❖ Presença de uma ou mais camadas neurais escondidas.
- ❖ Quantidade de camadas escondidas e de neurônios dependem, sobretudo, do tipo e complexidade do problema.
- ❖ **Exemplos de arquiteturas:** Perceptron multicamadas, redes de base radial (RBF).
- ❖ **Aplicações:** aproximação de funções, classificação de padrões, controle de processos, otimização, etc.

17

## 8. Processos de Treinamento

### Aspectos de conjunto de treinamento/teste

#### ● Finalidade do Treinamento:

Consiste da aplicação de passos ordenados a fim de ajustar (sintonizar) os parâmetros livres (pesos sinápticos e limiares) dos neurônios.

Após treinamento, a rede está apta para generalizar soluções (as quais não eram conhecidas).

#### ● Conjuntos de Treinamento e Teste:

❖ **Conjunto Total de Amostras** → Representa todos os dados disponíveis sobre o comportamento do processo a ser mapeado. Será dividido em subconjuntos de treinamento e de teste.

❖ **Subconjunto de Treinamento** → Usado essencialmente para o processo de aprendizado da rede. Composto aleatoriamente com cerca de 60 a 90% das amostras do conjunto total.

❖ **Subconjunto de Teste** → Usado p/ verificar se a generalização de soluções por parte da rede já estão em patamares aceitáveis. Composto de 10 a 40% das amostras do conjunto total.

➢ Estes dados não participam do treinamento da rede.

18

## 8. Processos de Treinamento

### Aspectos do treinamento supervisionado

#### ● Treinamento Supervisionado:

Consiste em se ter disponível, considerando cada amostra dos sinais de entrada, as respectivas saídas desejadas.

Cada amostra de treinamento é então composta pelos sinais de entradas e suas correspondentes saídas.

Comporta como se houvesse um “professor” ensinando para a rede qual seria a resposta correta para cada amostra apresentada.

#### ● Passos do Treinamento Supervisionado:

1. Apresente uma amostra de treinamento.
2. Calcule a saída produzida pela rede.
3. Compare com a saída desejada.
4. Se estiver dentro de valores aceitáveis:

Então → Termine o processo de aprendizado.

Senão → Ajuste os pesos sinápticos e limiares dos neurônio e volte ao passo 1.



19

## Fim da Apresentação



20