

I WorkShop de Inteligência Artificial - UNISC

Sistemas Inteligentes baseados em Redes Neurais Artificiais aplicados ao Processamento de Imagens

*Coordenador do Projeto:
Prof. Dr. Fernando Osório*

*Bolsista CNPq :
João Ricardo Bittencourt*

*UNISC - Santa Cruz do Sul
Junho de 2000*



UNISINOS - Centro de Ciências Exatas e Tecnológicas (C6/6)
Curso de Informática - Mestrado em Computação Aplicada
E-mail: osorio@exatas.unisinos.br
Web: <http://www.inf.unisinos.br/~osorio/>



Tópicos abordados

1. Introdução & Conceitos Básicos

- 1.1. Projeto HMLT
- 1.1. Inteligência: Humana e Artificial
- 1.2. Aprendizado de máquinas


2. Redes Neurais Artificiais - RNAs

- 2.1. Conceitos Básicos
- 2.2. Representação de Conhecimentos
- 2.3. Modelos de RNAs
- 2.4. Aprendizado Neural
- 2.5. Discussão: vantagens / desvantagens

3. Processamento de Imagens

- 3.1. Conceitos e Aplicações
 - 3.1.1. Tratamento de Imagens
 - 3.1.2. Reconhecimento de Padrões
- 3.2. Processamento de Imagens *Convencional*
- 3.3. Processamento de Imagens *Neural*
- 3.4. Exemplos de Aplicações: OCR, Filtros, etc.

6. Conclusões e Perspectivas




Introdução: Contexto da Pesquisa

Inteligência Humana ⇒ Inteligência Artificial

Aprendizado Humano ⇒ Aprendizado de Máquinas

Métodos de Raciocínio e Aquisição de Conhecimentos Múltiplos ⇒ Sistemas Híbridos



Introdução

Inteligência Humana ⇒ Inteligência Artificial

Aprendizado Humano ⇒ Aprendizado de Máquinas

Métodos de Raciocínio e Aquisição de Conhecimentos Múltiplos ⇒ Sistemas Híbridos

Sistemas Inteligentes Híbridos

Projeto de Pesquisa HMLT - *Hybrid Machine Learning Tools*
“Ferramentas Híbridas de Aprendizado para o Máquinas”

Coordenador Prof. Fernando Osório

Bolsistas de Iniciação Científica..... Carla Medeiros Barros
João Ricardo de Bittencourt Menezes
Rafael Guterres Jeffman

Mestrando..... Farlei Heinen

Cooperação: Laboratoire LEIBNIZ - Grenoble, França e LRI/UFRGS




INTELIGÊNCIA: Humana e Artificial



REPRODUZIR A
→
INTELIGÊNCIA HUMANA



- O que é Inteligência ?
- O que é um ser Inteligente ?



INTELIGÊNCIA: Humano e Artificial



REPRODUZIR A
→
INTELIGÊNCIA HUMANA



- O que é Inteligência ?
- O que é um ser Inteligente ?

- * Associação de idéias e conceitos
- * Concluir coisas
- * Capacidade de aprendizado
- * Acúmulo de conhecimentos
- * Raciocínio: lógico, abstrato, dedução, analogia, indução, inferência, síntese, análise

- * Uso prático de experiências e conhecimentos passados
- * Tomada de decisões
- * Criar coisas novas (criatividade)
- * Saber o que eu sei (saber explicar)
- * Interação
- * Comunicação



Inteligência Artificial: Conceitos Básicos



REPRODUZIR A
INTELIGÊNCIA HUMANA



- Conceito de Inteligência: CAPACIDADE DE **RESOLVER PROBLEMAS**
CAPACIDADE DE **APRENDER**
CAPACIDADE DE **SE ADAPTAR / MELHORAR**
- Realizar Atividades Inteligentes
- Sistemas Inteligentes:
 - * Sistemas Especialistas
 - * Sistemas de Apoio ao Diagnóstico e a Decisão
 - * Reprodução de atividades típicas dos seres humanos:
Fala, Audição, Visão, Deslocamento, Manipulação de Objetos, etc.
 - * Jogos: jogo da velha, xadrez, jogos de ação



Inteligência Artificial: Conceitos Básicos



REPRODUZIR A
INTELIGÊNCIA HUMANA



- Sistemas Inteligentes: CAPACIDADE DE **RESOLVER PROBLEMAS**
CAPACIDADE DE **APRENDER**
CAPACIDADE DE **SE ADAPTAR / MELHORAR**

⇒ **Grandes Desafios:**

- Linguagem / PLN
- Visão Artificial
- Robótica Autônoma

« *Sentidos Humanos* »

* **Problema escolhido:**

Processamento de Imagens

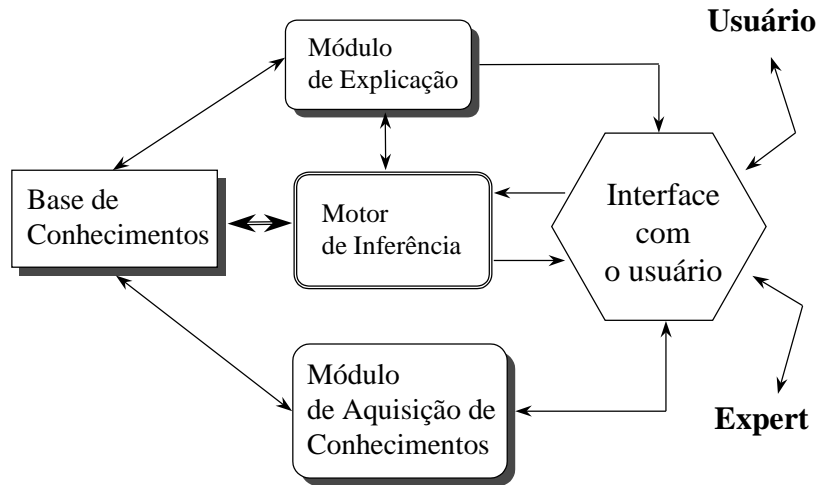
* **Ferramentas Usadas:**

Redes Neurais & Sistemas Híbridos



Inteligência Artificial: Adquirindo e usando conhecimentos

Sistemas Especialistas



Sistema Especialista: Exemplo Básico e Introdutório:

Sistema de auxílio ao diagnóstico de pacientes

Médico: 8 perguntas sobre os sintomas do paciente (resposta: 'S'/'N')

Sintomas: 1 = Dor de Cabeça, 2 = Febre, 3 = Problemas digestivos, ...

Base de Conhecimentos do Médico

1	2	3	4	5	6	7	8	Diagnóstico
S	S	N	S	N	S	S	S	Gripe
S	N	S	S	S	N	N	S	Sem problemas
S	N	S	N	S	N	S	N	Morte certa
S	N	N	S	S	N	S	N	Morte certa

Criar uma árvore binária de decisão baseada na tabela de conhecimentos

Consultas ao sistema:

S,N,S,N,S,N,S,N => Diagnóstico ?

S,N,?,?,S,N,S,N => Diagnóstico ?

Inteligência Artificial: Sistemas Especialistas

Diagnóstico: Substância tóxica ingerida

	<i>Abreviações</i>	<i>Substância Tóxica</i>	<i>Ocorrência</i>
1	adt, a	Anti-depressores tri-cíclicos	265
2	B	Barbitúricos	86
3	ben, b	Benzodiazepina	414
4	C	Carbamato	68
5	P	Fenotiazina	130
6	M	Morfina	13
7	E	Alcool	137

Combinações

a (25), aBb (12), aBbp (9), ab (104), abc (11), abm (5), abp (38), ap (5), B (8), Bb (23), Bbcp (5), Bcp (13), ben (37), bc (24), bm (8), bp (31), c (5), p (5), Ea (12), Eab (36), Eabp (8), E (12), EB (6), Ebb (5), EBbp (5), Eb (32), Ebc (10), Ebp (11)

Tabela - Os diferentes tipos de substâncias tóxicas da base de dados

13

Inteligência Artificial: Aprendizado de Máquinas

* Sistemas Especialistas de 1a. Geração:

- Aquisição manual de conhecimentos
- Problemas: Base de Conhecimentos (regras e fatos)

* Sistemas Especialistas de 2a. Geração:

- Aquisição automática de conhecimentos
- Integração de diferentes métodos da I.A.

“Sistemas Híbridos”

14

Inteligência Artificial: Aprendizado de Máquinas

Inteligência Artificial

Sistemas Inteligentes

Aprendizado de Máquinas

Representação de Conhecimentos

Sistemas Especialistas
KBS, robótica,
visão artificial, ...

CBR, ILP, indução de árvores
de decisão, **redes neurais**
algoritmos genéticos, ...

Métodos Simbólicos
Métodos baseados em:
Redes Neurais Artificiais
Regras Fuzzy
Regras Bayesianas (probab.)

15

Inteligência Artificial: Aprendizado de Máquinas

- O que é o aprendizado?

- * Adaptação do comportamento (melhoria)
- * Correção dos erros cometidos no passado
- * Otimização da performance do sistema (melhoria)
- * Interação com o meio, experimentação e descoberta
- * Representação do conhecimento adquirido
Memória e compressão dos conhecimentos

16

Aprendizado de Máquinas / Machine Learning

⇒ Conhecimentos Teóricos / Simbólicos

$$\text{XOR} = (A \text{ Or } B) \text{ And Not } (A \text{ And } B)$$

ou

$$\text{XOR} = (A \text{ And Not } (B)) \text{ Or } (\text{Not } (A) \text{ And } B)$$

⇒ Conhecimentos Empíricos / Dados

A	B	XOR
0	0	0
0	1	1
1	0	1
1	1	0

17

Aprendizado de Máquinas / Machine Learning

⇒ Conhecimentos Teóricos / Simbólicos

Se existem 2 casas na horizontal, vertical ou diagonal
com uma marca do jogador oponente
e a terceira casa está livre
Então jogar nesta casa!

⇒ Conhecimentos Empíricos / Dados

X ₂		X
O ₁	O ₃	X ₄
O ₅		


18

Métodos de Aprendizado de Máquinas

- Aprendizado por analogia / por instâncias
Sistemas baseados em casos
CBR - *Case Based Reasoning*
- Aprendizado por Indução
Indução de Árvores de Decisão
ID3, C4.5, CN2 - *Induction of Decision Trees*
ILP - *Inductive Logic Programming (Prolog)*
- Aprendizado por evolução/seleção
Algoritmos Genéticos
GA e GP - *Genetic Algorithms / Genetic Programming*
- Aprendizado por reforço (*reinforcement learning*)
- Aprendizado Bayesiano (probabilista)
- Aprendizado Neural
MLP Back-Propagation - *Artificial Neural Networks*

19

Redes Neurais Artificiais: Aprendizado de Máquinas



Redes Neurais Artificiais:

Neurônio...
Modelo Simulado
Modelo SIMPLIFICADO

Características Básicas:

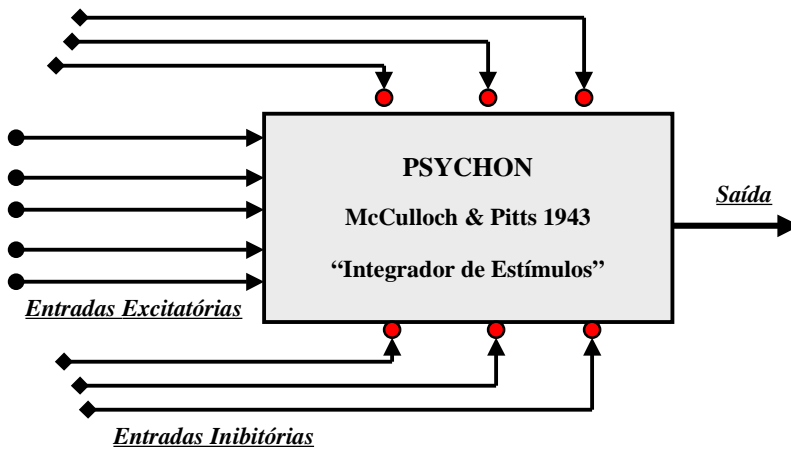
Adaptação
Aprendizado
Autômato

Representação de Conhecimentos:

Baseada em *Conexões*

20

Redes Neurais Artificiais: Origem



21

X_1 X_2 X_N ← Entradas (Dendritos)

Perceptron


NEURAL

W_1 W_2 ... W_N ← Pesos Sinápticos (Efeito de inibição ou de excitação sobre a ativação dos sinais de entrada)

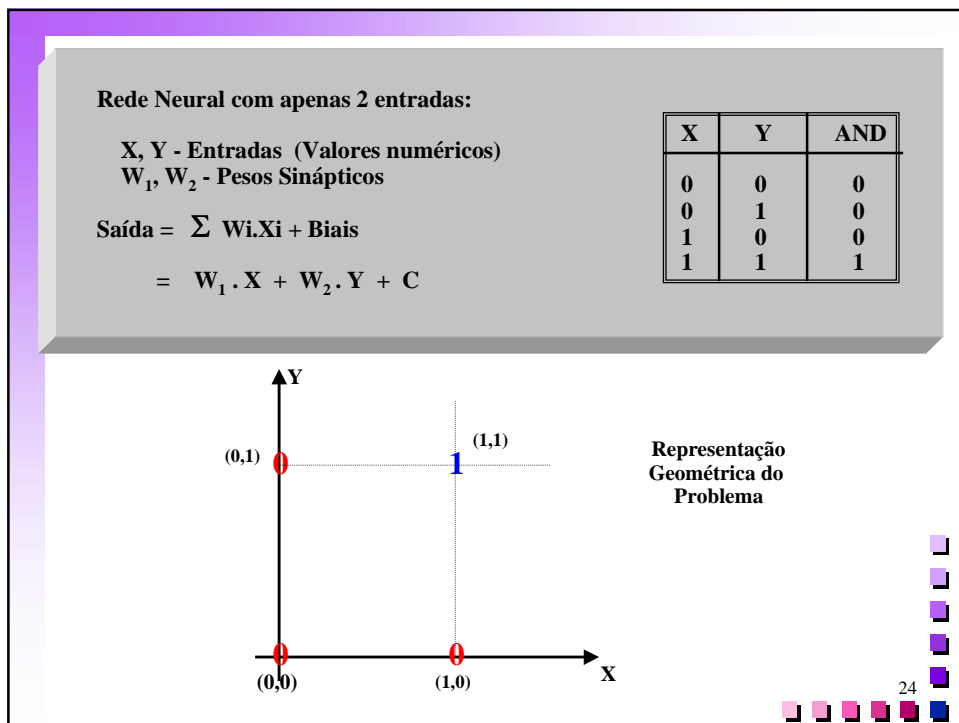
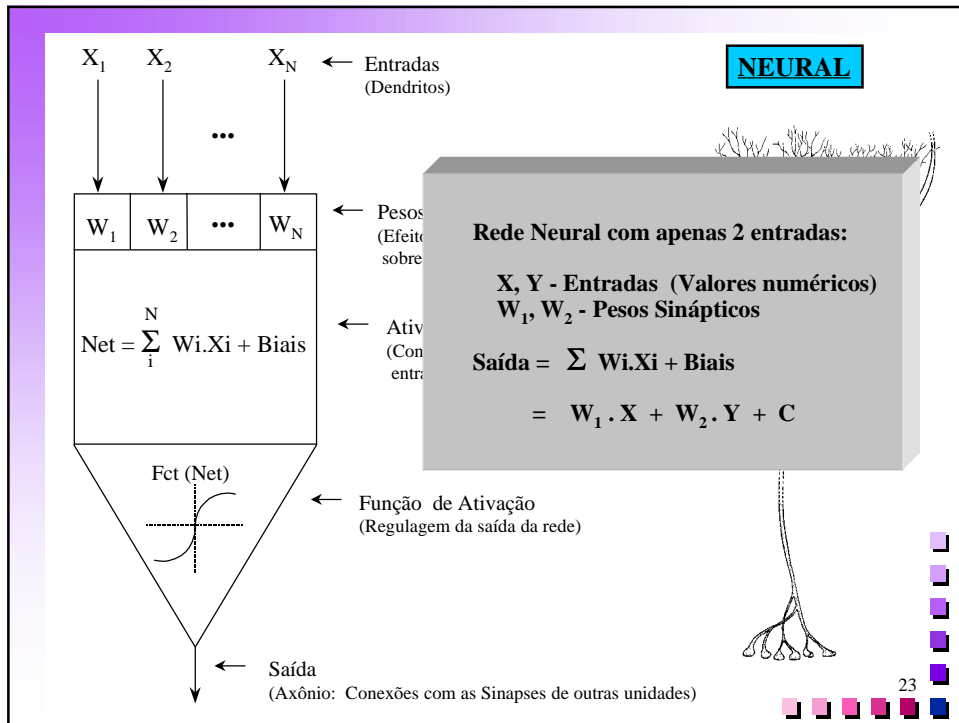
$$\text{Net} = \sum_1^N W_i \cdot X_i + \text{Biais}$$
 ← Ativação (Considera o conjunto total das entradas e dos seus pesos associados)

$\text{Fct}(\text{Net})$ ← Função de Ativação (Regulagem da saída da rede)

Saída (Axônio: Conexões com as Sinapses de outras unidades)



22




Rede Neural com apenas 2 entradas:

X, Y - Entradas (Valores numéricos)
 W_1, W_2 - Pesos Sinápticos

Saída = $\sum W_i \cdot X_i + \text{Biais}$

= $W_1 \cdot X + W_2 \cdot Y + C$

X	Y	AND
0	0	0
0	1	0
1	0	0
1	1	1





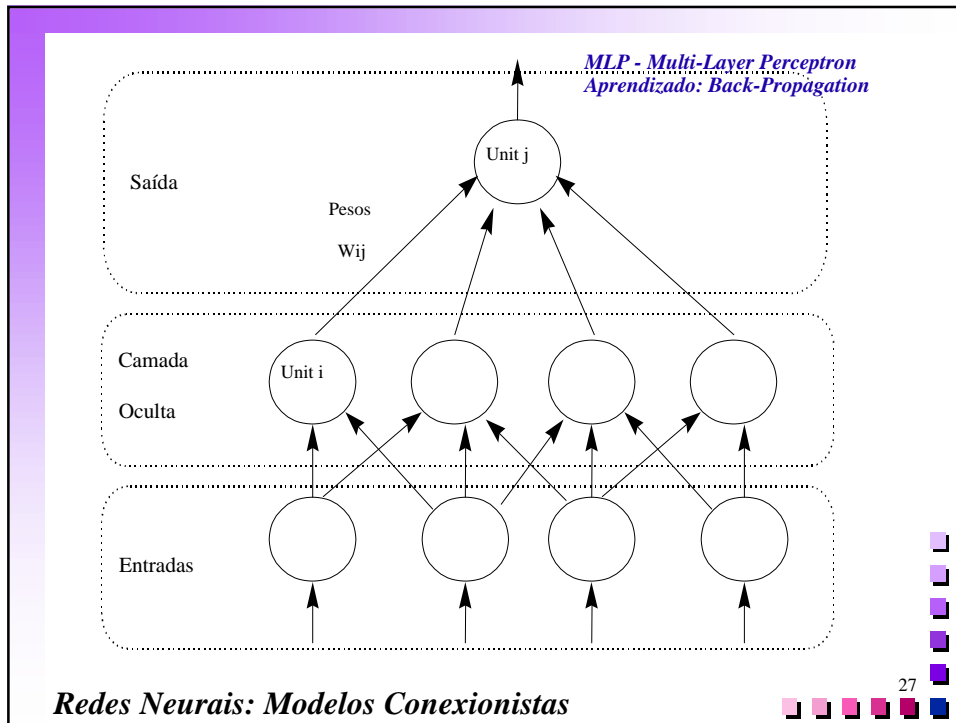
Representação Geométrica do Problema

Como classificar?
Separar as classe

Redes Neurais: Representação de Conhecimentos

Reta, Plano ou Hiper-plano de separação das classes

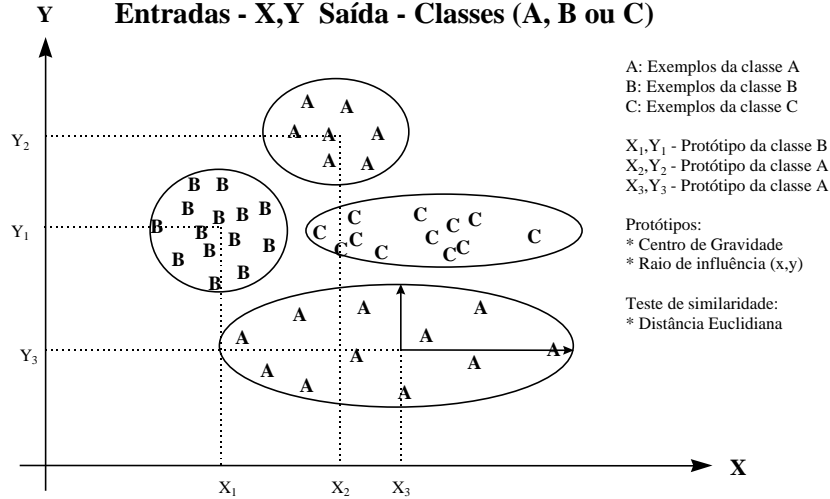




Redes Neurais: Modelos Conexionistas

Redes à base de Protótipos

Entradas - X,Y Saída - Classes (A, B ou C)



29

Redes Neurais: Modelos Conexionistas

⇒ Em relação as unidades da rede:

- * Redes baseadas em Perceptrons (MLP - *Multi-Layer Perceptron*)
- * Redes baseadas em Protótipos (RBF - *Radial Basis Function*)

⇒ Em relação a estrutura da rede:

- * Redes de uma única camada
- * Redes de múltiplas camadas
- * Redes do tipo uni-direcional (*Feed-Forward*)
- * Redes do tipo recorrentes (*Feed-Back*)
- * Redes com estrutura estática (não altera sua estrutura)
- * Redes com estrutura dinâmica (altera a estrutura)
- * Redes com conexões de ordem superior

30

Redes Neurais: Aprendizado

⇒ Em relação ao aprendizado:

- * **Aprendizado supervisionado**
- * **Aprendizado semi-supervisionado** (reinforcement learning)
- * **Aprendizado não supervisionado** (self-organizing, clustering)

- * **Aprendizado instantâneo**
- * **Aprendizado por pacotes**
- * **Aprendizado contínuo**
- * **Aprendizado ativo**

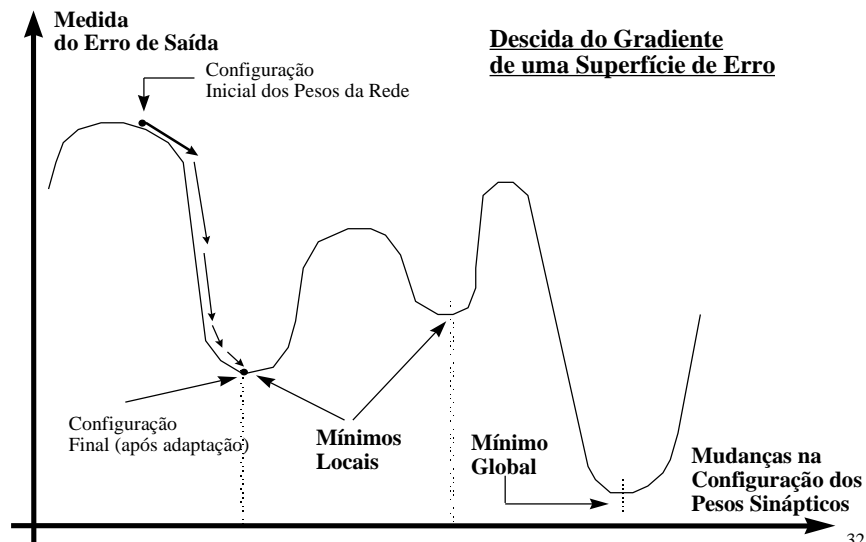
- * **Aprendizado: aproximação de funções**
- * **Aprendizado: classificação**

- * Usar apenas uma base de exemplos de aprendizado
- * Usar uma base de aprendizado e uma base de teste de **generalização**

31

Redes Neurais: Aprendizado Neural

APRENDIZADO = Adaptação das conexões (pesos sinápticos)



Redes Neurais: Aprendizado Neural

REGRA DELTA: Perceptron [Rosenblatt] / Adaline [Widrow]

$$\text{Erro} = \text{SD} - \text{SN}$$

Erro = Erro estimado na saída de um neurônio

SD = Saída Desejada (valor desejado de saída do aprendizado supervisionado)

SN = Saída Rede (valor de saída que foi obtido pela ativação do neurônio)

$$\text{Peso_Novo}(i) = \text{Peso_Antigo}(i) + \frac{\beta * \text{Erro}(i) * \text{Entrada}(i)}{|\text{Entrada}(i)|}$$

Peso_Novo(i) = Peso da entrada 'i' de um neurônio, após a adaptação

Peso_Antigo(i) = Peso da entrada 'i' de um neurônio, antes da adaptação

Entrada(i) = Valor da entrada 'i' de um neurônio

β = Fator de ajuste aplicado aos pesos (valor entre 0 e 1)

33

Redes Neurais: Aprendizado Neural

• Método da Descida do Gradiente - Multi-Layer Perceptron (MLP) BackPropagation

Erro quadrático: $E = \frac{1}{2} \sum (D_i - A_i)^2$ Ajuste dos Pesos: $\Delta W_{ij} = -\alpha \frac{\partial E}{\partial W_{ij}}$

Derivação da regra de reajuste dos pesos
(Neurônios da camada de saída - saída linear)

$$\frac{\partial E}{\partial W_{ij}} = \frac{\partial E}{\partial A_i} \frac{\partial A_i}{\partial W_{ij}} = \delta_i X_j$$

$$\frac{\partial E}{\partial A_i} = -(D_i - A_i) = \delta_i$$

$$\frac{\partial A_i}{\partial W_{ij}} = X_j$$

$$\Delta W_{ij} = -\alpha \cdot \delta_i \cdot X_j = \alpha \cdot (D_i - A_i) \cdot X_j$$

34

Redes Neurais: Aprendizado Neural

• Método da Descida do Gradiente - Multi-Layer Perceptron (MLP) BackPropagation

Erro quadrático: $E = \frac{1}{2} \sum_i (D_i - A_i)^2$

Ajuste dos Pesos: $\Delta W_{ij} = -\alpha \frac{\partial E}{\partial W_{ij}}$

$$\frac{\partial E}{\partial W_{ij}} = \frac{\partial E}{\partial S_i} \frac{\partial S_i}{\partial W_{ij}} = \delta_i X_j$$

$$\frac{\partial E}{\partial S_i} = \frac{\partial E}{\partial A_i} \frac{\partial A_i}{\partial S_i} = - (D_i - A_i) \cdot Fa'(S_i) = \delta_i$$

$$\frac{\partial E}{\partial A_i} = - (D_i - A_i)$$

$$\frac{\partial A_i}{\partial S_i} = Fa'(S_i)$$

$$\frac{\partial S_i}{\partial W_{ij}} = X_j$$

$$Fa(x) = \frac{1}{1 + e^{-x}} \quad \therefore \quad Fa'(x) = Fa(x) \cdot (1 - Fa(x))$$

$$Fa(S_i) = Fa(S_i) \cdot (1 - Fa(S_i)) = A_i \cdot (1 - A_i)$$

$$Fa(x) = \tanh(x) \quad \therefore \quad Fa'(x) = (1 - Fa(x)) \cdot Fa(x)$$

$$Fa'(S_i) = (1 - Fa(S_i)) \cdot Fa(S_i) = (1 - A_i) \cdot A_i$$

$$\Delta W_{ij} = -\alpha \cdot \delta_i \cdot X_j = \alpha \cdot (D_i - A_i) \cdot Fa'(S_i) \cdot X_j$$

Derivação da regra de reajuste dos pesos
(Neurônios da camada de saída - usando a sigmoide)

35

Redes Neurais: Aprendizado Neural

• Método da Descida do Gradiente - Multi-Layer Perceptron (MLP) BackPropagation

Erro quadrático: $E = \frac{1}{2} \sum_i (D_i - A_i)^2$

Ajuste dos Pesos: $\Delta W_{ij} = -\alpha \frac{\partial E}{\partial W_{ij}}$

$$\frac{\partial E}{\partial W_{ij}} = \frac{\partial E}{\partial S_i} \frac{\partial S_i}{\partial W_{ij}} = \delta_i X_j$$

$$\frac{\partial E}{\partial S_i} = \frac{\partial E}{\partial A_i} \frac{\partial A_i}{\partial S_i} = - Fa'(S_i) \cdot \sum_k \delta_k W_{ki} = \delta_i$$

$$\frac{\partial E}{\partial A_i} = \sum_k \frac{\partial E}{\partial S_k} \frac{\partial S_k}{\partial A_i} = \sum_k \frac{\partial E}{\partial S_k} \frac{\partial}{\partial A_i} \sum_h W_{hk} A_h = \dots$$

$$\dots = \sum_k \frac{\partial E}{\partial S_k} W_{ki} = - \sum_k \delta_k W_{ki}$$


$$\frac{\partial A_i}{\partial S_i} = Fa'(S_i)$$

$$\frac{\partial S_i}{\partial W_{ij}} = X_j$$

$$\Delta W_{ij} = -\alpha \cdot \delta_i \cdot X_j = \alpha \cdot X_j \cdot Fa'(S_i) \cdot \sum_k \delta_k W_{ki}$$

Derivação da regra de reajuste dos pesos
(Camada intermediária da rede = Hidden Layer)

36



Redes Neurais Artificiais: Aplicações Práticas

- **Sistemas de auxílio ao Diagnóstico: Médico, Falhas de Sistemas, etc;**
- **Previsão de Séries Temporais: Cotações da Bolsa de Valores, Dados Econômicos, Consumo de Energia Elétrica, Metereologia, etc;**
- **Processamento de Linguagem Natural - PLN (Textos e Web);**
- **Data Mining & KDD (Knowledge Data Discovery);**
- **Robótica Inteligente;**
- **Sistemas de Controle e Automação;**
- **Reconhecimento e Síntese de Voz;**
- **Processamento de Sinais: Radar, Sensores, etc.**

UCI-ML - University of California Irvine - Machine Learning Repository
<http://www.ics.uci.edu/~mlern/MLRepository.html>

Redes Neurais Artificiais: Aplicações Práticas

PROJETO HMLT

APLICAÇÕES DAS REDES NEURAIIS

EM

* PROCESSAMENTO DE IMAGENS

* ROBÓTICA AUTÔNOMA

* DATA MINING

39


Conclusão e Perspectivas

- * **Importância do Aprendizado nos Sistemas Inteligentes**
- * **Aprendizado Neural: propriedades interessantes...**
Robustez, Paralelismo, Generalização, Entradas/Saídas Quantitativas
- * **Processamento de Imagens: área de estudos de grande interesse para a I.A.**
Visão Artificial - Desafio
- * **Processamento de Imagens usando Sistemas Inteligentes:**
Redes Neurais - Ferramenta bastante adequada para se tratar imagens
- * **Redes Neurais aplicadas ao processamento de imagens:**
Tratamento de Imagens / Reconhecimento e Classificação de Imagens
- * **Resultados são bastante promissores**
- * **Tendência: *Sistemas Híbridos***
Integrar => Pré-Processamento, Pós-Processamento
Cooperação - Multi-agente, Modular
Tarefas complexas e de alto nível

40

Inteligência Artificial: Perspectivas

Hybrid Machine Learning Tools
<http://www.inf.unisinos.br/~osorio/>



Grupo de Inteligência Artificial @



41