

Sistemas Híbridos Inteligentes

HMLT - Hybrid Machine Learning Tools

Congresso da SBC - ENIA'99

Autores:

Prof. Dr. Fernando Osório

Prof. Dra. Renata Vieira

Rio de Janeiro - Julho 1999



UNISINOS - Centro de Ciências Exatas e Tecnológicas - Informática

E-mail: osorio@exatas.unisinos.br

renata@exatas.unisinos.br

Web: <http://www.inf.unisinos.br/~osorio/>

Tópicos abordados:

0. Introdução

1. Inteligência Artificial: Métodos Simbólicos

1.1 Conceitos Básicos

1.2 Aquisição e Representação de Conhecimentos

1.3 Aprendizado Simbólico

1.4 Vantagens e Desvantagens

2. Inteligência Artificial: Métodos Conexionistas (*Redes Neurais*)

2.1 Conceitos Básicos

2.2 Representação de Conhecimentos

2.3 Modelos Conexionistas - Classificação

2.4 Aprendizado Neural

2.5 Vantagens e Desvantagens

3. Sistemas Híbridos Inteligentes

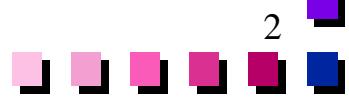
3.1 Conceitos Básicos

3.2 Tipos de Integração

3.3 Sistemas Híbridos Neuro-Simbólicos (SHNS)

3.4 Exemplos de SHNS: SYNHESYS, KBANN, INSS

3.5 Considerações Finais



I.A. - Métodos Simbólicos: Conceitos Básicos

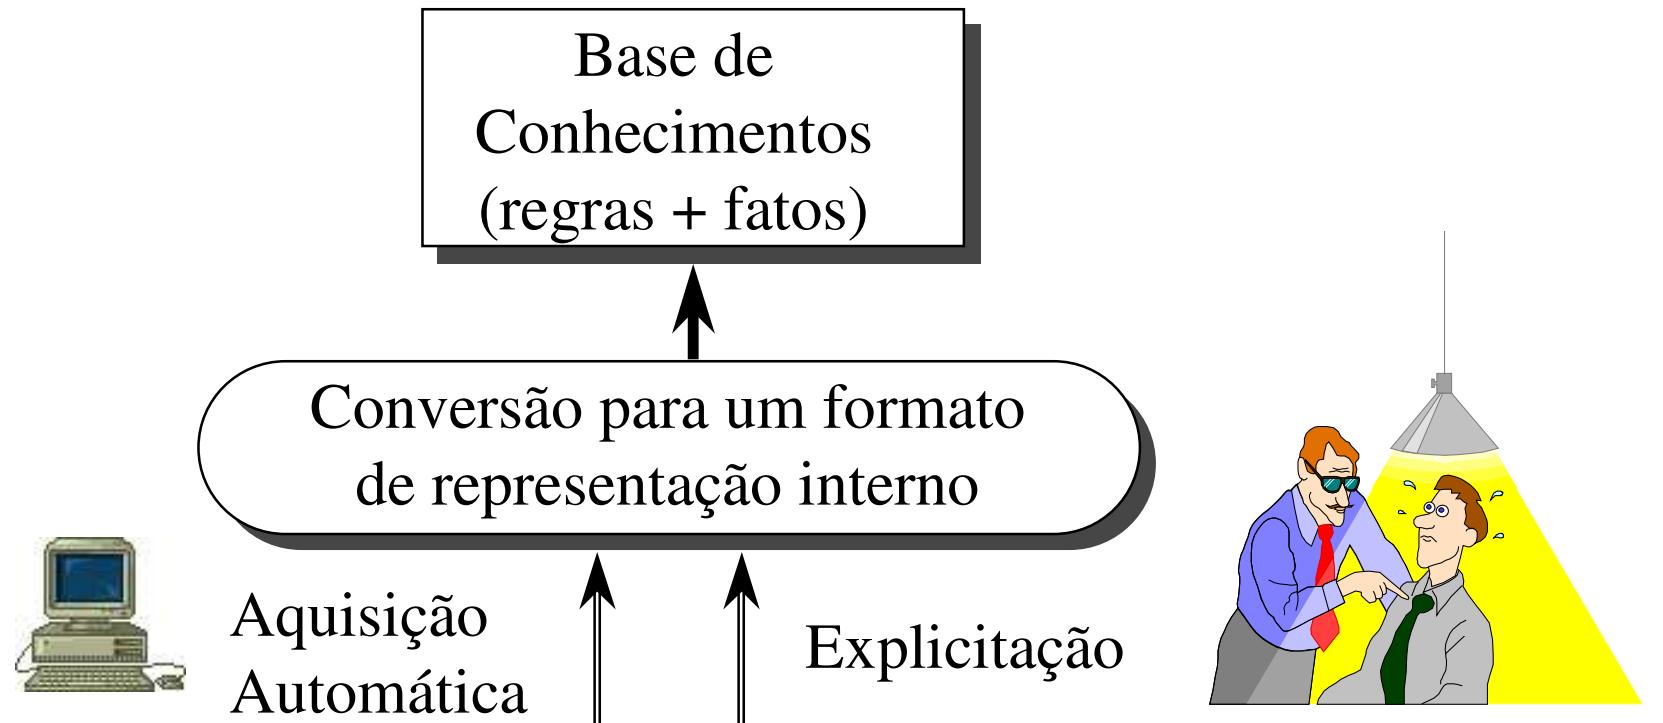


REPRODUZIR A
INTELIGÊNCIA HUMANA



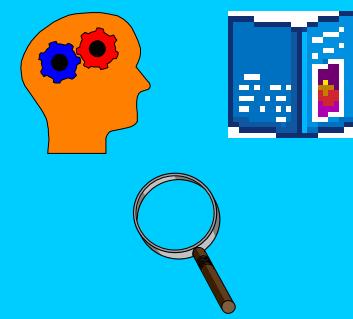
- Conceito de Inteligência
- Atividades Inteligentes
- Sistemas Inteligentes:
 - * Sistemas Especialistas
 - * Sistemas de Apoio ao Diagnóstico e a Decisão
 - * Reprodução de atividades típicas dos seres humanos:
Fala, Audição, Visão, Deslocamento, Manipulação de Objetos, etc.

Métodos Simbólicos: Aquisição de Conhecimentos



Conhecimentos sobre uma área de aplicação:

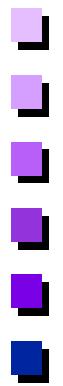
- *Conhecimentos do especialista*
- *Teorias sobre o domínio de aplicação*
- *Resultados de experiências práticas*
(casos conhecidos)



Métodos Simbólicos: Representação de Conhecimentos

- * Sistemas baseados em conhecimentos:
KBS - Knowledge Base Systems, Expert Systems (Frames e Redes Semânticas)
Rule Based Systems, Production Rule Systems
- * Sistemas baseados em regras de lógica difusa ou nebulosa
Fuzzy Expert Systems
- * Sistemas baseados em probabilidades
Redes Bayesianas
- * Sistemas baseados em casos ou exemplos
CBR - Case Based Reasoning
- * Árvores de decisão
IDT - Inductive Decision Trees
- * Algoritmos Genéticos
GA - Genetic Algorithms

Sistemas Especialistas baseados em Conhecimento Simbólico
Dado um problema:
Assume-se usualmente => Conhecimento é *Completo* e *Correto*



Métodos Simbólicos: Representação de Conhecimentos

⇒ Conhecimentos Teóricos

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

ou

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

⇒ Conhecimentos Empíricos

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



Métodos Simbólicos: Aprendizado

- Aprendizado por analogia
Sistemas baseados em casos
CBR - *Case Based Reasoning*
- Aprendizado por Indução
Árvores de Decisão
ID3, C4.5, CN2 - *Induction of Decision Trees*
ILP - *Inductive Logic Programming (Prolog)*
- Aprendizado por Explicação
EBL - *Explanation-Based Learning*
- Aprendizado por evolução/seleção
Algoritmos Genéticos
GA e GP - *Genetic Algorithms / Genetic Programming*



BASE DE DADOS SOBRE O PROBLEMA

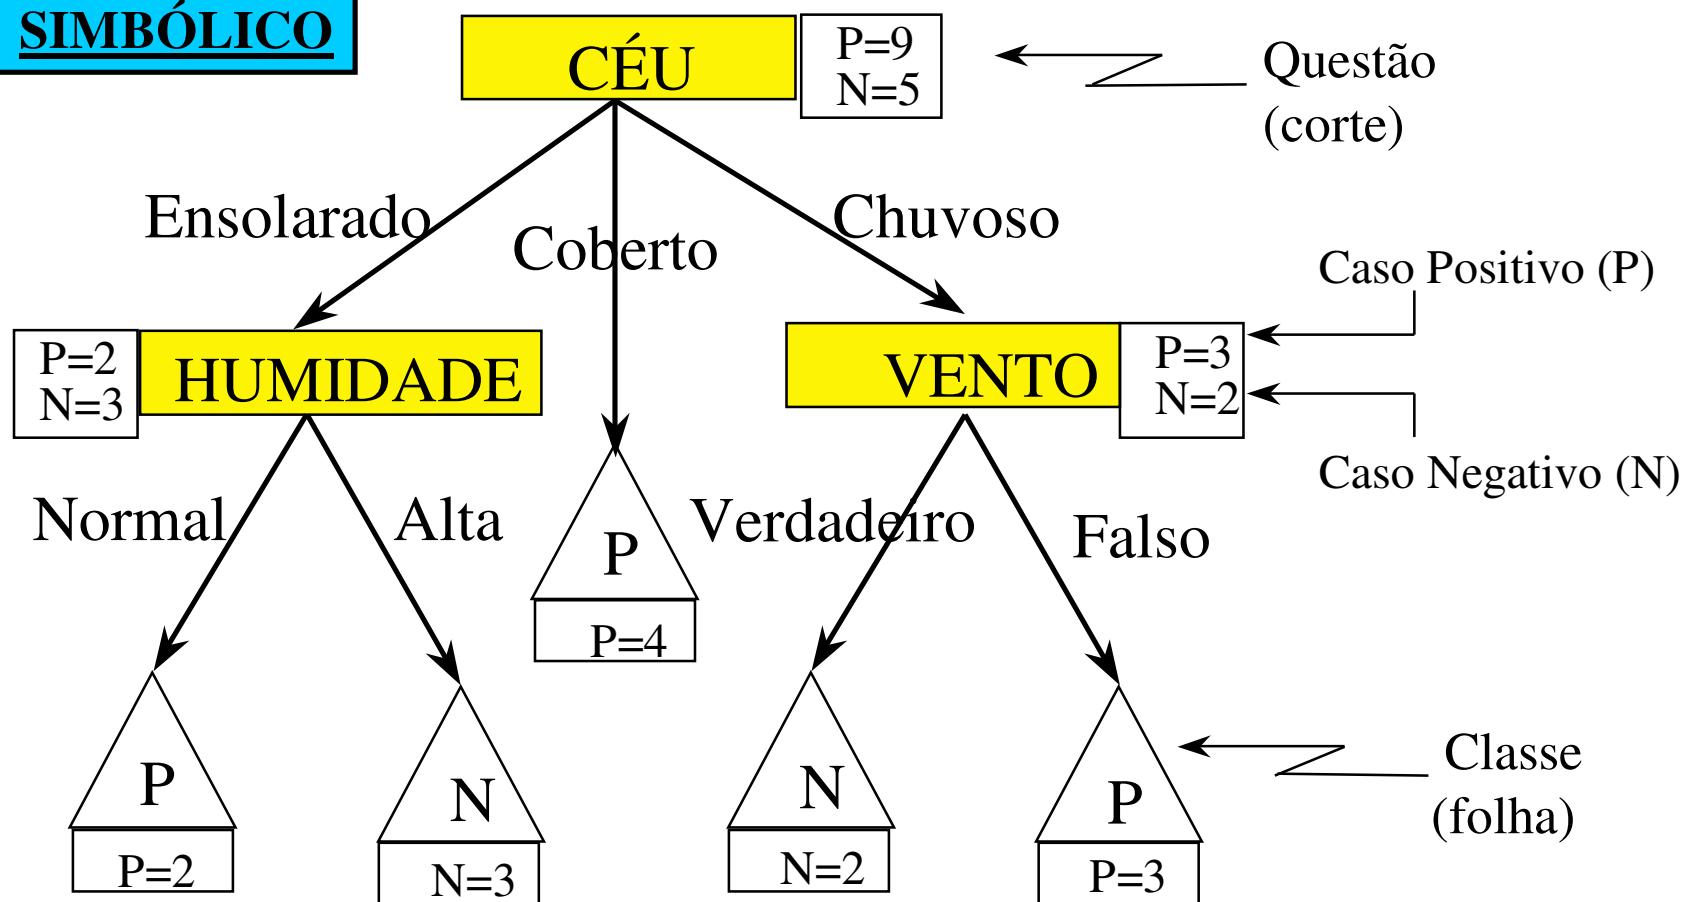
<i>NÚMERO</i>	<i>CÉU</i>	<i>TEMPERATURA</i>	<i>HUMIDADE</i>	<i>VENTO</i>	<i>CLASSE</i>
1	ensolarado	elevada	alta	não	N
2	ensolarado	elevada	alta	sim	N
3	coberto	elevada	alta	não	P
4	chuvisco	média	alta	não	P
5	chuvisco	baixa	normal	não	P
6	chuvisco	baixa	normal	sim	N
7	coberto	baixa	normal	sim	P
8	ensolarado	média	alta	não	N
9	ensolarado	baixa	normal	não	P
10	chuvisco	média	normal	não	P
11	ensolarado	média	normal	sim	P
12	coberto	média	alta	sim	P
13	coberto	elevada	normal	não	P
14	chuvisco	média	alta	sim	N

Tabela – Conjunto de dados de aprendizado : Condições meteorológicas

N = Negativo (tempo ruim)

P = Positivo (tempo bom)

SIMBÓLICO

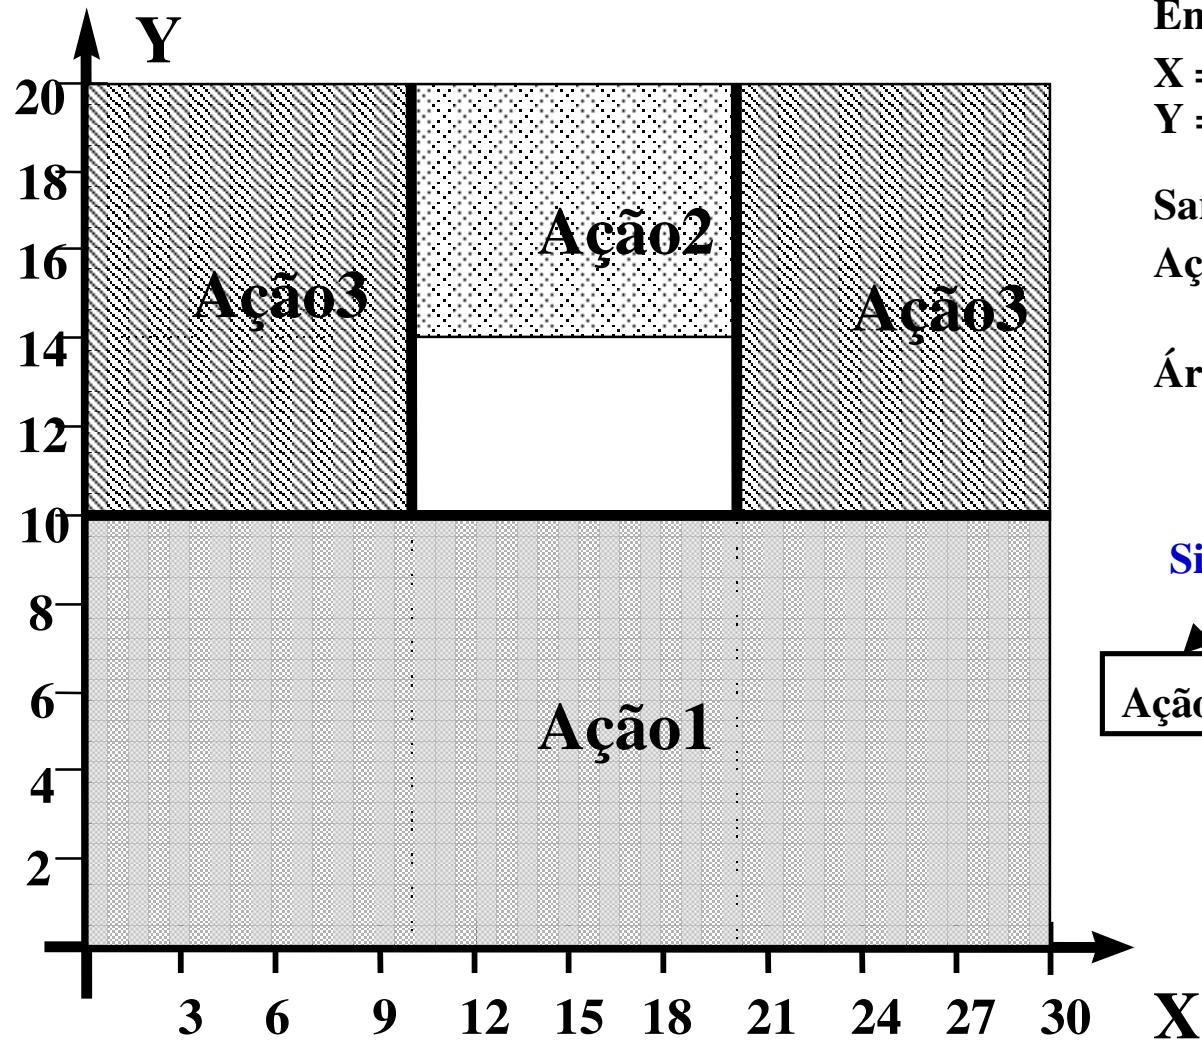


IF ((CÉU=Ensolarado *and* HUMIDADE=Normal) *or*
 (CÉU=Coberto) *or*
 (CÉU=Chuvoso *and* VENTO=Falso))

Then Classe = P

ARVORE DE DECISÃO

Métodos Simbólicos: Árvores de Decisão



Entradas:

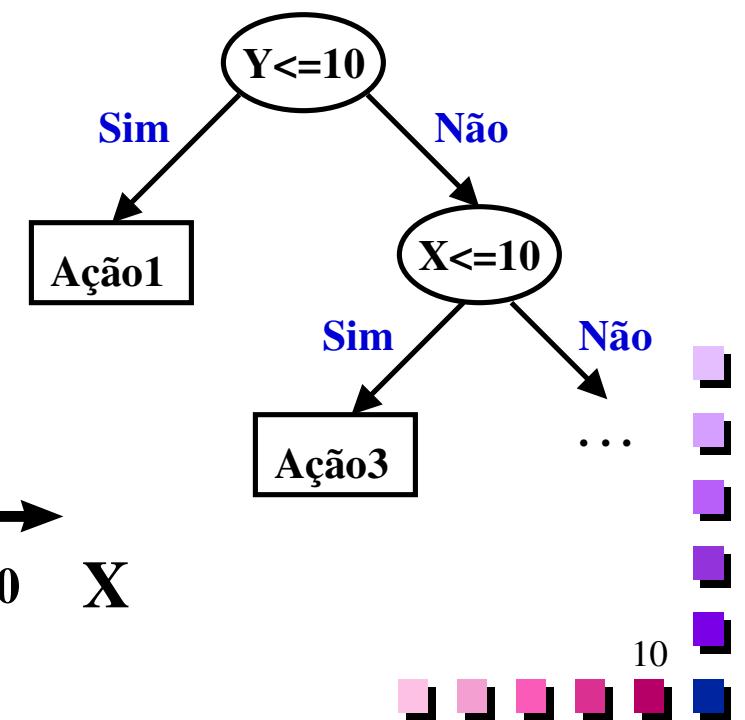
$$X = [0..30]$$

$$Y = [0..20]$$

Saídas (Ações):

Ação1 , Ação2 , Ação3

Árvore de Decisão:

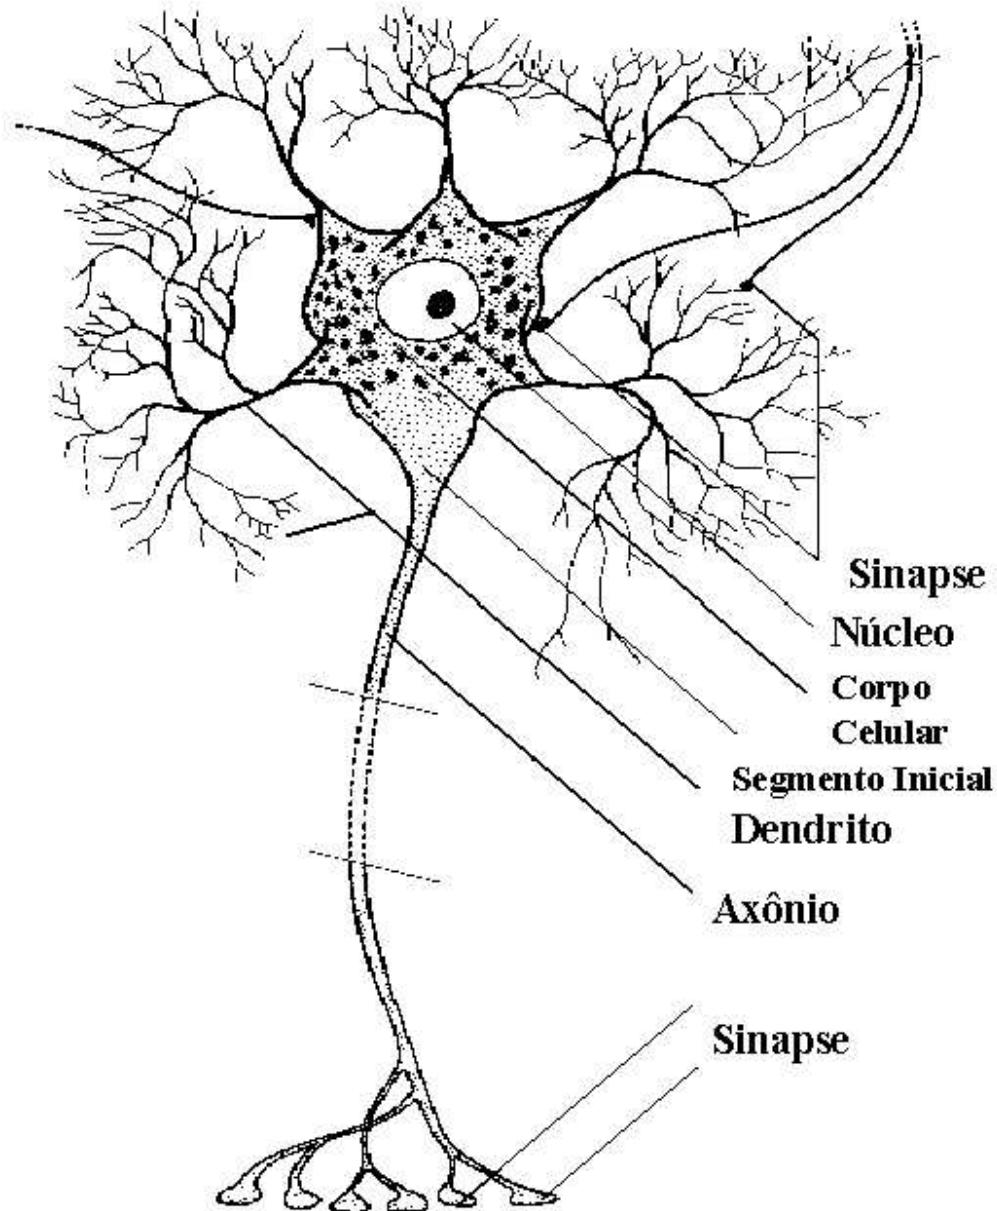


Métodos Simbólicos: Vantagens e Desvantagens

- + Conhecimento representado por **regras** (ou outra estrutura similar) que podem ser **facilmente interpretadas e analisadas**;
- + **Permite a explicação** do processo que levou a uma determinada **resposta**;
- + **Fácil inserção de novos conhecimentos** obtidos à partir do especialista ou através de métodos automáticos de aquisição de conhecimentos;
- Necessidade de se trabalhar com **conhecimentos completos e exatos** sobre um determinado problema;
- Dificuldade de **explicitar todos** os conhecimentos relativos ao problema através de regras simbólicas;
- Dificuldade para tratar **informações imprecisas ou aproximadas**, e valores numéricos (**dados quantitativos**).



I.A. - Métodos Conexionistas: Conceitos Básicos



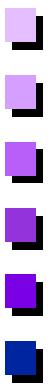
Redes Neurais Artificiais:

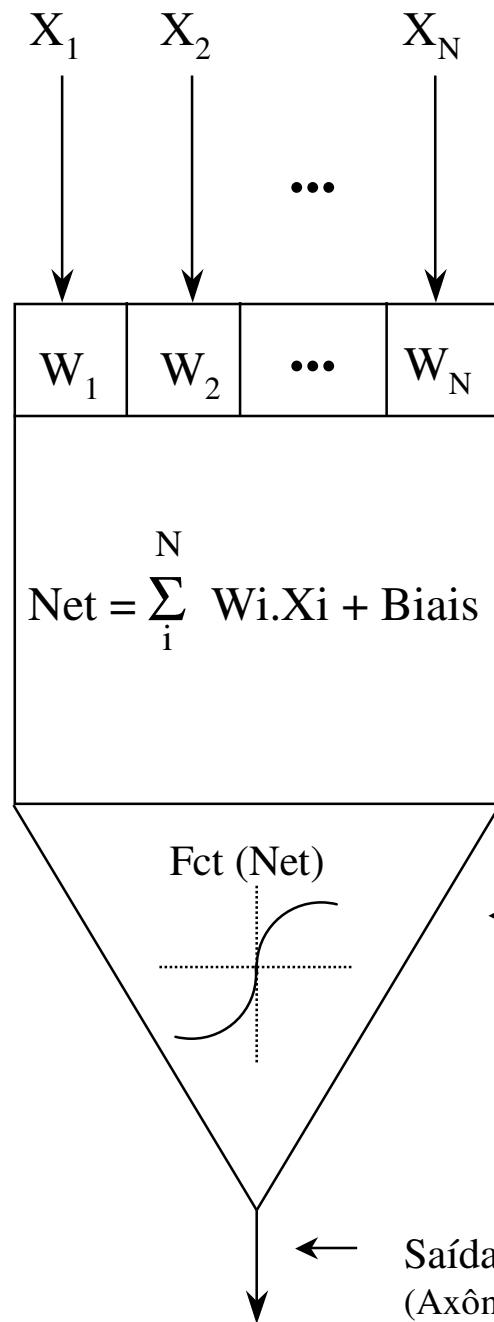
Neurônio...
Modelo Simulado
Modelo SIMPLIFICADO

Características Básicas:
Adaptação
Aprendizado
Autômato

Representação de
Conhecimentos:

Baseada em Conexões





← Entradas (Dendritos)

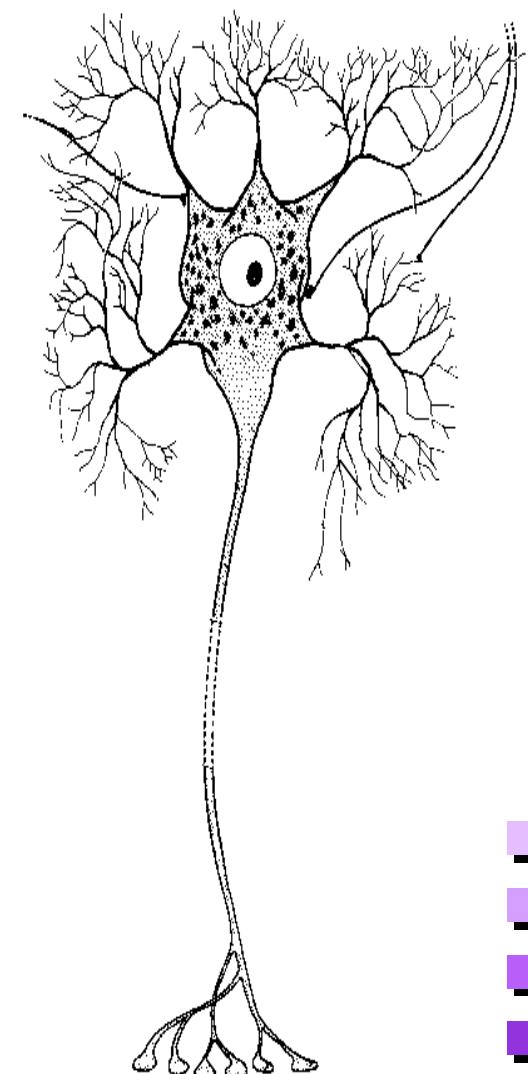
← Pesos Sinápticos
(Efeito de inibição ou de excitação sobre a ativação dos sinais de entrada)

← Ativação
(Considera o conjunto total das entradas e dos seus pesos associados)

← Função de Ativação
(Regulagem da saída da rede)

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

NEURAL



X_1 X_2 \dots X_N \leftarrow Entradas (Dendritos)

NEURAL

W_1 W_2 \dots W_N

$$\text{Net} = \sum_i^N W_i \cdot X_i + \text{Biais}$$

← Pesos (Efeitos sobre)

← Ativação (Conexões entre)

Fct (Net)

← Função de Ativação (Regulagem da saída da rede)

Saída

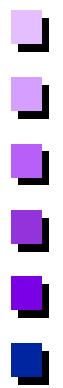
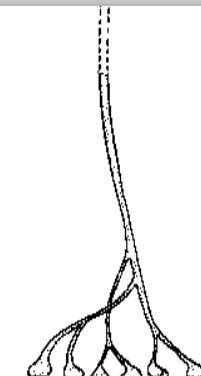
(Axônio: Conexões com as Sinapses de outras unidades)

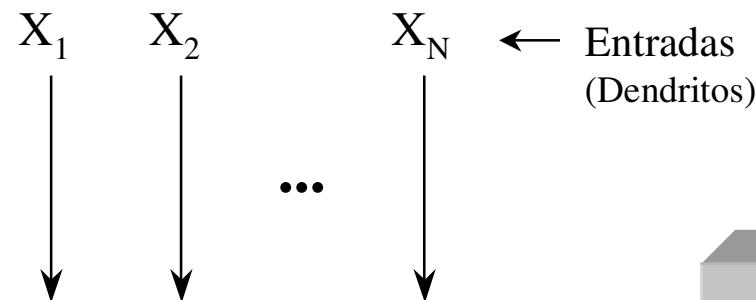
Rede Neural com apenas 2 entradas:

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

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

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





NEURAL

Rede Neural com apenas 2 entradas:

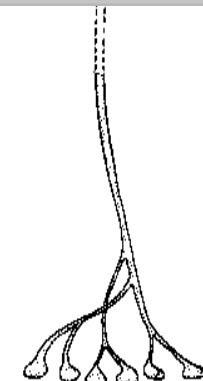
X, Y - Entradas (Valores numéricos)
 W_1, W_2 - Pesos Sinápticos

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

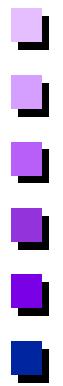
$$= W_1 \cdot X + W_2 \cdot Y + C$$

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

Função
 (Saída da rede)

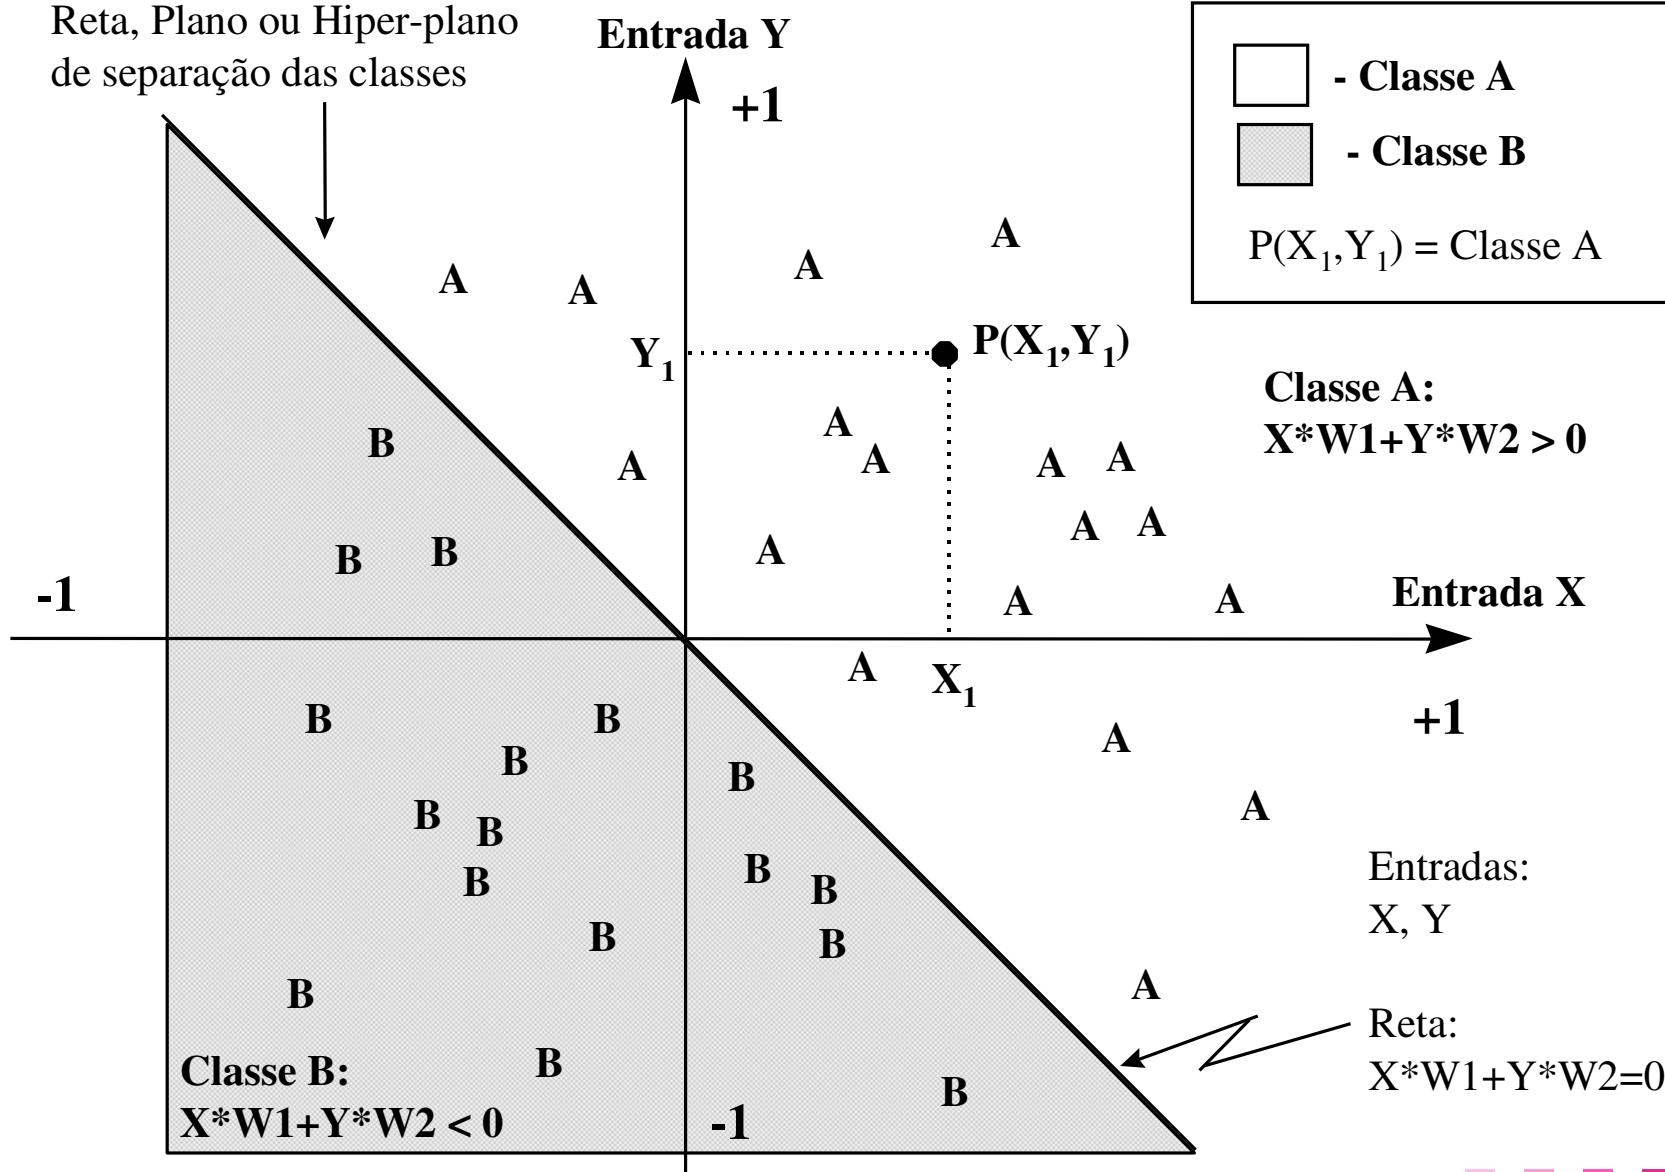


Após sinapses de outras unidades)



Métodos Conexionistas: Representação de Conhecimentos

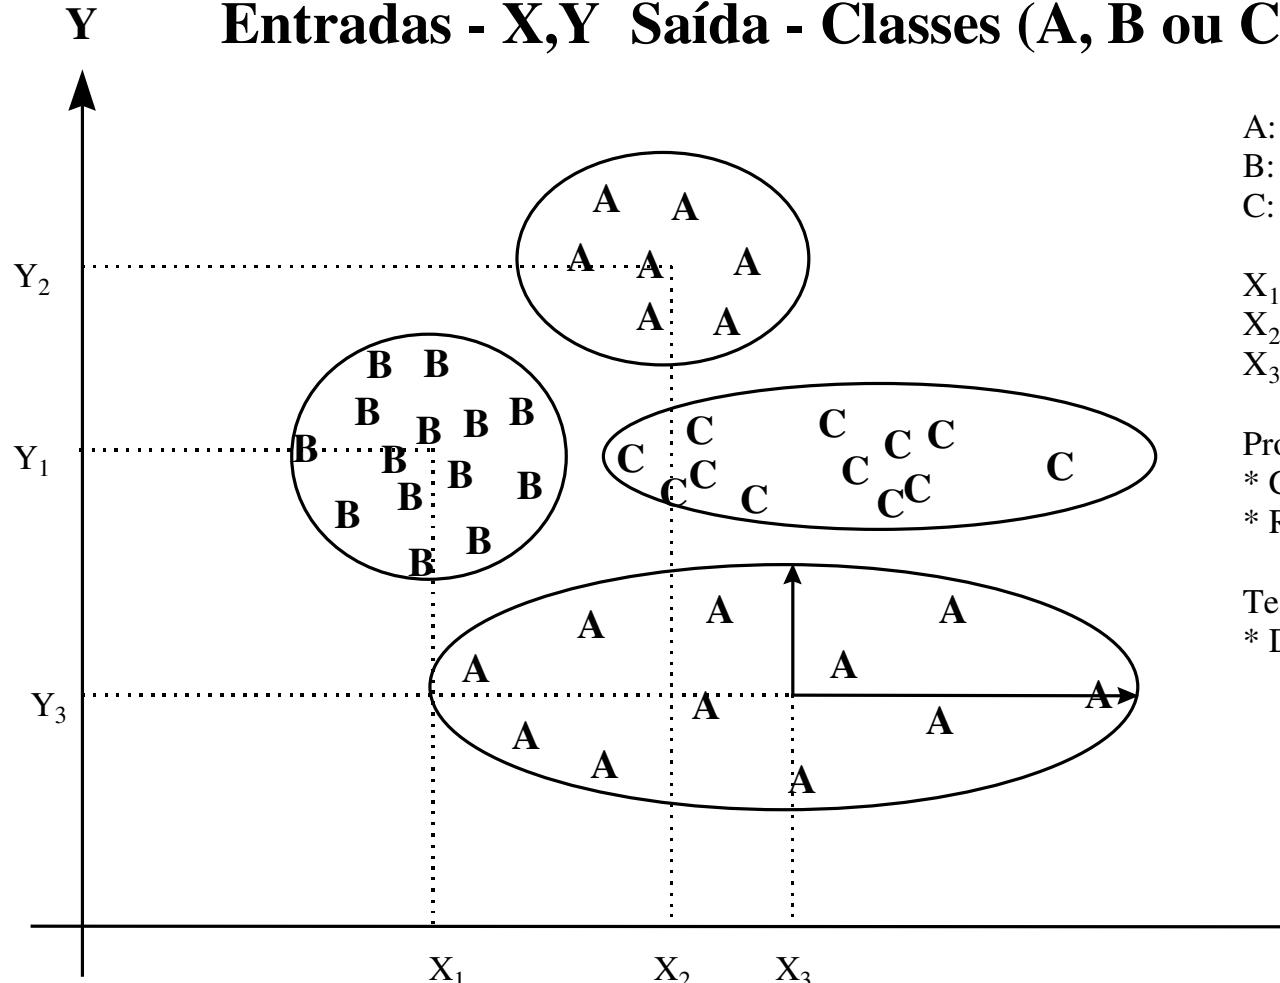
Reta, Plano ou Hiper-plano de separação das classes



Métodos Conexionistas: Representação de Conhecimentos

Redes à base de Protótipos

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



A: Exemplos da classe A
B: Exemplos da classe B
C: Exemplos da classe C

X_1, Y_1 - Protótipo da classe B
 X_2, Y_2 - Protótipo da classe A
 X_3, Y_3 - Protótipo da classe A

Protótipos:
* Centro de Gravidade
* Raio de influência (x,y)

Teste de similaridade:
* Distância Euclidiana



Modelos Conexionistas: Classificação

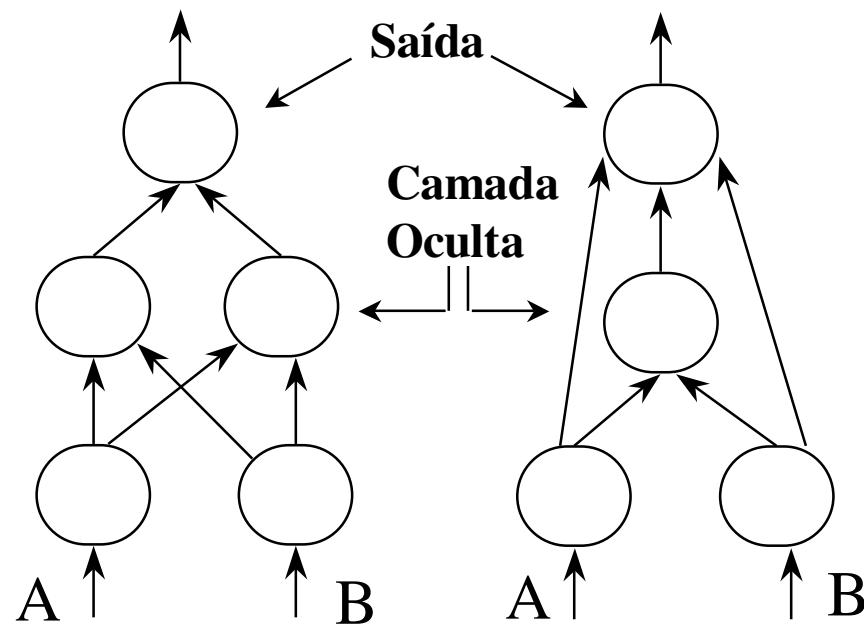
⇒ Em relação as unidades da rede:

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

⇒ Em relação a estrutura da rede:

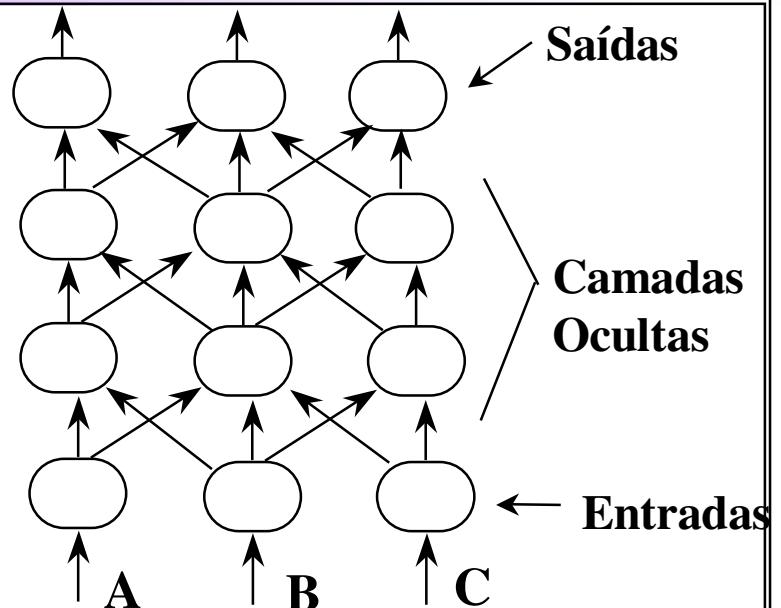
- * Redes de uma única camada
- * Redes de múltiplas camadas
- * Redes do tipo uni-direcional (*Feed-Forward*)
- * Redes do tipo recorrentes (*Feed-Back*)
- * Redes com estrutura estática (não altera sua estrutura)
- * Redes com estrutura dinâmica (altera a estrutura)
- * Redes com conexões de ordem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



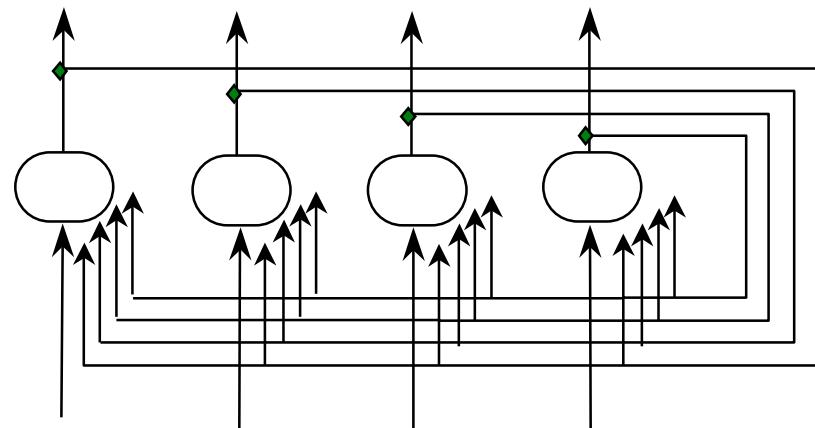


(a) Rede de três camadas

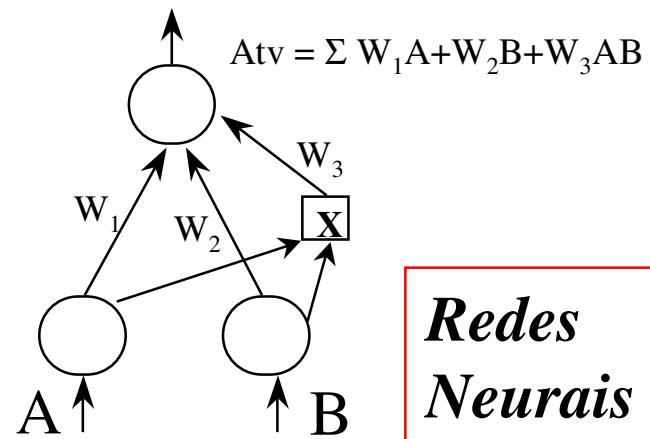
(b) Rede com atalhos



(c) Rede com múltiplas camadas



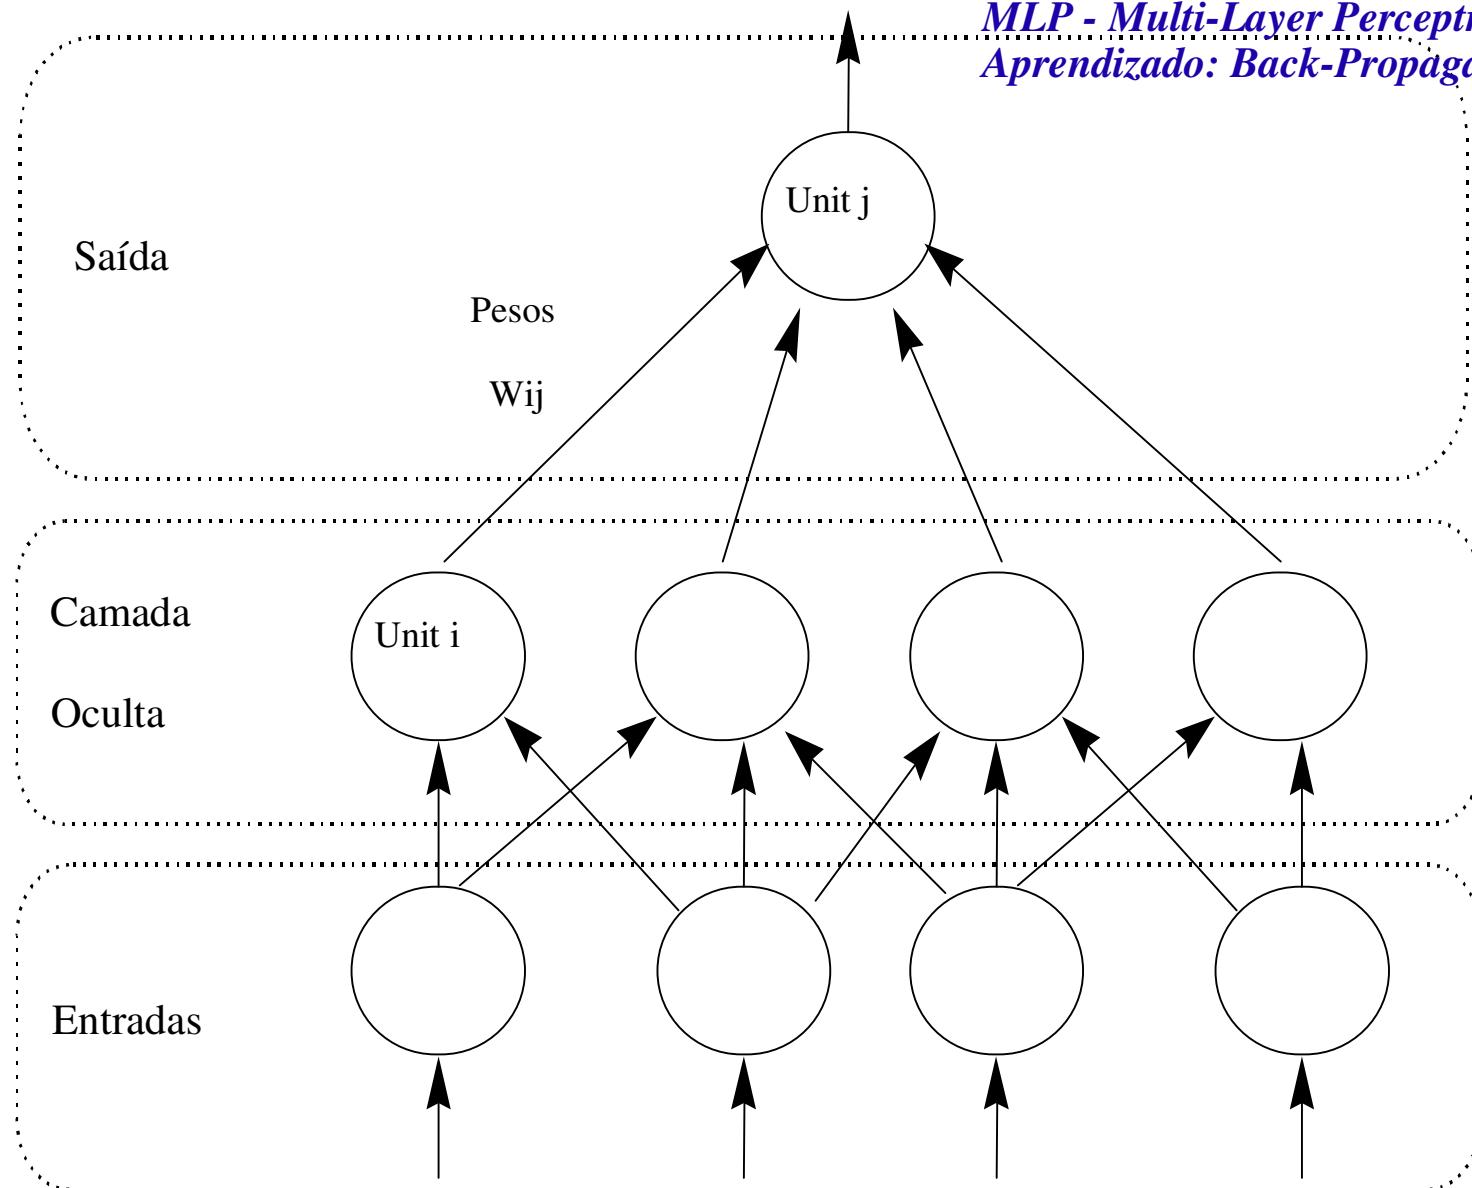
(d) Rede recorrente



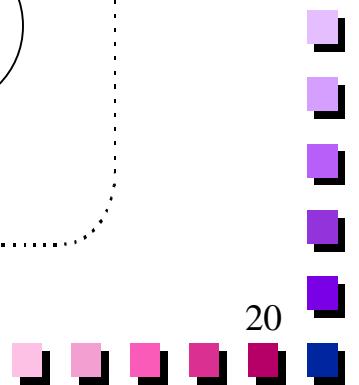
Redes Neurais



MLP - Multi-Layer Perceptron
Aprendizado: Back-Propagation



20



Modelos Conexionistas: Classificação

⇒ 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

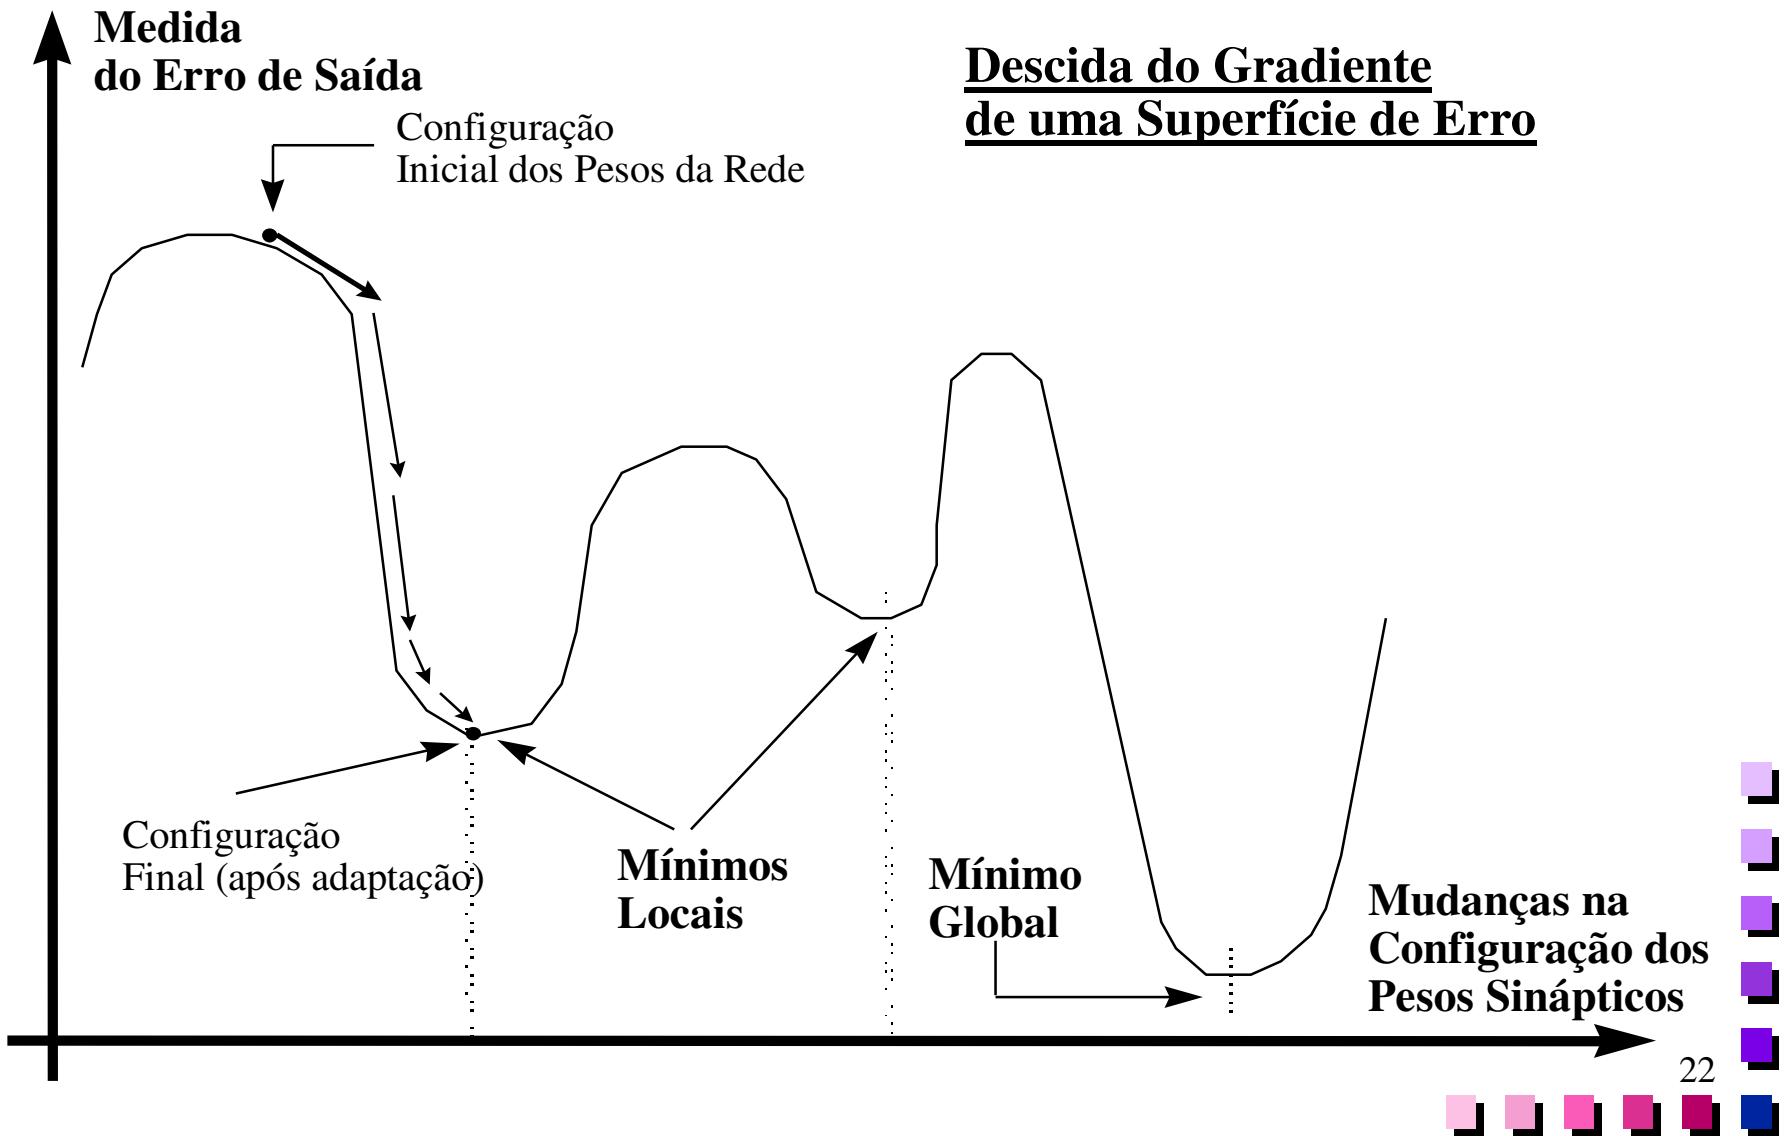
- * Aprendizado: aproximação de funções
- * Aprendizado: classificação

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

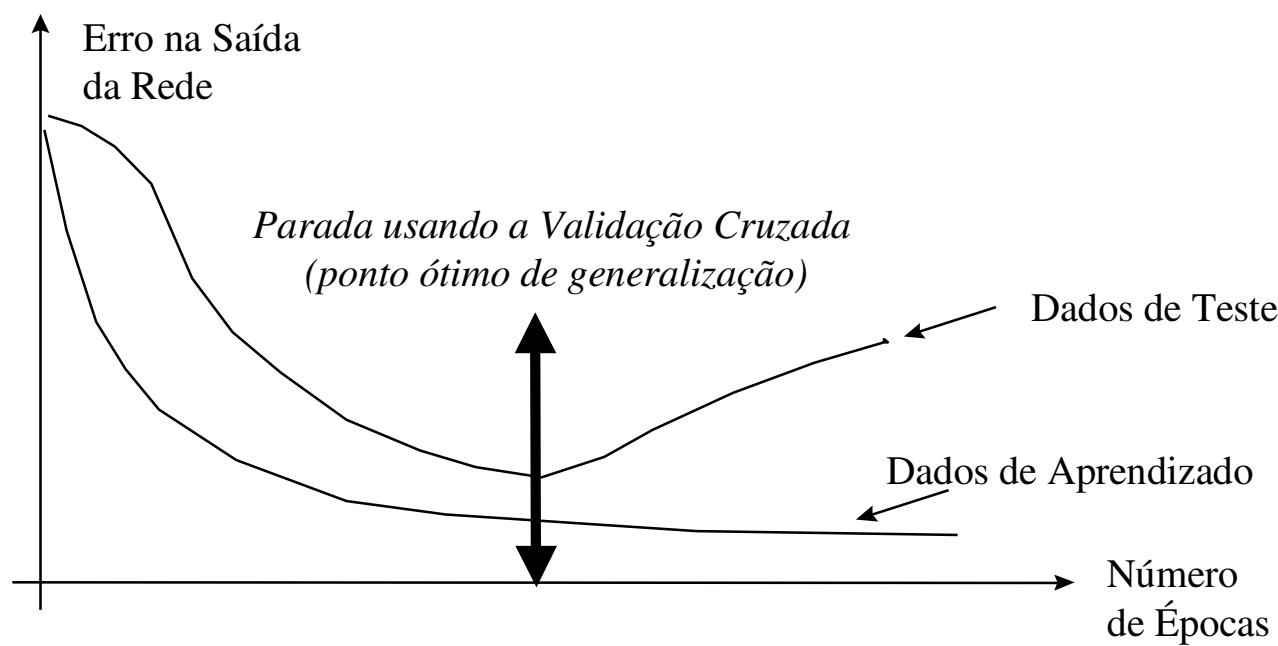
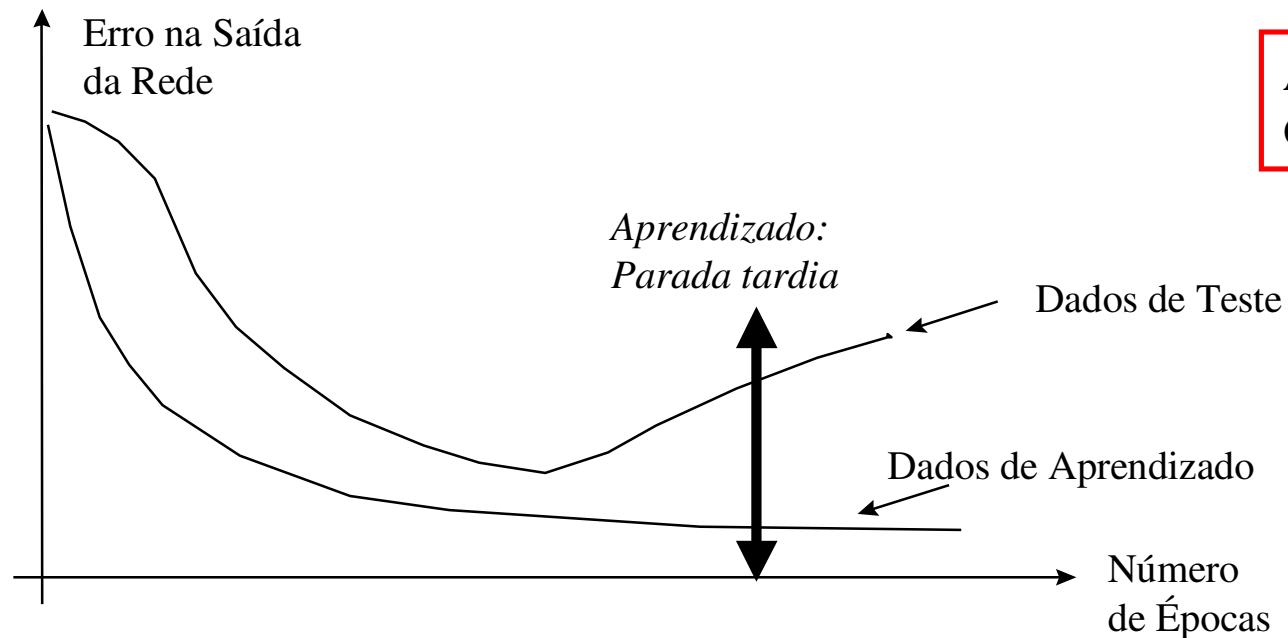


Modelos Conexionistas: Aprendizado Neural

APRENDIZADO = Adaptação das conexões (pesos sinápticos)



APRENDIZADO: GENERALIZAÇÃO



Métodos Conexionistas: Vantagens e Desvantagens

- + **Aquisição automática de conhecimentos empíricos** à partir de uma base de exemplos de aprendizado referente a um problema;
- + **Manipulação de dados quantitativos, aproximados e mesmo incorretos** com uma degradação gradual das respostas;
- + **Grande poder de representação de conhecimentos** através da criação de relações ponderadas entre as entradas do sistema;
- **Dificuldade de configuração** das redes em relação à sua **estrutura** inicial e também no que se refere aos **parâmetros** dos algoritmos de aprendizado;
- **Dificuldade de explicitar os conhecimentos** adquiridos pela rede através de uma linguagem comprehensível para um ser humano;
- **Dificuldade de convergência** (bloqueios) e **instabilidade**, inerentes aos algoritmos de otimização empregados;
- **Lentidão do processo de aprendizado / adaptação.**

Sistemas Híbridos Inteligentes

* Conceitos Básicos:

- Complementaridade
- Divisão de tarefas / Especialização
- Modularidade
- Diversificação:
 - Representação de Conhecimentos
 - Fontes de Aquisição de Conhecimentos

Exemplo: SER HUMANO



Sistemas Híbridos Inteligentes: Integração

* Módulos Básicos:

- Métodos Simbólicos: CBR, KBS, IDT, GA, Fuzzy, ...
- Métodos Conexionistas: Redes Neurais

* Tipos de Integração:

- Simbólico-Difuso
- Simbólico-Genético
- Neuro-Genético
- Neuro-CBR
- Neuro-Simbólicos
 - Neuro-Fuzzy
 - Neuro- IDT
 - Neuro-KBS



Sistemas Híbridos Neuro-Simbólicos

S.H.N.S.

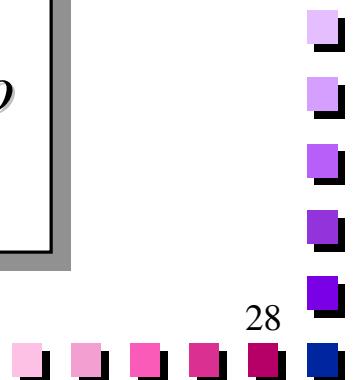
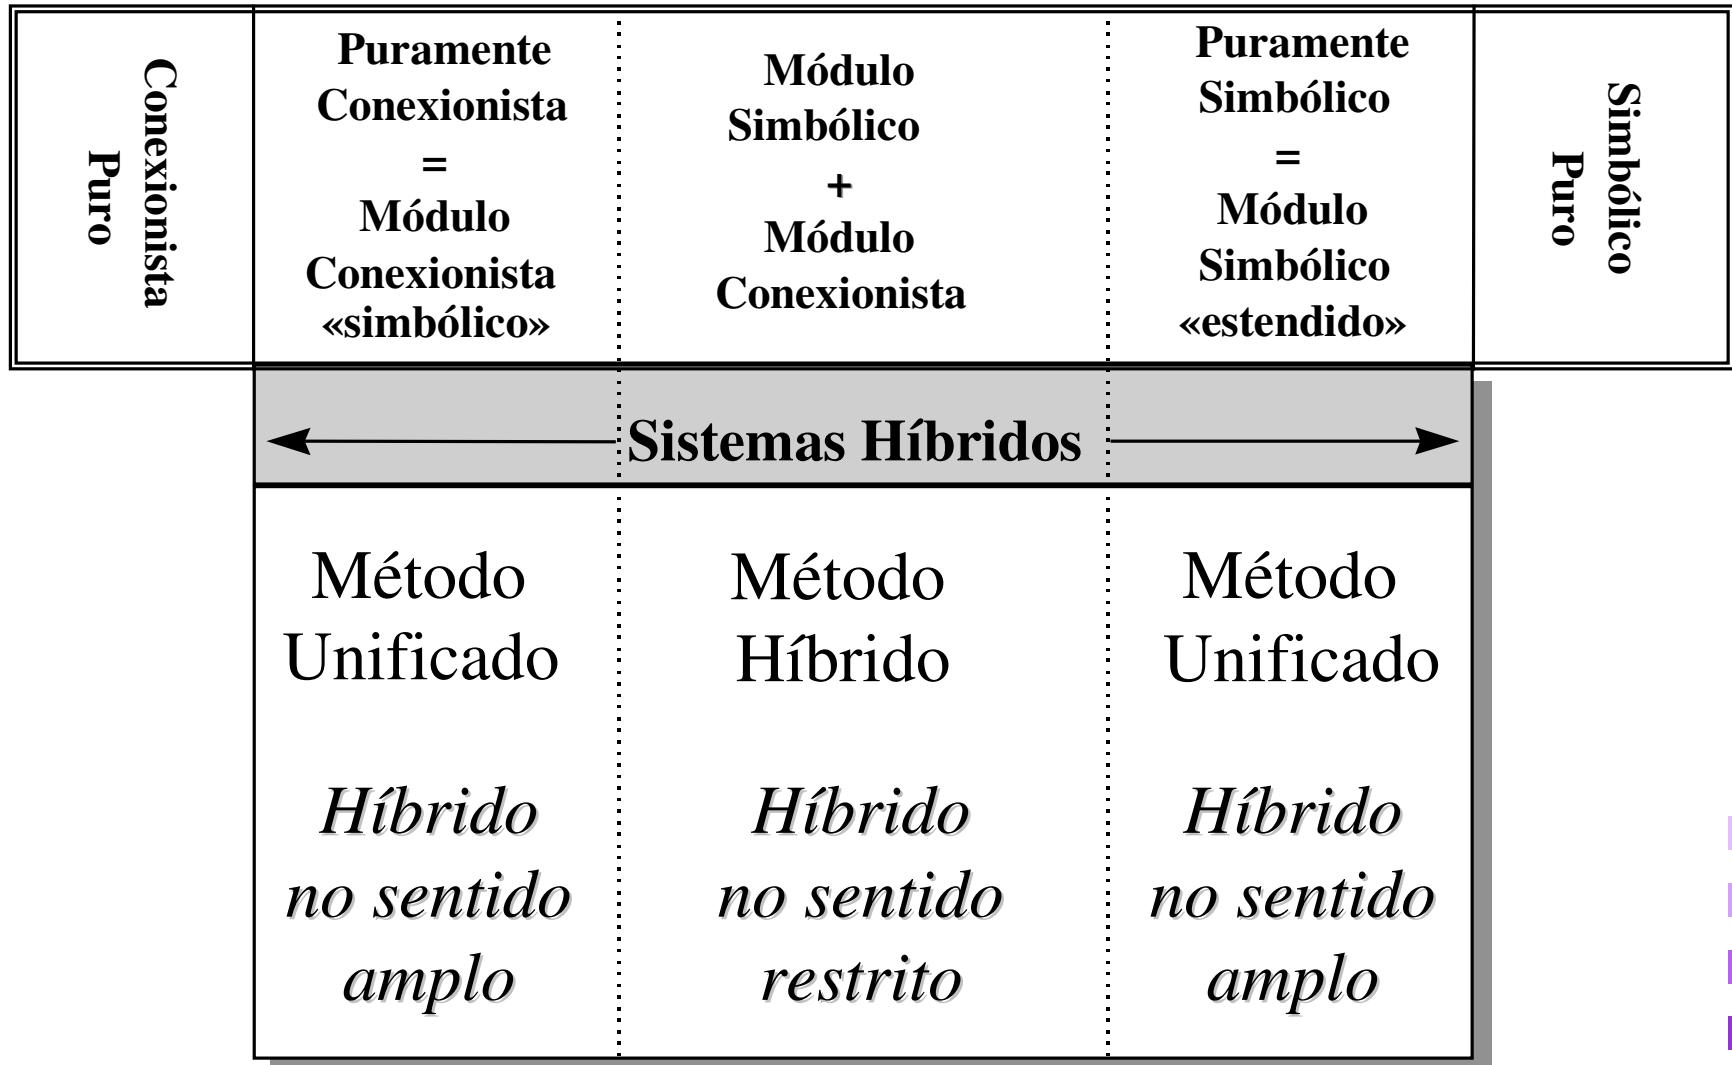
INTEGRAÇÃO:

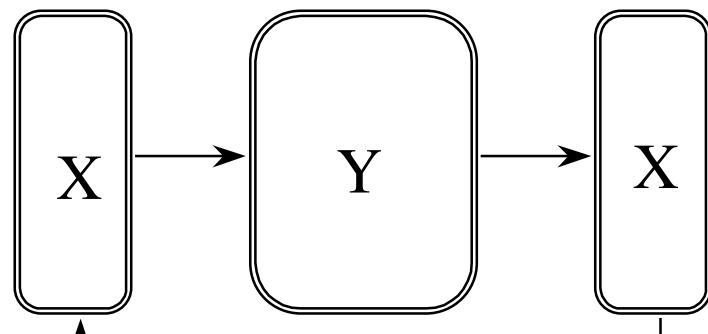
NÍVEL SIMBÓLICO

NÍVEL SUB-SIMBÓLICO

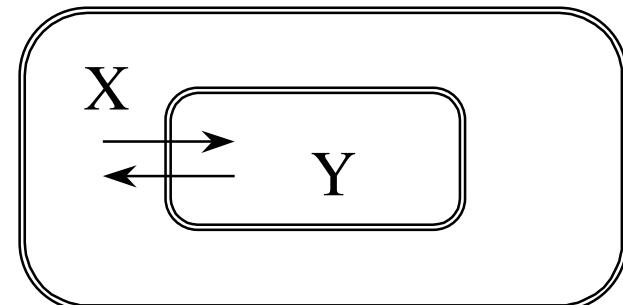


Sistemas Híbridos Neuro-Simbólicos

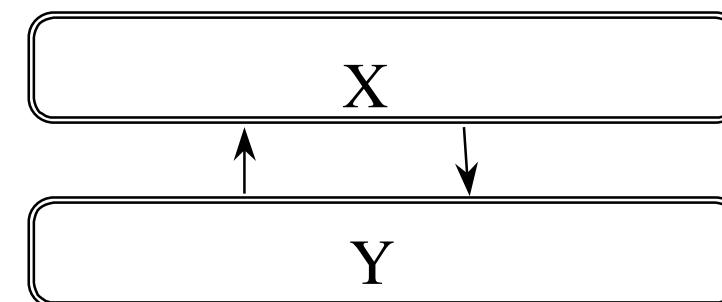




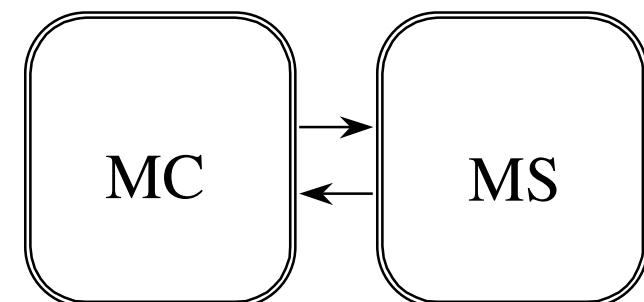
(a) Processamento em Cadeia



(b) Sub-Processamento



(c) Meta-Processamento



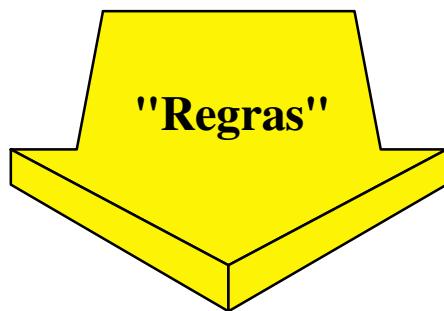
(d) Co-Processamento

SHNS

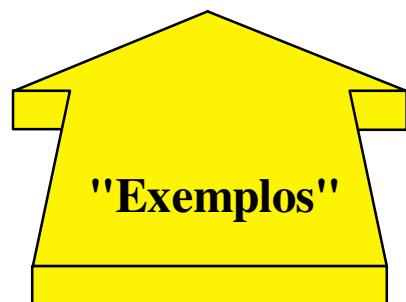
MC: Módulo Conexionista - MS: Módulo Simbólico
 X,Y: MC ou MS - X diferente de Y

Aquisição de Conhecimentos

Conhecimentos Teóricos



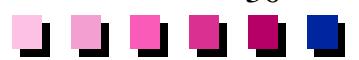
Aquisição de Conhecimentos



Conhecimentos Empíricos

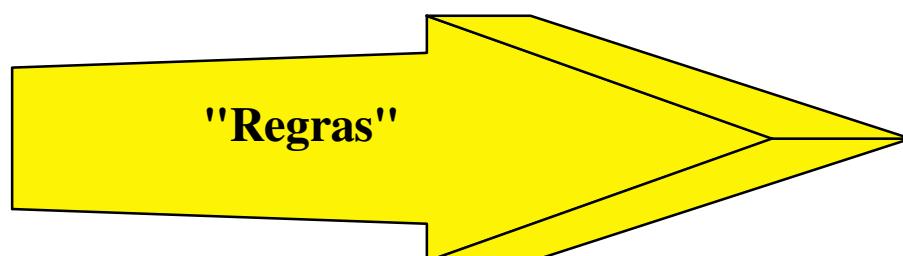


30



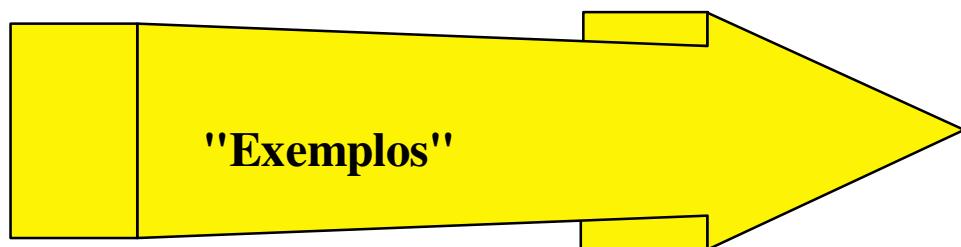
Aquisição de Conhecimentos

Conhecimentos Teóricos



Módulo Simbólico

Aquisição de Conhecimentos

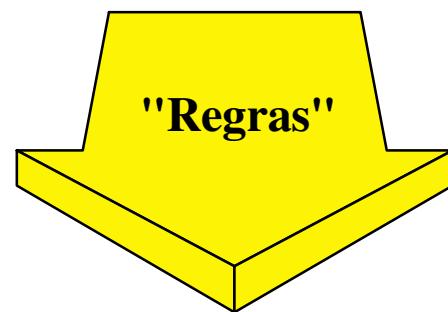


Módulo Conexionista

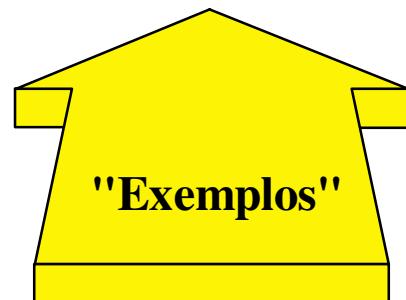
Conhecimentos Empíricos

Aquisição de Conhecimentos

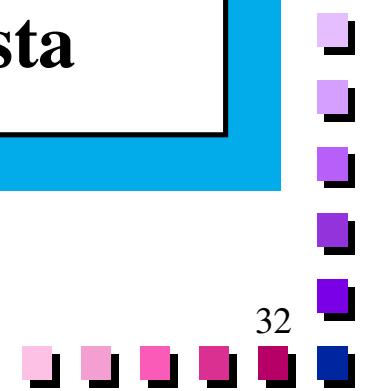
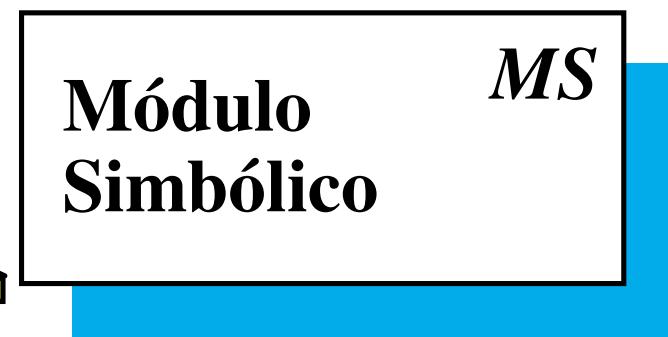
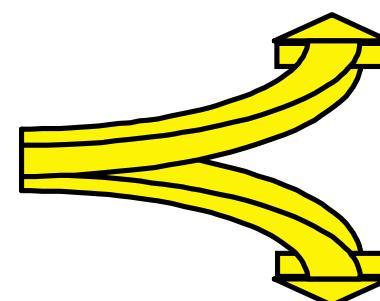
Conhecimentos Teóricos



Aquisição de Conhecimentos



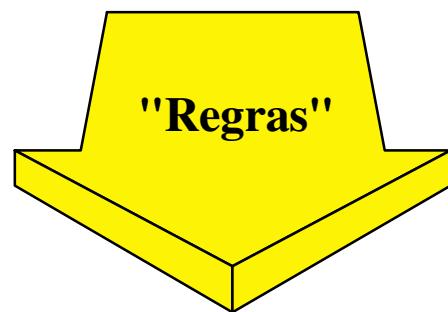
Conhecimentos Empíricos



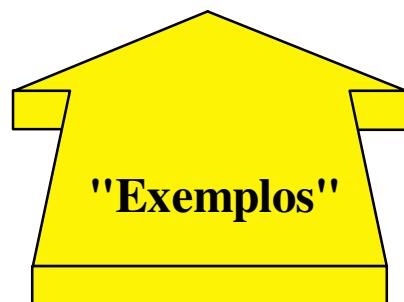
Aquisição de Conhecimentos

Sistema Híbrido Neuro-Simbólico

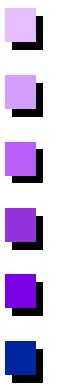
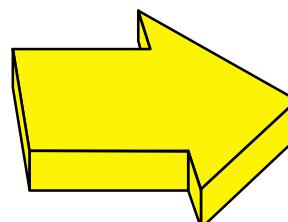
Conhecimentos Teóricos



Aquisição de Conhecimentos



Conhecimentos Empíricos



Sistemas Híbridos Neuro-Simbólicos

1. SYNHESYS - A. Giacometti

Symbolic and NEural Hybrid Expert SYstem Shell

Rede incremental baseada em protótipos - ARN2

Módulo simbólico de inferência com «Forward/Backward Chaining»

2. KBANN - G. Towell

Knowledge Based Artificial Neural Networks

Rede do tipo MLP com uso do algoritmo Back-Propagation

Compilação de regras em uma RNA, aprendizado e extração de regras

3. INSS - F. Osório

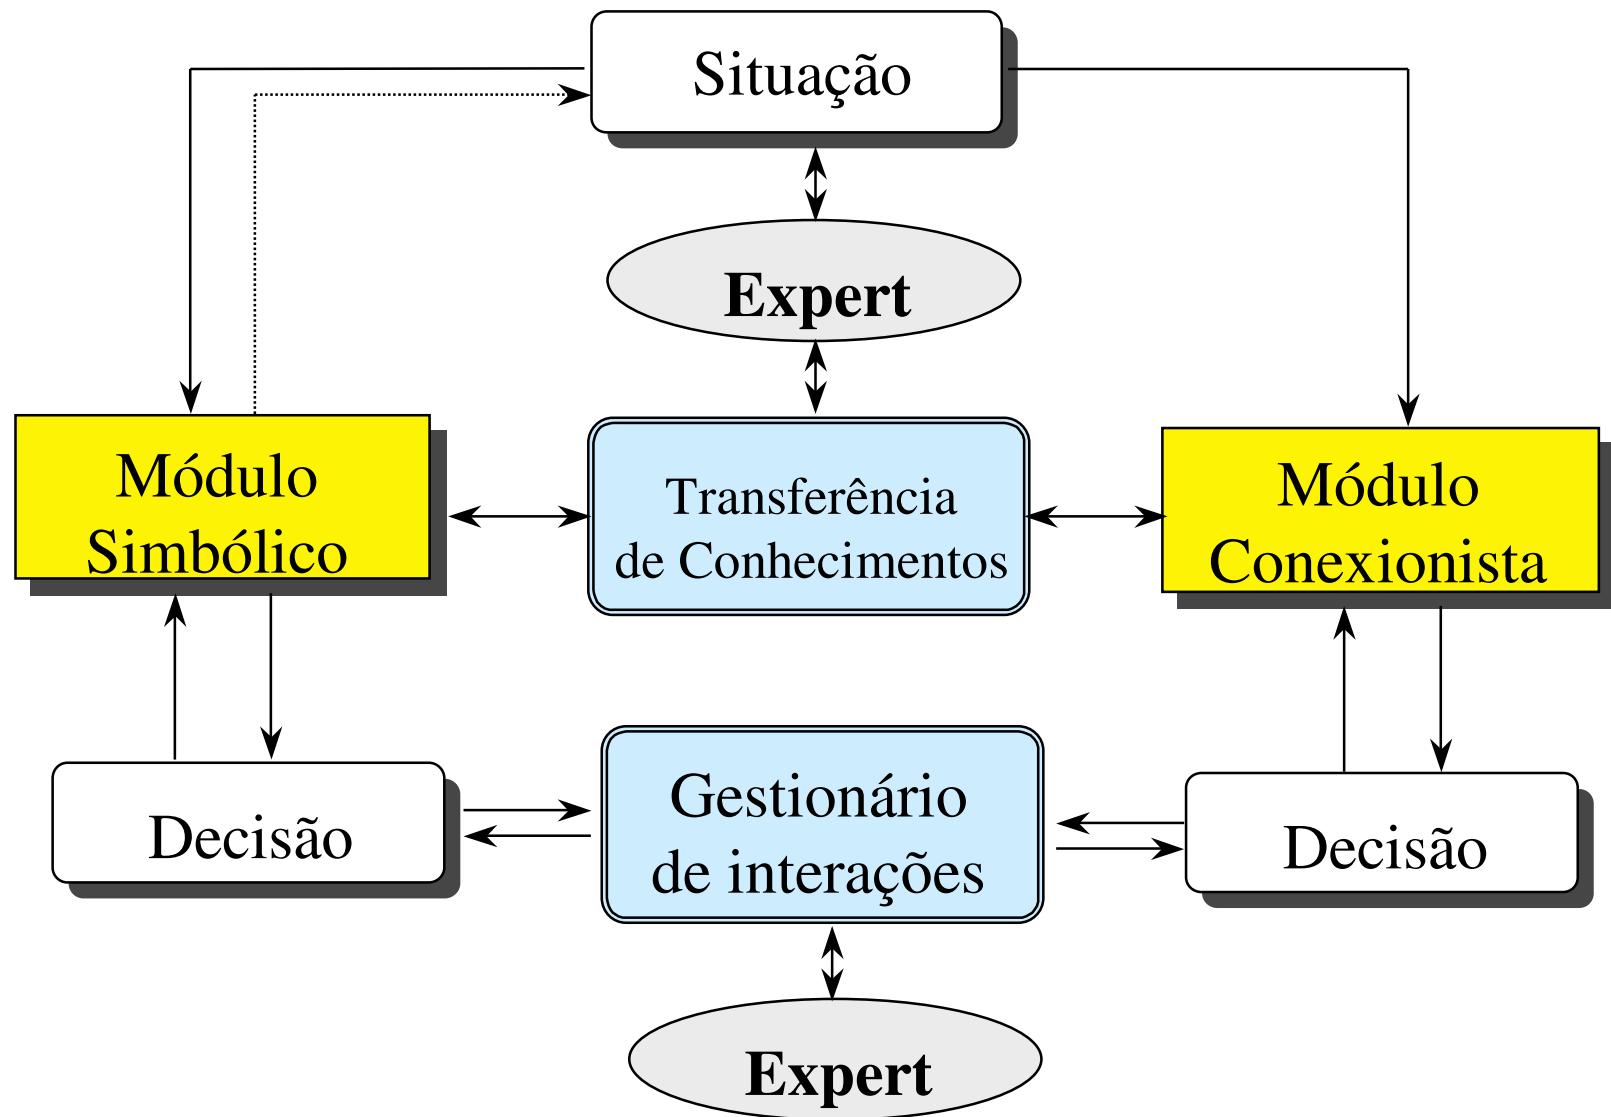
Incremental Neuro-Symbolic System

Rede incremental do tipo MLP com uso do algoritmo Cascade-Correlation

Compilação de regras, aprendizado, extração e validação

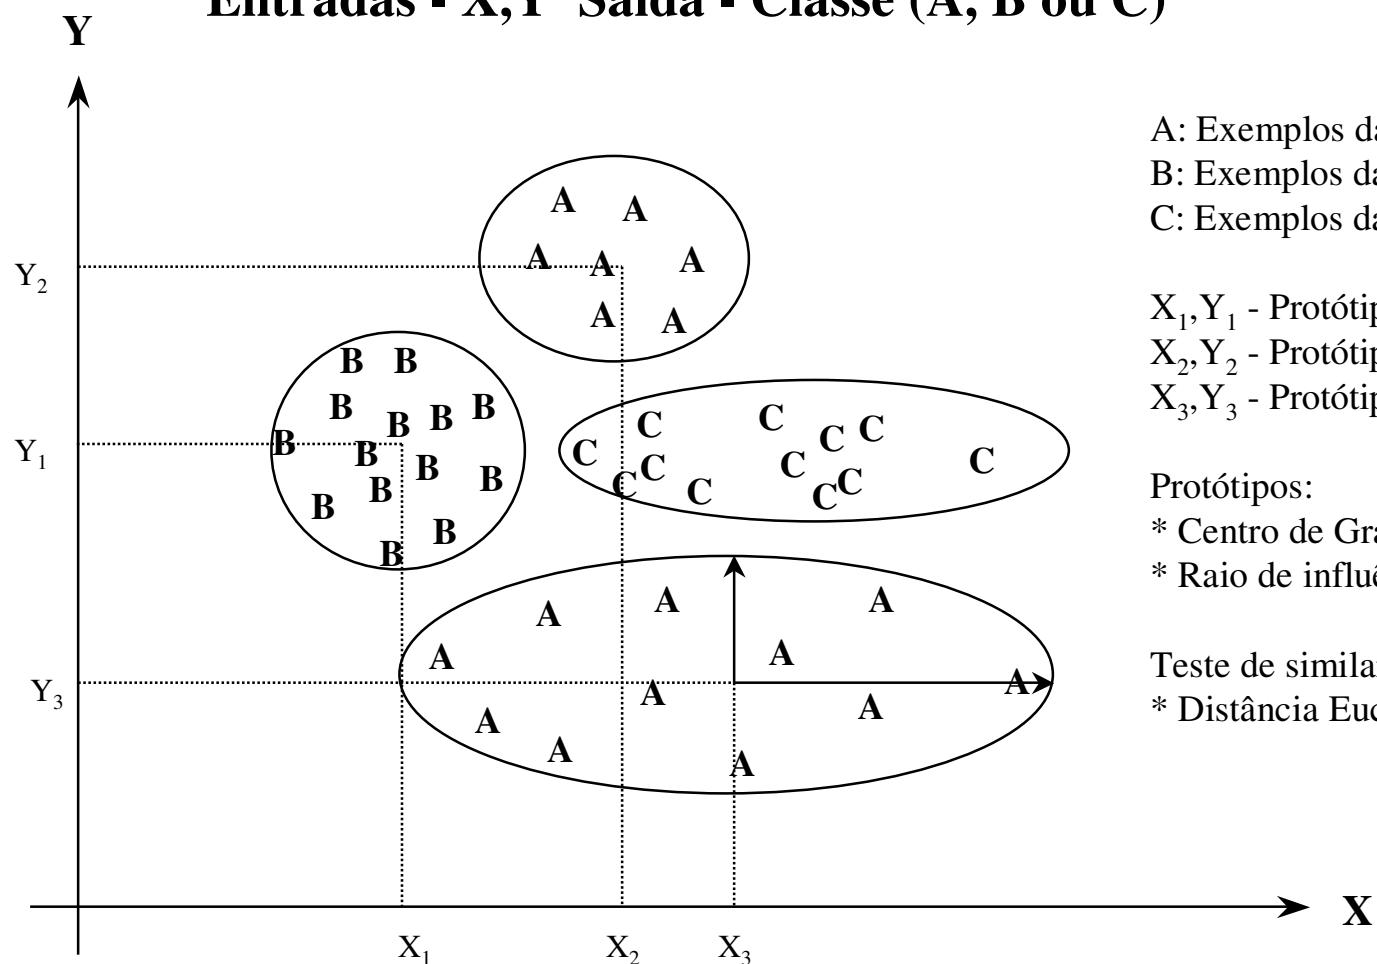


Sistema SYNHESYS



Sistema SYNHESYS

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



A: Exemplos da classe A
B: Exemplos da classe B
C: Exemplos da classe C

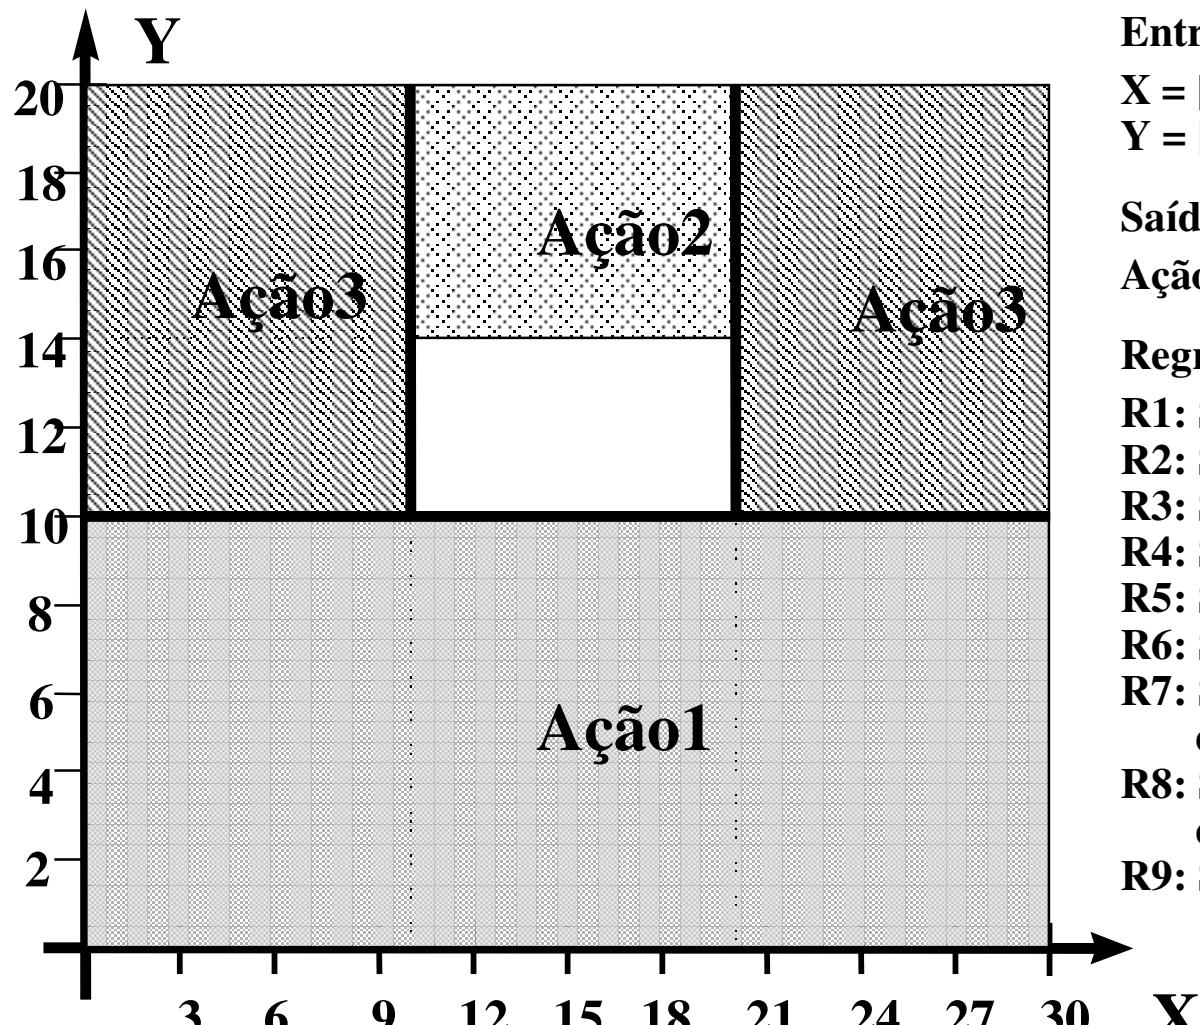
X_1, Y_1 - Protótipo da classe B
 X_2, Y_2 - Protótipo da classe A
 X_3, Y_3 - Protótipo da classe A

Protótipos:
* Centro de Gravidade (x,y)
* Raio de influência (rx,ry)

Teste de similaridade:
* Distância Euclidiana

Protótipos: Hiper-elipsoides / Hiper-Esferas

Sistema SYNHESYS



Protótipos: Hiper-retângulos

Entradas:

$X = [0..30]$

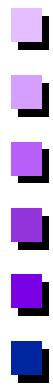
$Y = [0..20]$

Saídas (Ações):

Ação1 , Ação2 , Ação3

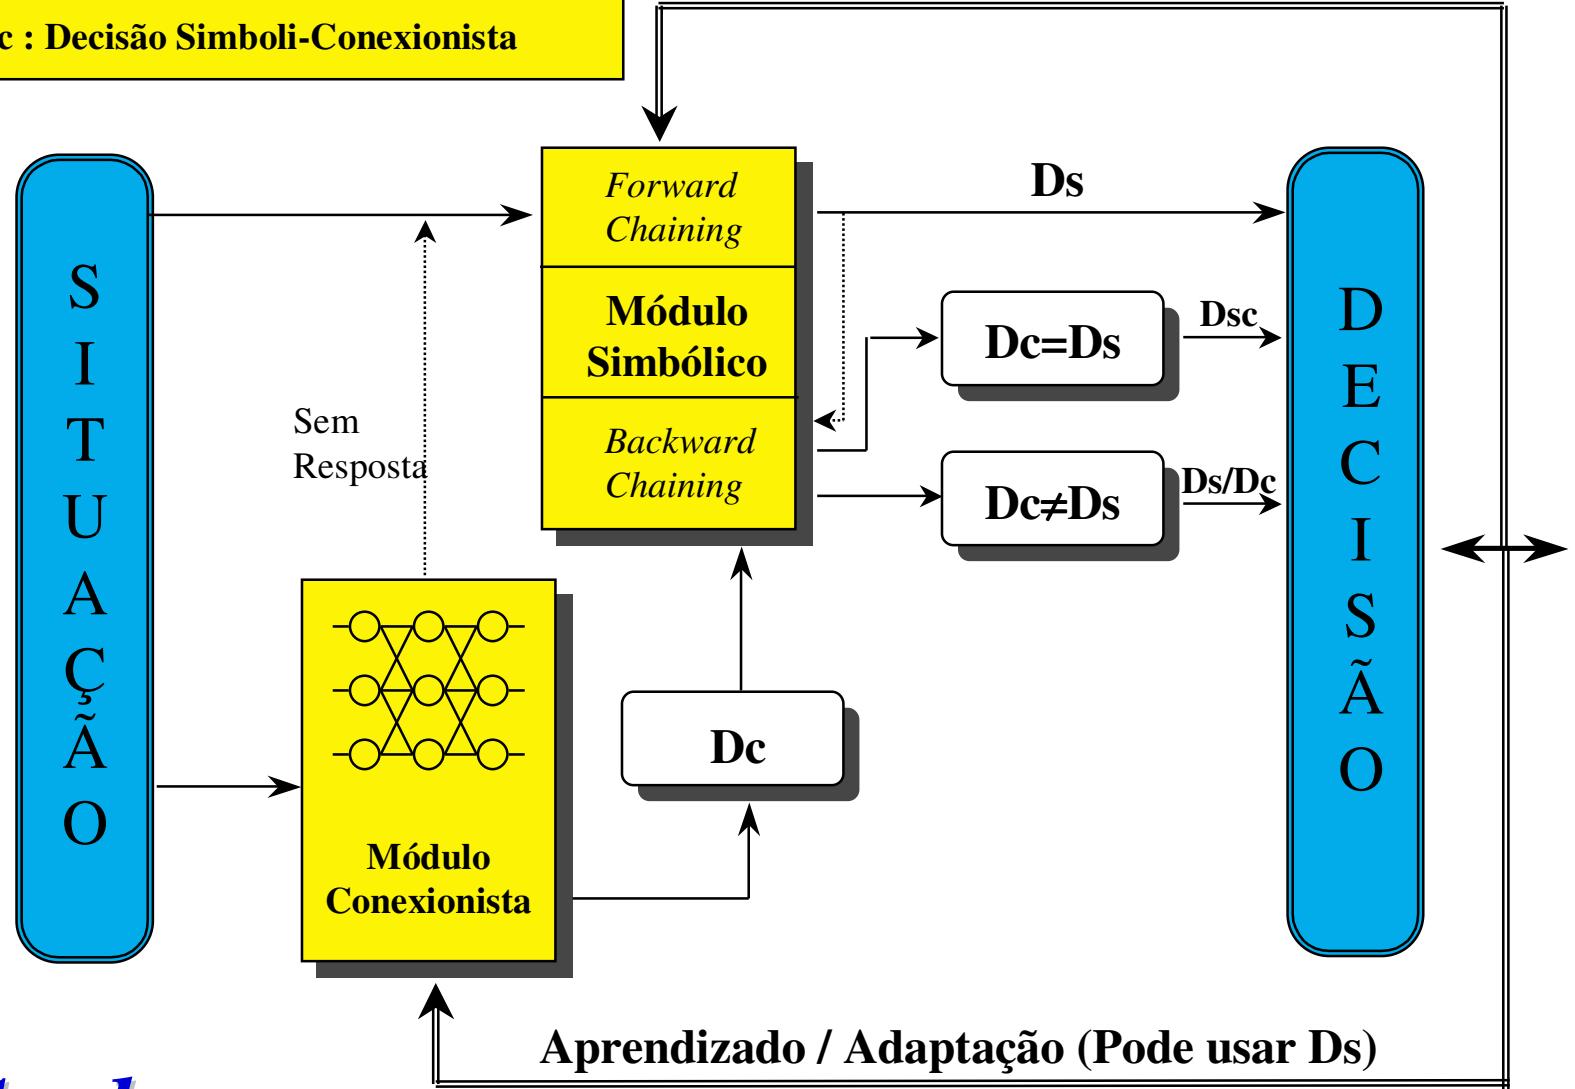
Regras:

- R1: Se $Y \text{ in } [0..10]$ então Y_Fraco
- R2: Se $Y \text{ in } [10..20]$ então Y_Forte
- R3: Se $X \text{ in } [0..10]$ então X_Fraco
- R4: Se $X \text{ in } [10..20]$ então X_Médio
- R5: Se $X \text{ in } [20..30]$ então X_Forte
- R6: Se Y_Fraco então Ação1
- R7: Se Y_Forte e X_Fraco então Ação3
- R8: Se Y_Forte e X_Forte então Ação3
- R9: Se $Y \text{ in } [14..20]$ e $X \text{ Médio}$ então Ação2



Ds : Decisão do Módulo Simbólico
Dc : Decisão do Módulo Conexionista
Dsc : Decisão Simboli-Conexionista

Apagar ou adicionar uma regra



Synthesys

Sistemas Híbridos Neuro-Simbólicos



1. SYNHESYS - A. Giacometti

Symbolic and NEural Hybrid Expert SYstem Shell

Rede incremental baseada em protótipos - ARN2

Módulo simbólico de inferência com «Forward/Backward Chaining»



2. KBANN - G. Towell

Knowledge Based Artificial Neural Networks

Rede do tipo MLP com uso do algoritmo Back-Propagation

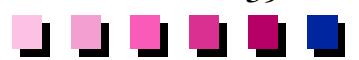
Compilação de regras em uma RNA, aprendizado e extração de regras

3. INSS - F. Osório

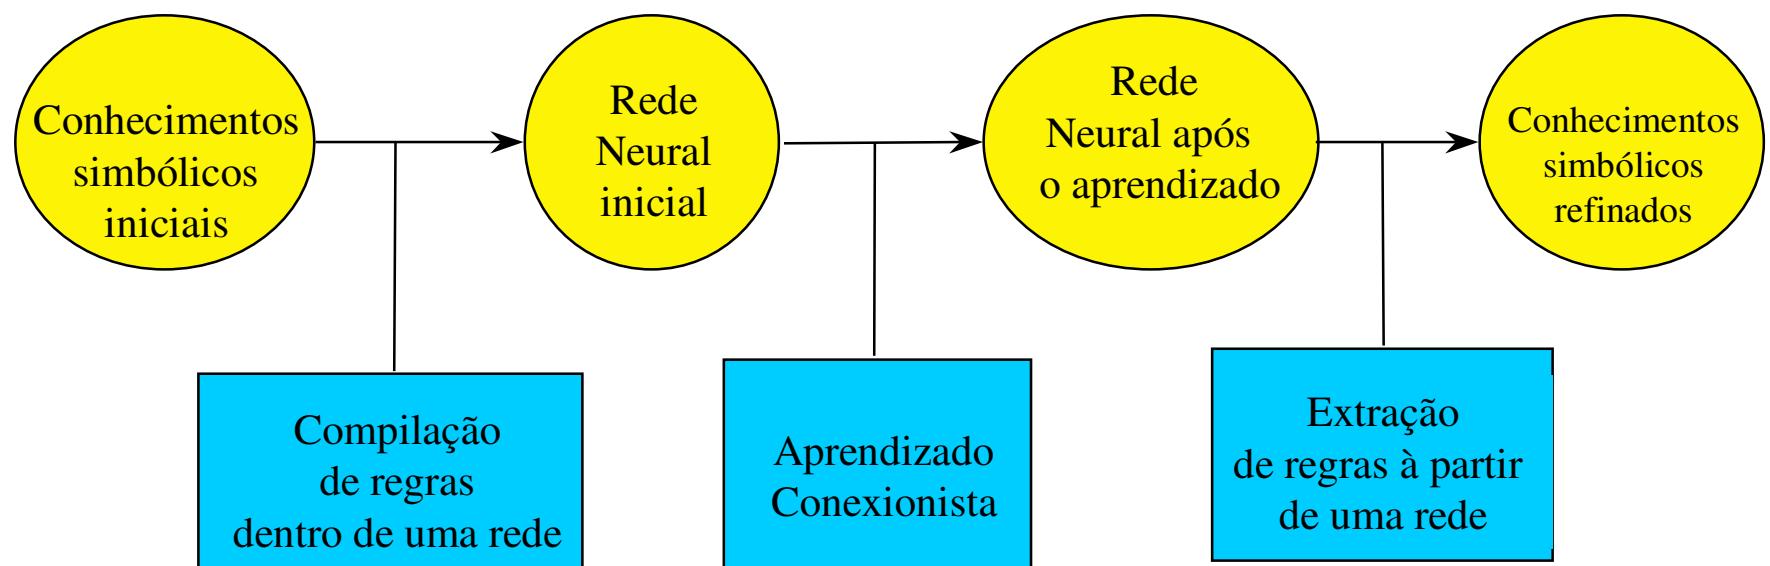
Incremental Neuro-Symbolic System

Rede incremental do tipo MLP com uso do algoritmo Cascade-Correlation

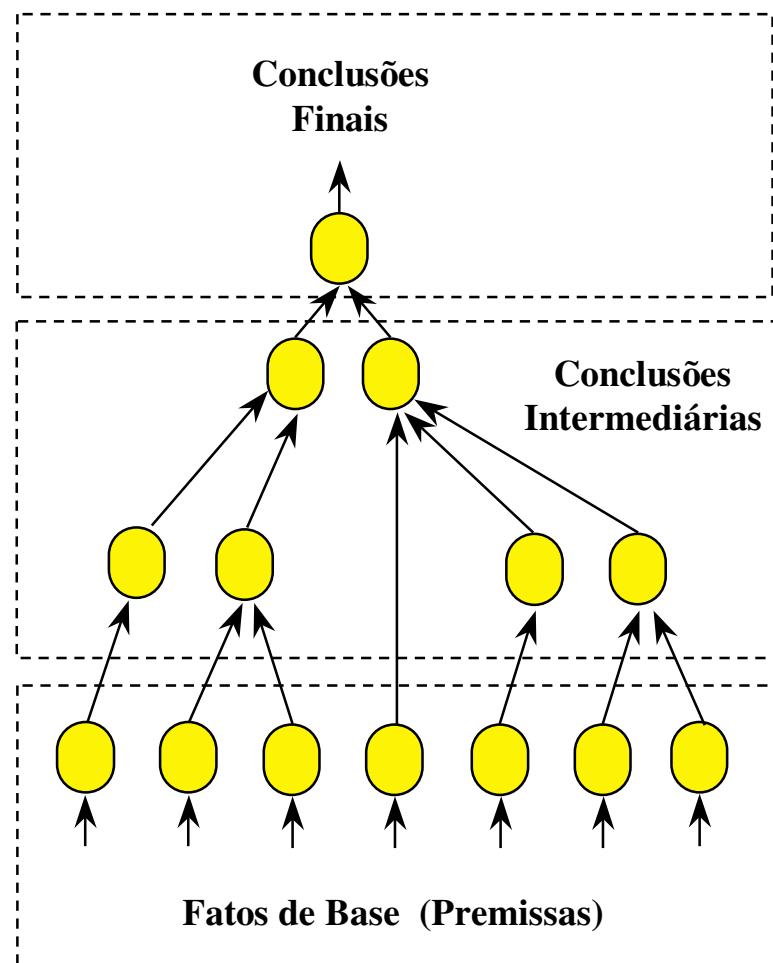
Compilação de regras, aprendizado, extração e validação



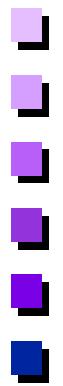
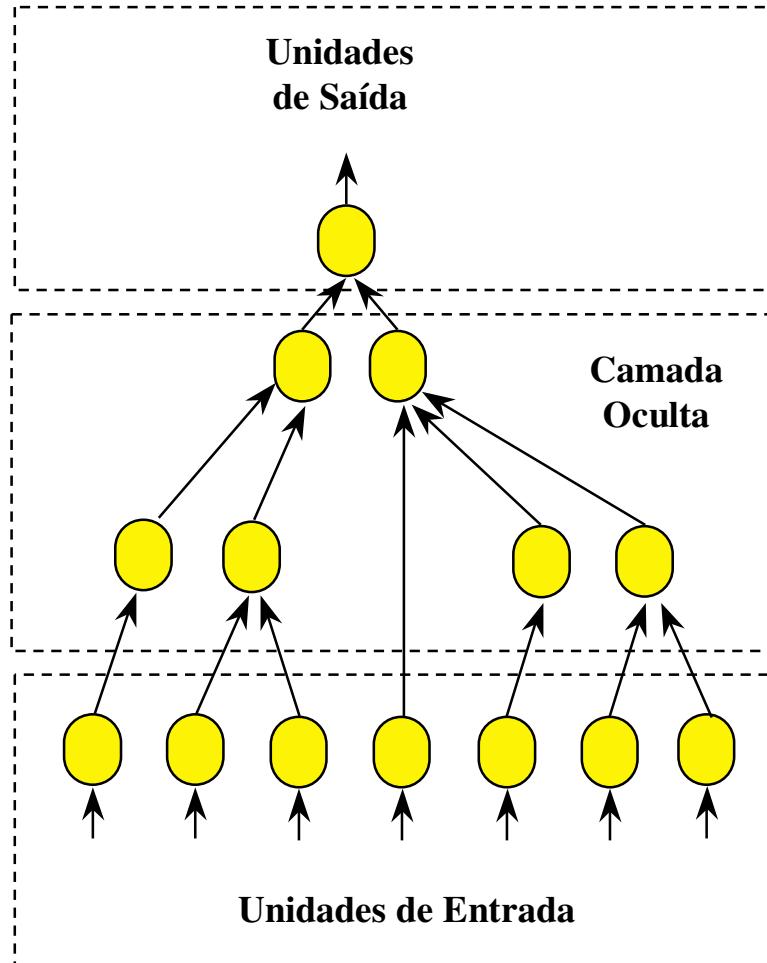
Sistema KBANN



Base de Conhecimentos Símbólicos



Rede Neural Artificial



Conhecimentos sobre um domínio de aplicação

Conhecimentos Teóricos

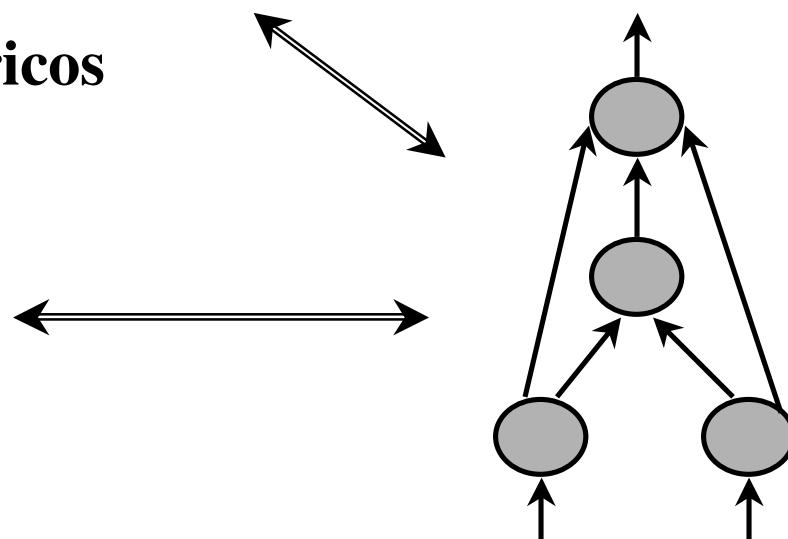
$$\text{XOR} = (\text{A Or B}) \text{ And Not} (\text{A And B})$$

ou

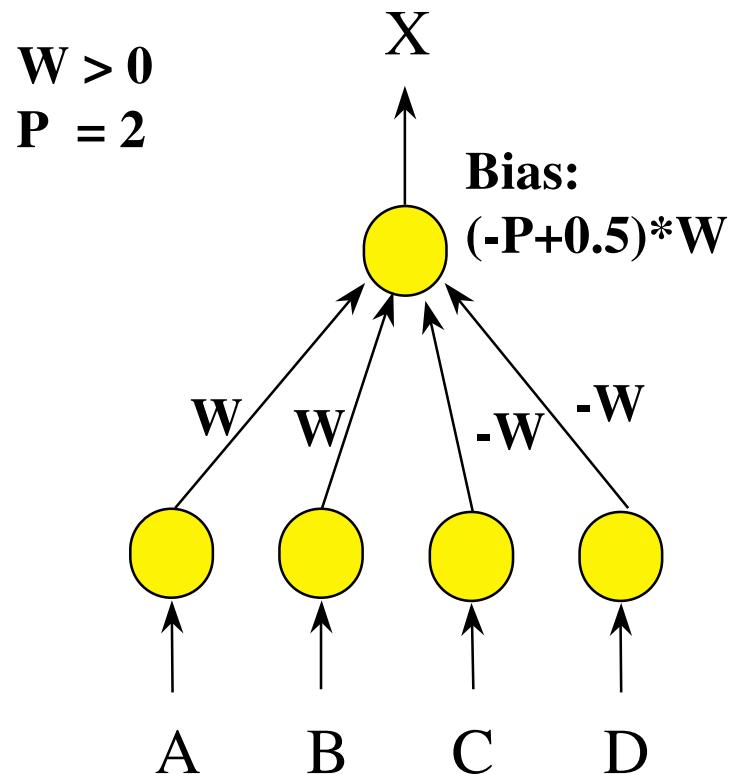
$$\text{XOR} = (\text{A And Not} (\text{B})) \text{ Or} (\text{Not} (\text{A}) \text{ And B})$$

Conhecimentos Empíricos

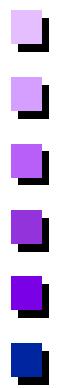
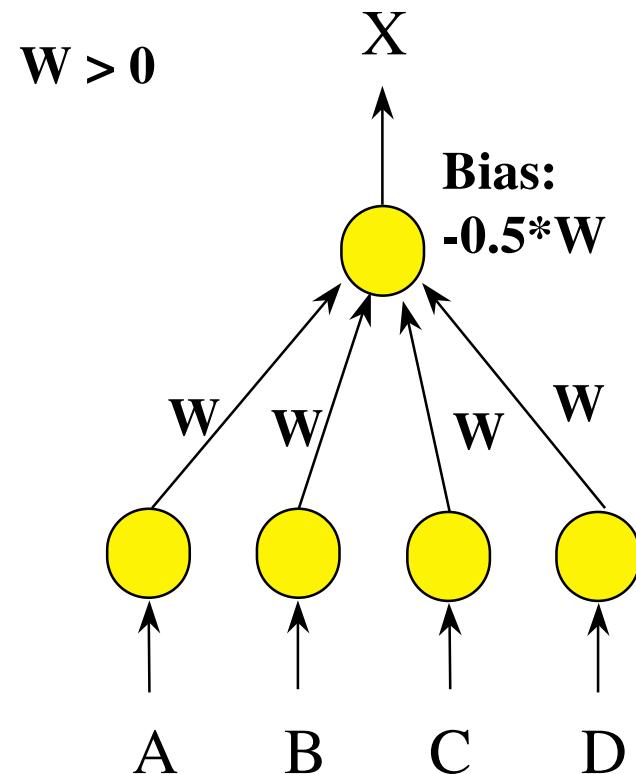
A	B	XOR
0	0	0
0	1	1
1	0	1
1	1	0



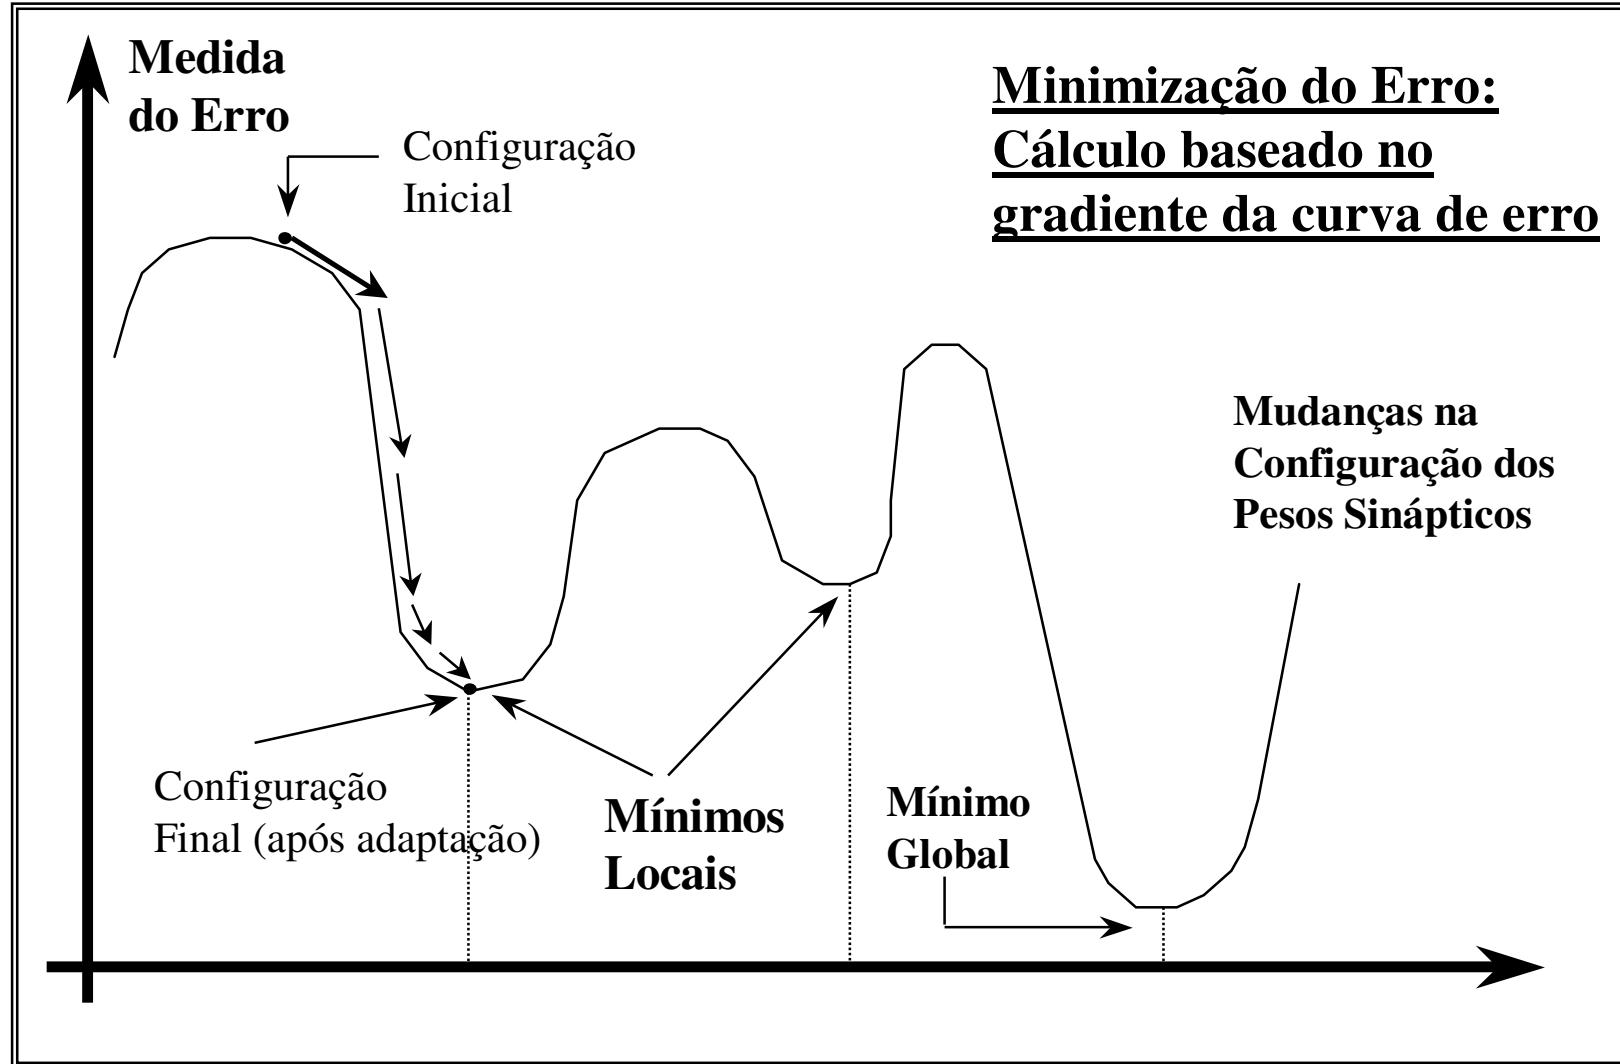
Operador E - Conjunção:
 $X :- A, B, \text{Not}(C), \text{Not}(D).$



Operador OU - Disjunção:
 $X :- A.$ $X :- B.$
 $X :- C.$ $X :- D.$

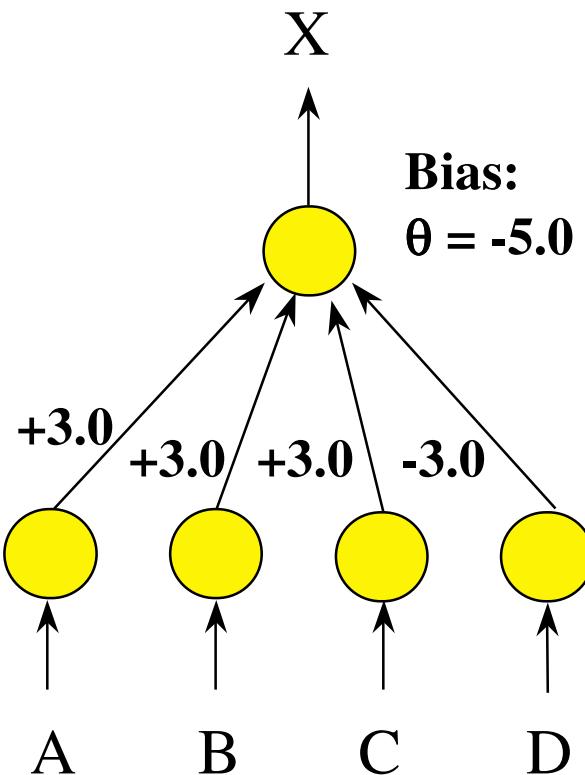


RNA : Multi-Layer Perceptron (MLP) - Algoritmo utilizado : Back-Propagation



KBANN - Aprendizado

Algoritmo SUBSET



$X := A, B, C.$
 $X := A, B, \text{not}(D).$
 $X := A, C, \text{not}(D).$
 $X := B, C, \text{not}(D).$

IF (A and B and C) or
(A and B and Not(D)) or
(A and C and Not(D)) or
(B and C and Not(D))
THEN X

KBANN - Extração de Regras

Sistema KBANN

Pontos fracos do Sistema KBANN



- Algoritmo de aprendizado pouco eficiente (Back-Propagation)
- Redes Neurais estáticas
- Bases de conhecimentos (regras e exemplos) com problemas significativos de incompletitude ou de incorreção
- Mudança do significado das unidades inseridas na rede neural
- Processo de extração de regras muito pesado (complexo)
- Extração de regras : implica na análise de todas as unidades da rede
- Utiliza unicamente regras simbólicas muito simples (compilação e extração)
 - Regras de produção IF/THEN - Representação de conhecimentos pobre
- Dificuldade para trabalhar com atributos quantitativos (variáveis contínuas)

Sistemas Híbridos Neuro-Simbólicos

✓ 1. SYNHESYS - A. Giacometti

Symbolic and NEural Hybrid Expert SYstem Shell

Rede incremental baseada em protótipos - ARN2

Módulo simbólico de inferência com «Forward/Backward Chaining»

✓ 2. KBANN - G. Towell

Knowledge Based Artificial Neural Networks

Rede do tipo MLP com uso do algoritmo Back-Propagation

Compilação de regras em uma RNA, aprendizado e extração de regras

→ 3. INSS - F. Osório

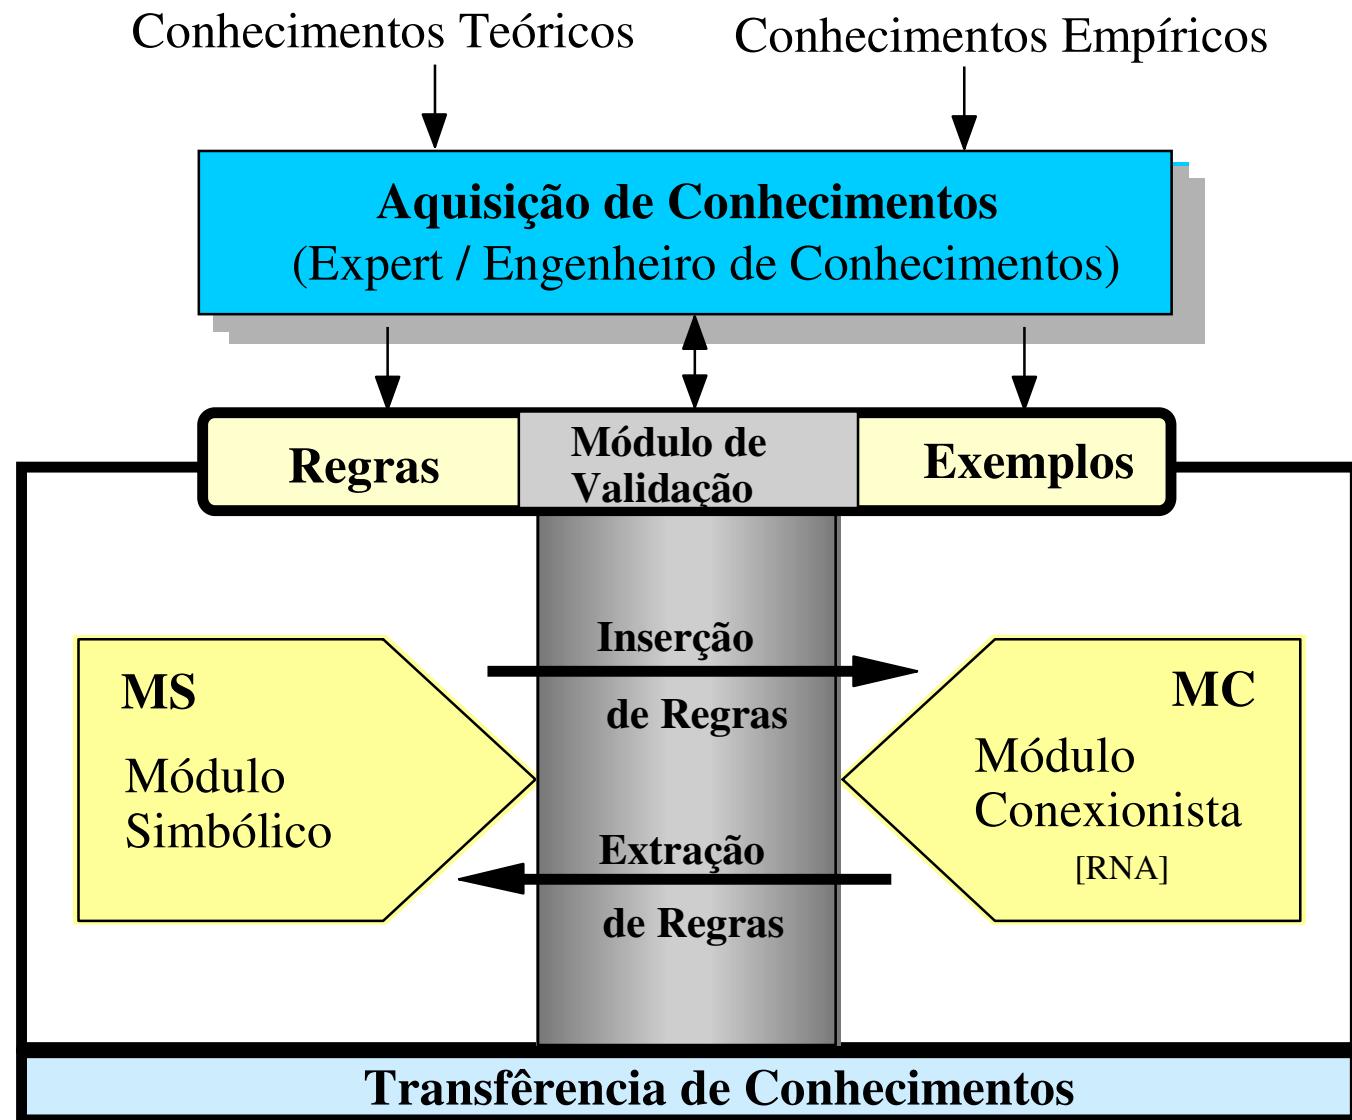
Incremental Neuro-Symbolic System

Rede incremental do tipo MLP com uso do algoritmo Cascade-Correlation

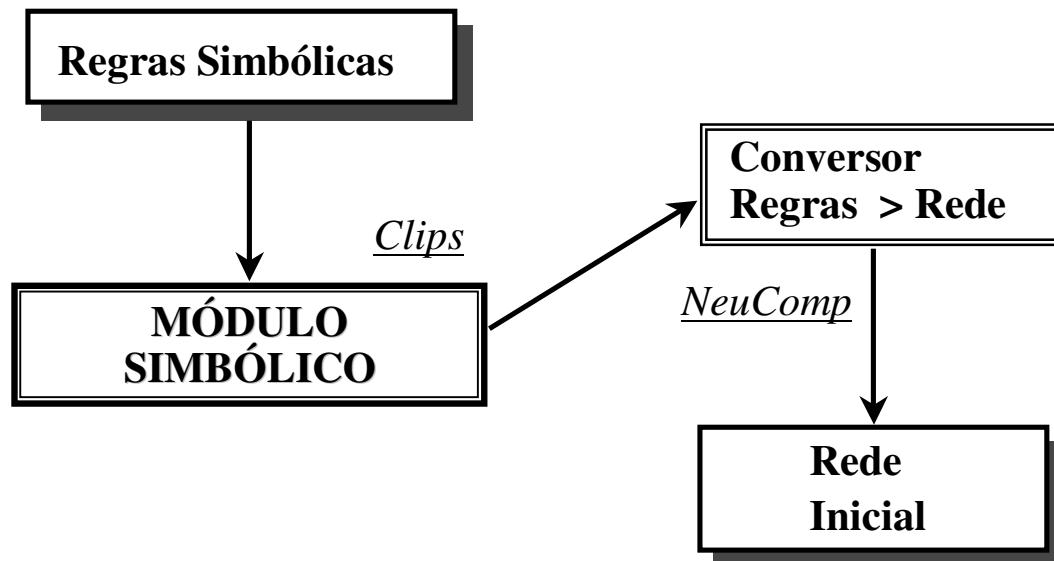
Compilação de regras, aprendizado, extração e validação



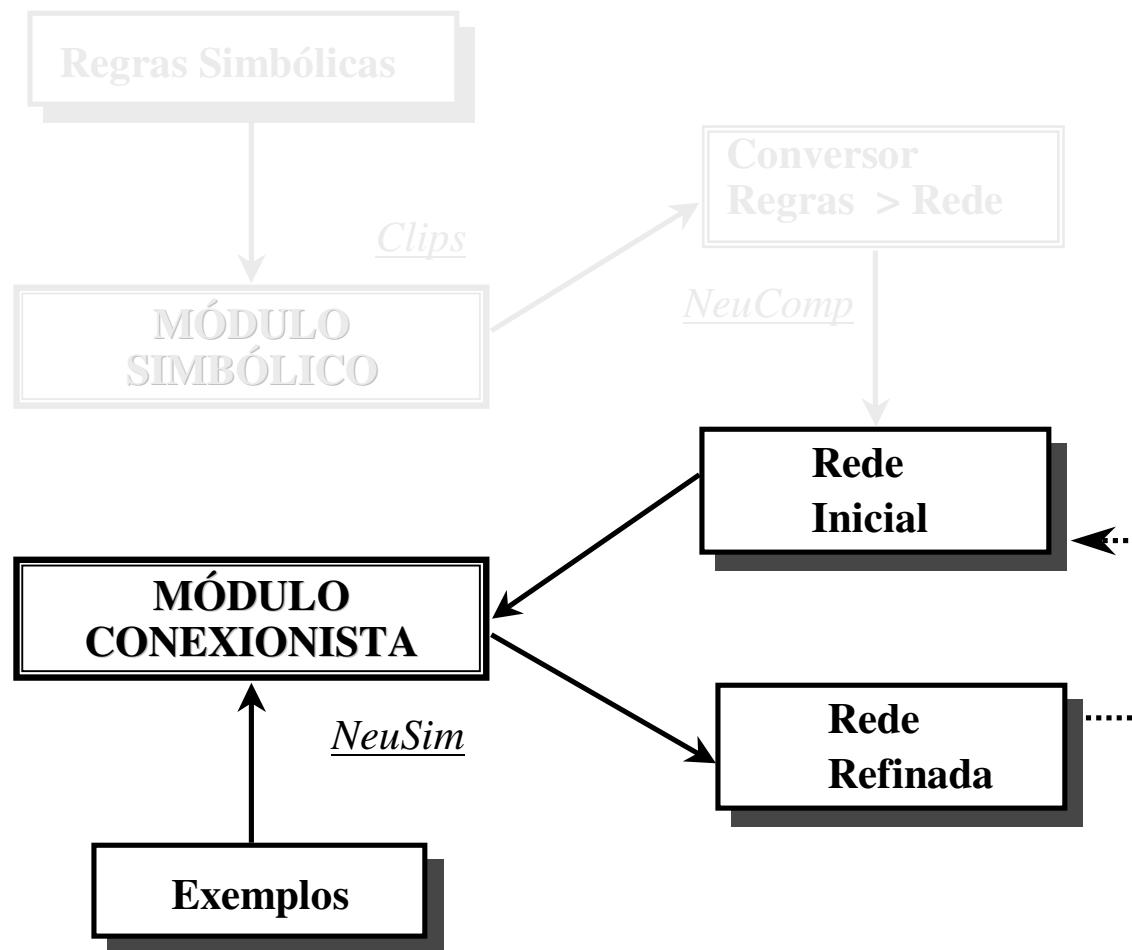
Sistema INSS



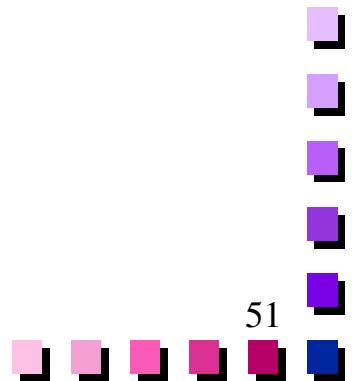
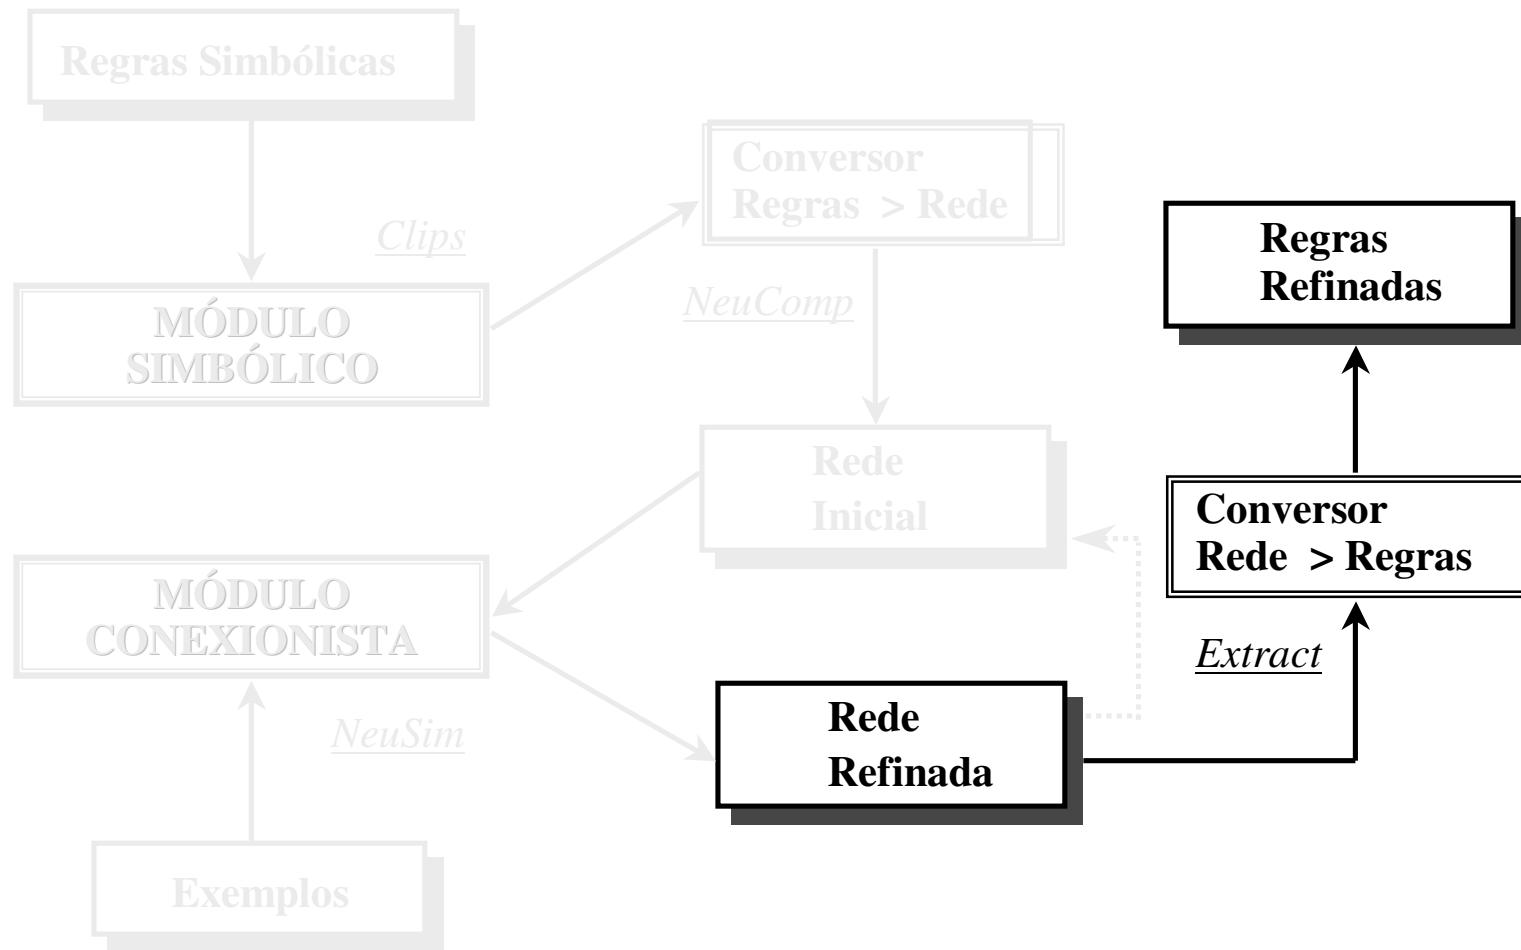
Sistema INSS



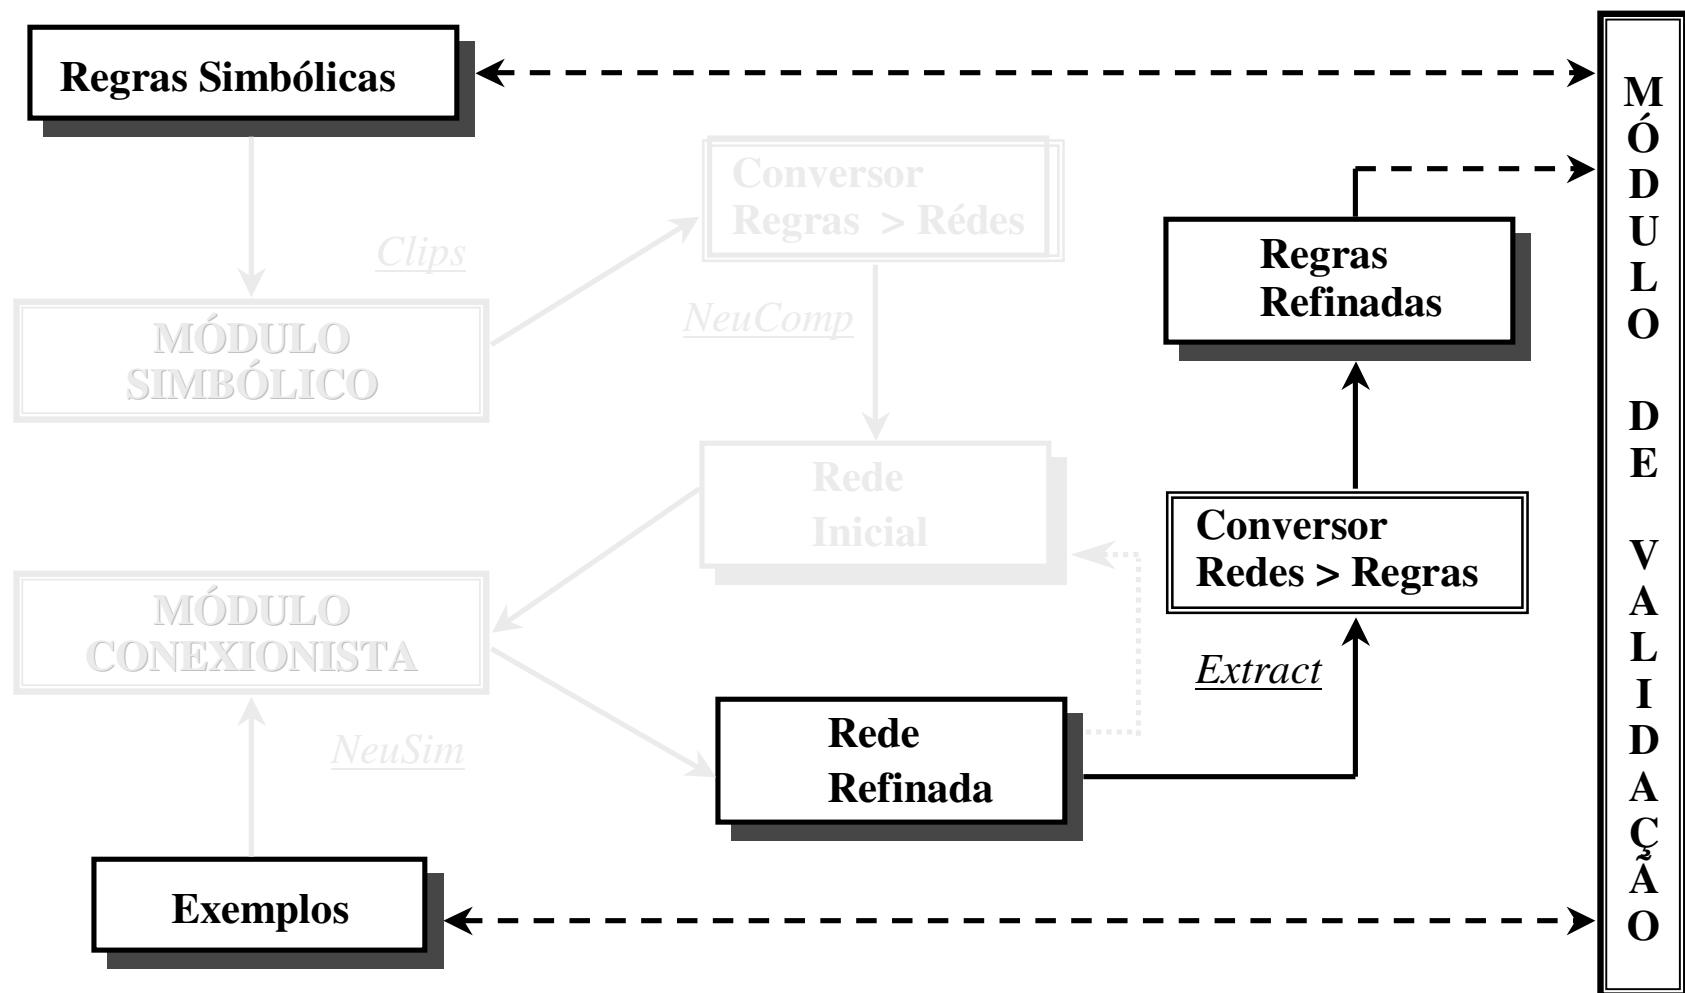
Sistema INSS



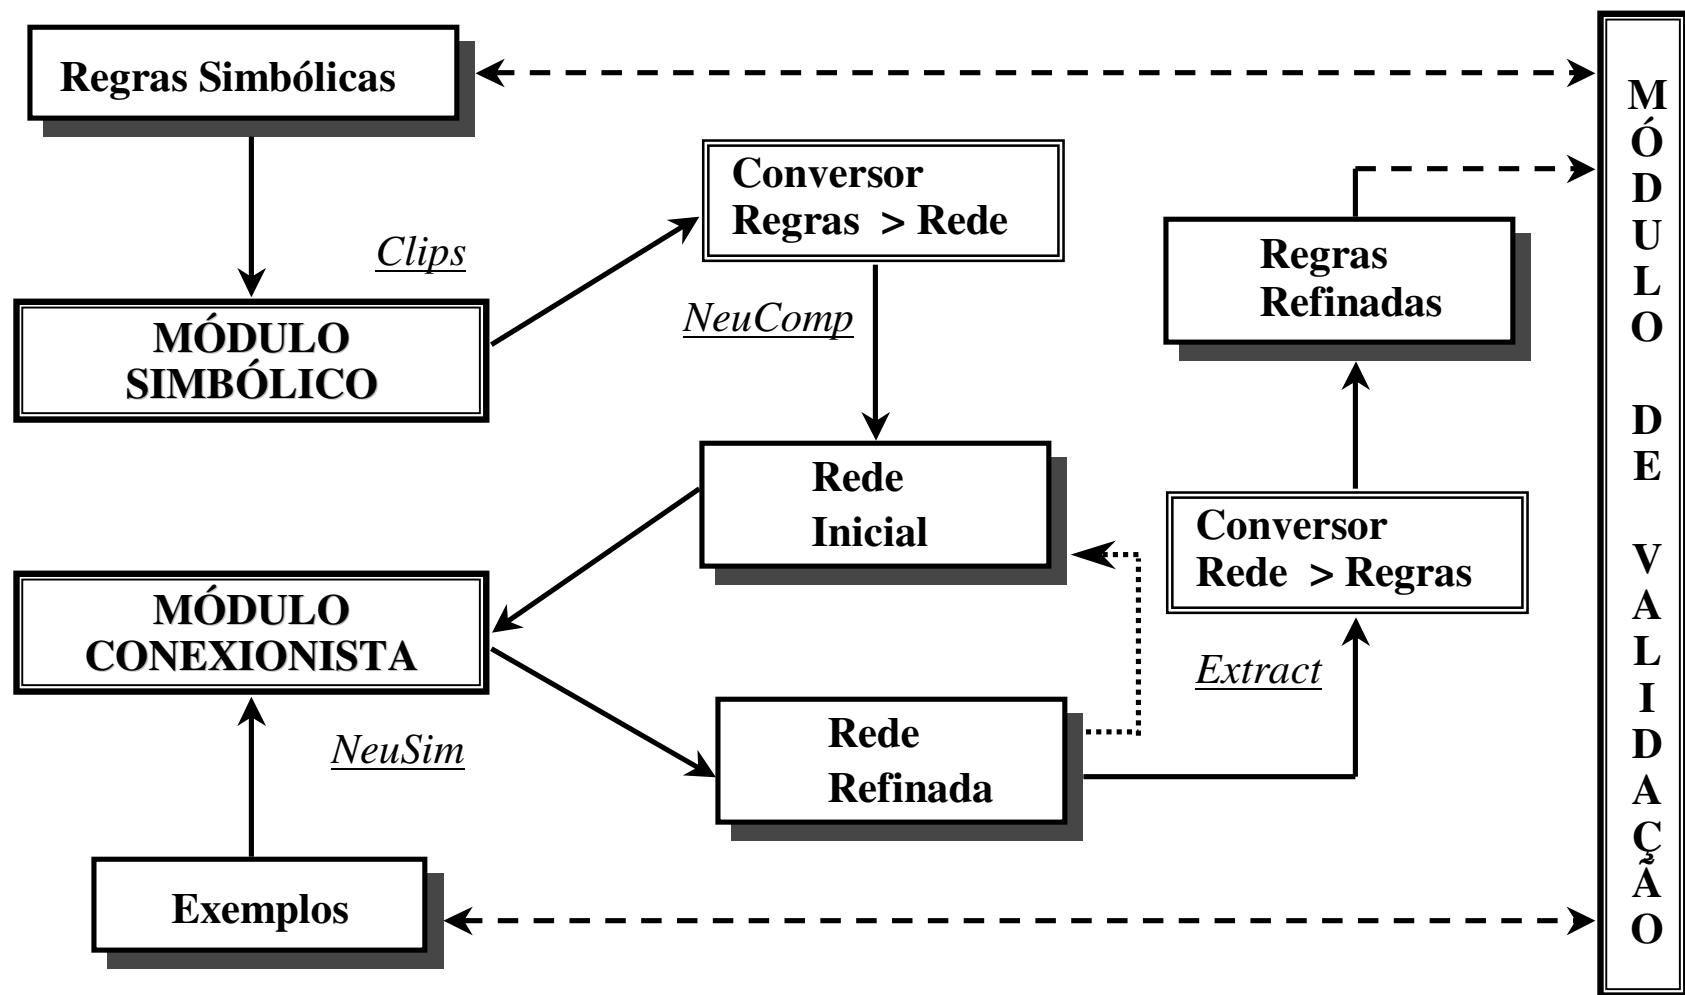
Sistema INSS



Sistema INSS



Sistema INSS



INSS : Compilação de Regras

\$Features:

A:binary;

B:binary.

\$End_Feat.

\$Rules:

A_OR_B <- A;

A_OR_B <- B;

A_AND_B <- A, B;

XOR <- A_OR_B, A_AND_B(false).

\$End_rules.

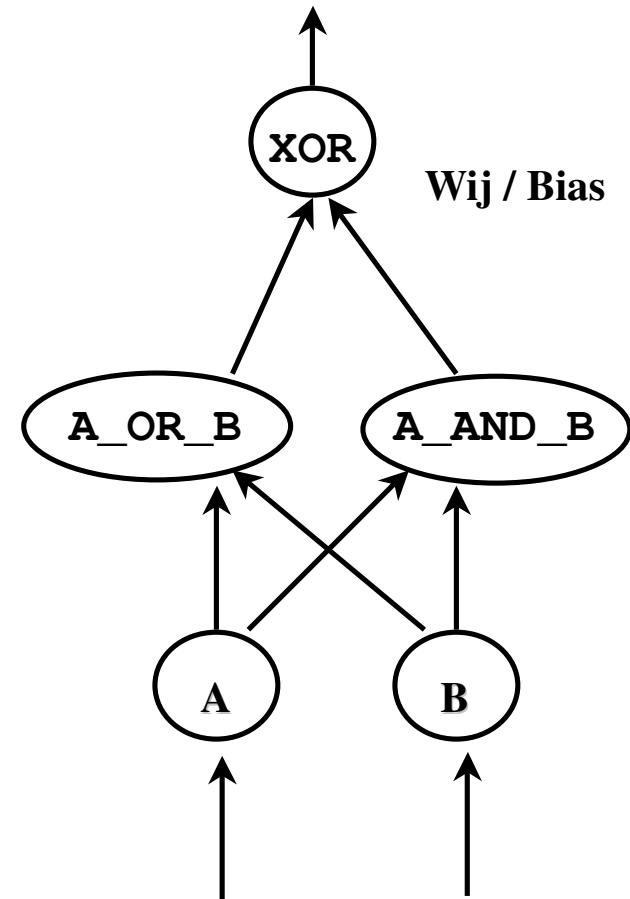
\$End.

%%

%% Exclusive Or - Lógica Booleana

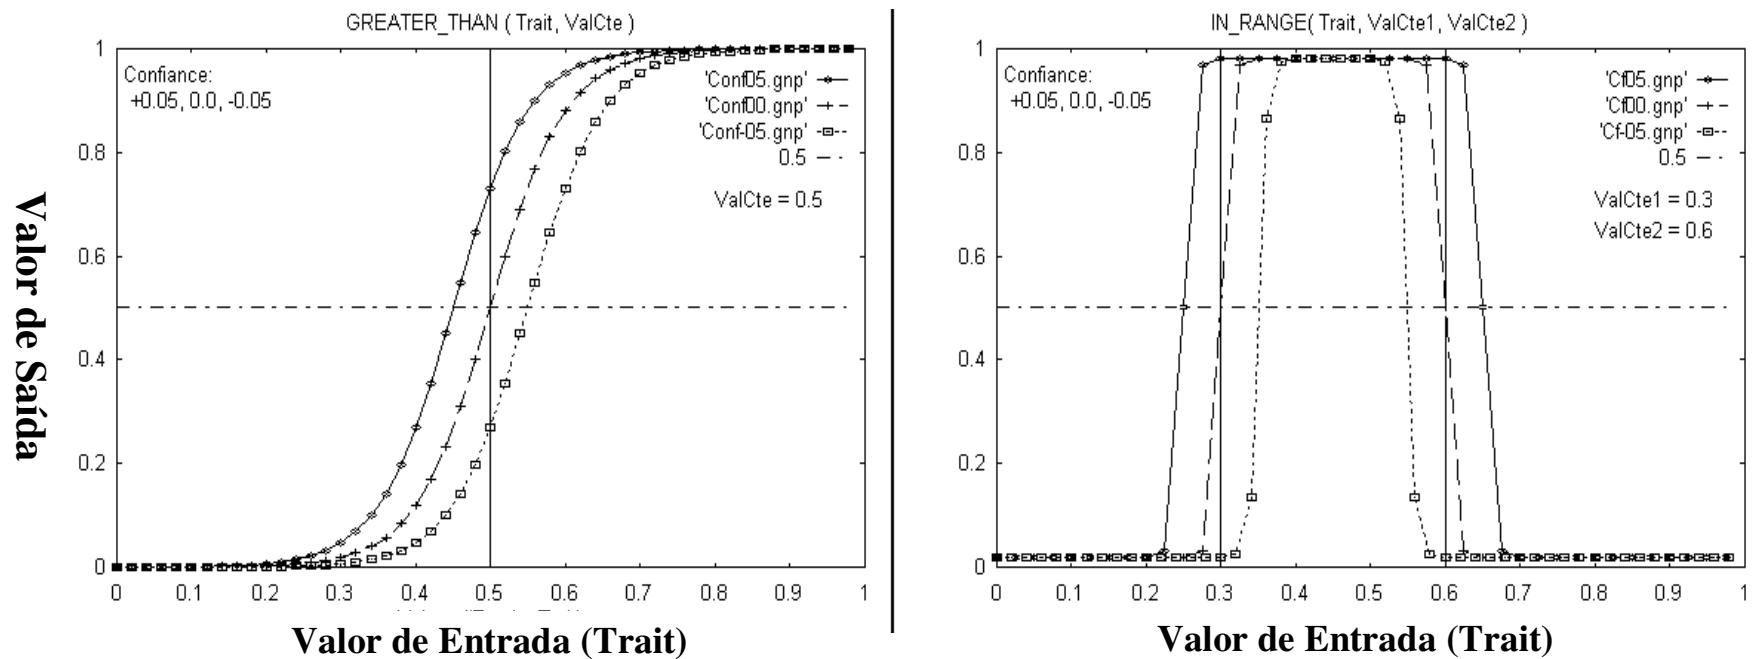
%% Xor = (A Or B) And Not (A And B)

%%



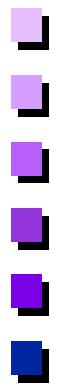
INSS: Compilação de Regras

Regras de ordem 0⁺



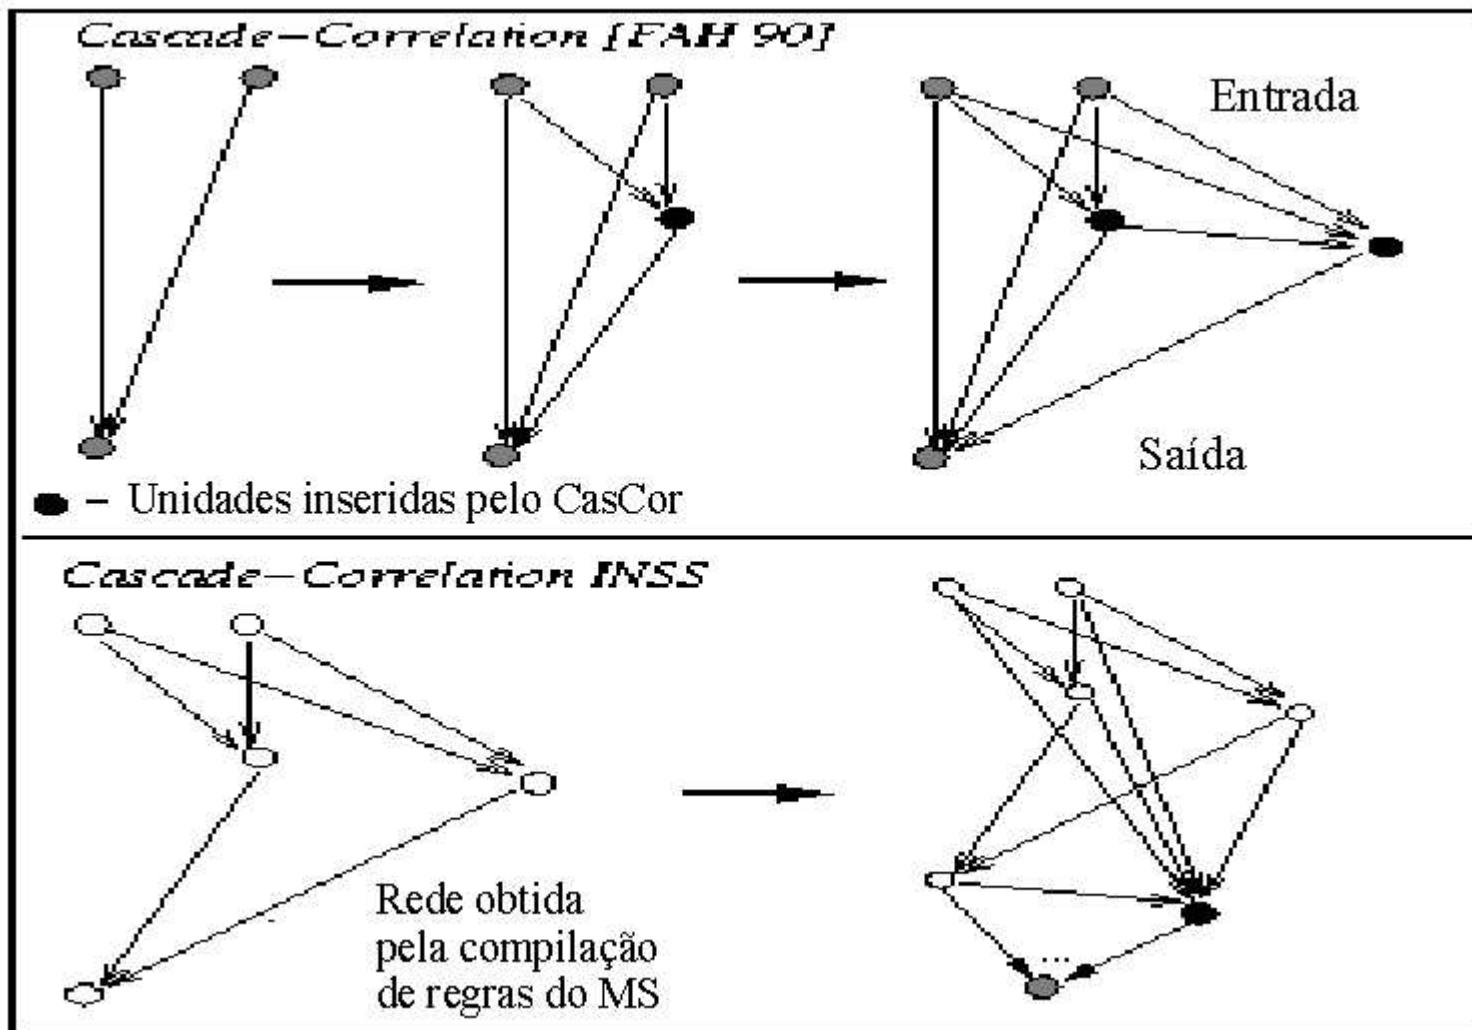
Greater_Than (Variável, Valor)
 Greater_Than (Variável, Variável)
 Less_Than (Variável, Valor)
 Less_Than (Variável, Variável)

In_Range (Variável, Min, Max)
 Equal (Variável, Valor)
 Equal (Variável, Variável)



INSS : Rede Neural Incremental

Algoritmo Cascade-Correlation (CasCor)



INSS e Rule_Out : Extração de Regras

Algoritmo de extração de regras : SUBSET [Towell]

RULE_OUT:

- * Extrair os novos conhecimentos adquiridos
- * Extrair as regras mais importantes
 - Seleção das unidades (neurônios) para a extração
 - Seleção das conexões para a extração
- * Em estudo : regras de ordem 0^+

Vantagens:

- * Extração incremental de conhecimentos
- * Validação dos conhecimentos adquiridos

INSS : Validação dos Conhecimentos

Conhecimentos Teóricos

R1 : If (A *Or* B) Then XOR=1

R2 : If *Not* (A *And* B) Then XOR=1

R3 : If (A *And* B) Then XOR=0

R4 : If *Not* (A) *And* *Not* (B) Then XOR=0

Conhecimentos Empíricos

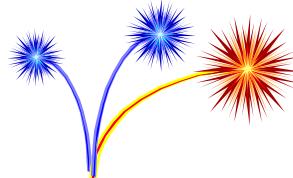
Ex.	A	B	XOR
E1	0	0	0
E2	0	1	1
E3	1	0	1
E4	1	1	1

Validação

- Incoerência entre R3 (Saída=0) e E4 (Saída=1)
- Não existem regras que satisfaçam E4

Sistema INSS

Pontos fortes do Sistema INSS

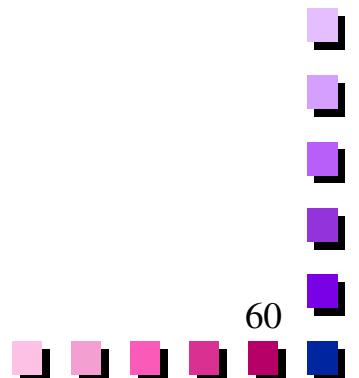


- **Algoritmo de aprendizado com um ótimo desempenho (Cascade-Correlation)**
- **Rede Neural do tipo incremental**
- **Permite o uso de conhecimentos (*regras e exemplos*) incompletos ou incoerentes**
- **Não modifica o significado das unidades inseridas na rede**
- **Processo incremental de extração de regras**
- **Extração de regras: análise parcial da rede (+ eficaz)**
- **Utiliza regras simbólicas de ordem 0 e 0⁺ (compilação)**
- **Trabalha com atributos quantitativos (variáveis contínuas) e qualitativos (variáveis discretas)**

Aprendizado de Máquinas Construtivo

Sistema INSS : Aplicações

- *Problemas Artificiais de Classificação* (Monk's Problems - S. Thrun)
- *Ajuda ao Diagnóstico Médico* - Comas Tóxicas (Projeto Esprit MIX)
- *Robótica Autônoma* (Robô móvel Khepera)
- *Problema da Balança* (Balance Scale Problem - T. Shultz)



Considerações Finais

- Conhecimentos : regras / exemplos - incompletos / incoerentes
- Algoritmos de aprendizado eficientes
- Redes Neurais do tipo incremental / Redes Recorrentes
- Compilação e extração de regras de alto nível
- Atributos quantitativos e qualitativos
- Validação dos conhecimentos adquiridos
- Evolução dos conhecimentos de forma continuada
- Aumento do poder de representação de conhecimentos
- Integração de múltiplos módulos: CBR, Fuzzy, GA, ...

*Sistema Híbrido Neuro-Simbólicos
Hybrid Machine Learning Tools*

Futuro



62

