



CT 720 Tópicos em Aprendizagem de Máquina e
Classificação de Padrões



1-Introdução

Conteúdo

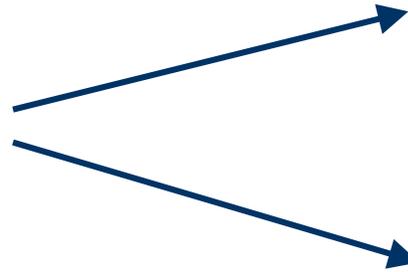
1. Percepção de máquina
2. Reconhecimento de padrão: exemplo
3. Sistemas de reconhecimento de padrões
4. Ciclo de projeto
5. Aprendizagem e adaptação
6. Conclusão

1-Percepção de máquina

- Construir máquinas para reconhecer padrões
 - reconhecimento de fala
 - identificação de impressão digital
 - reconhecimento de caracteres OCR
 - identificação de sequências DNA
- Compreensão de sistemas reconhecimento naturais
 - fala
 - visual

2-Reconhecimento de padrão: exemplo

- Seleção de peixes em uma correia transportadora de acordo com a espécie utilizando sensoriamento ótico



sea bass



salmon



Análise do problema

- Instalar uma câmera, capturar imagens e extrair características
 - comprimento
 - luminosidade
 - largura
 - número e forma das nadadeiras
 - posição da boca
- Conjunto de atributos a ser explorado pelo classificador

■ Modelos

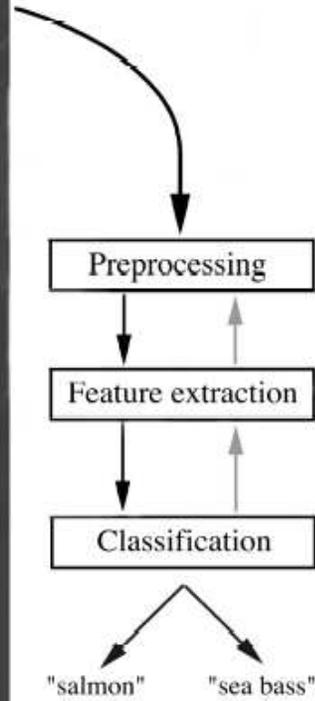
- descrições matemática de objetos
- objetos *salmon* \neq *sea bass*
- caracterizados por \neq modelos

■ Pré-Processamento

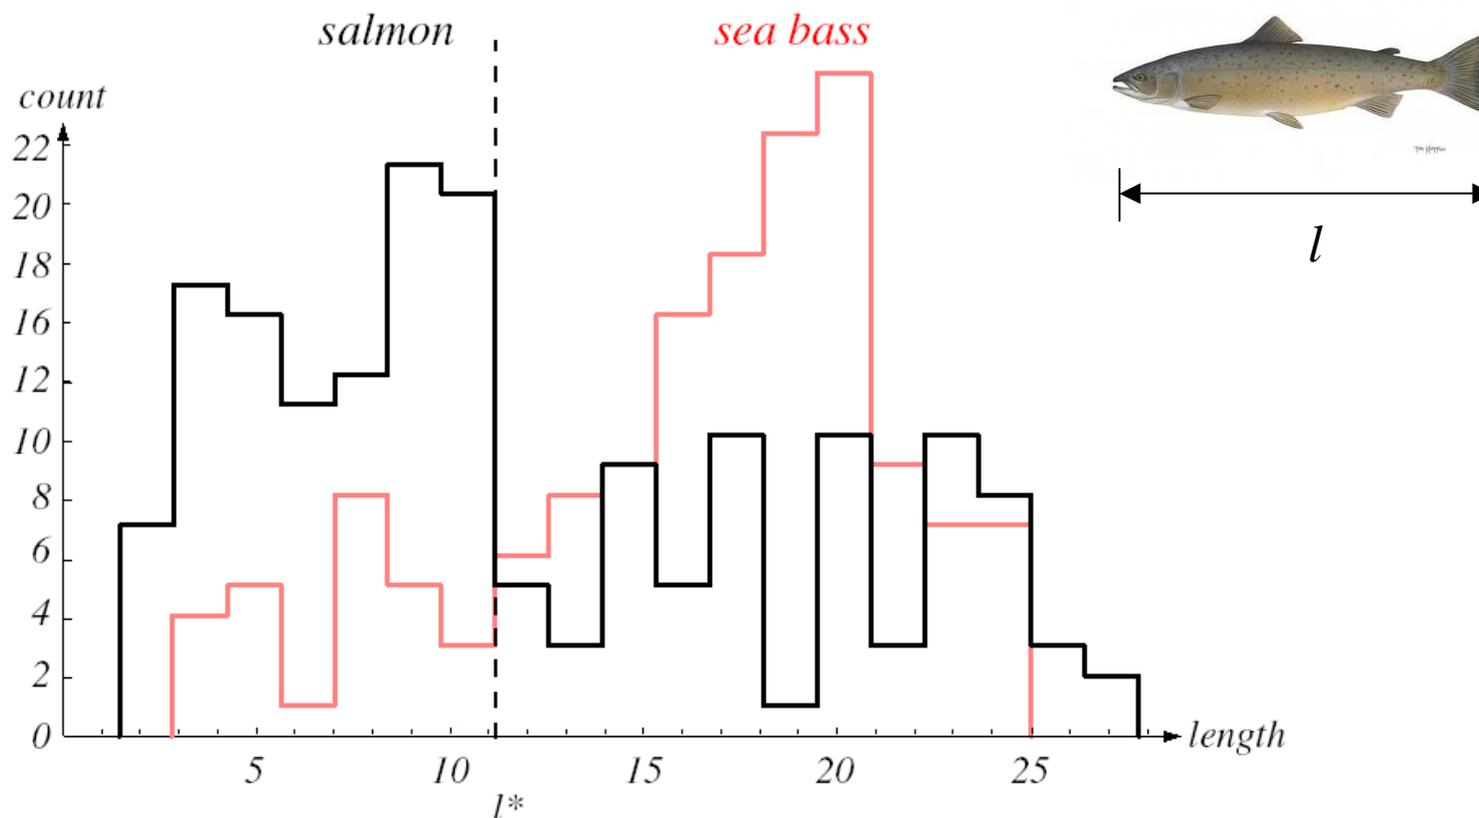
- segmentação para para isolar objetos da imagem
- informação de objetos enviadas para extrator de características

■ Extração de características (atributos)

- reduz quantidade de dados medindo certas características

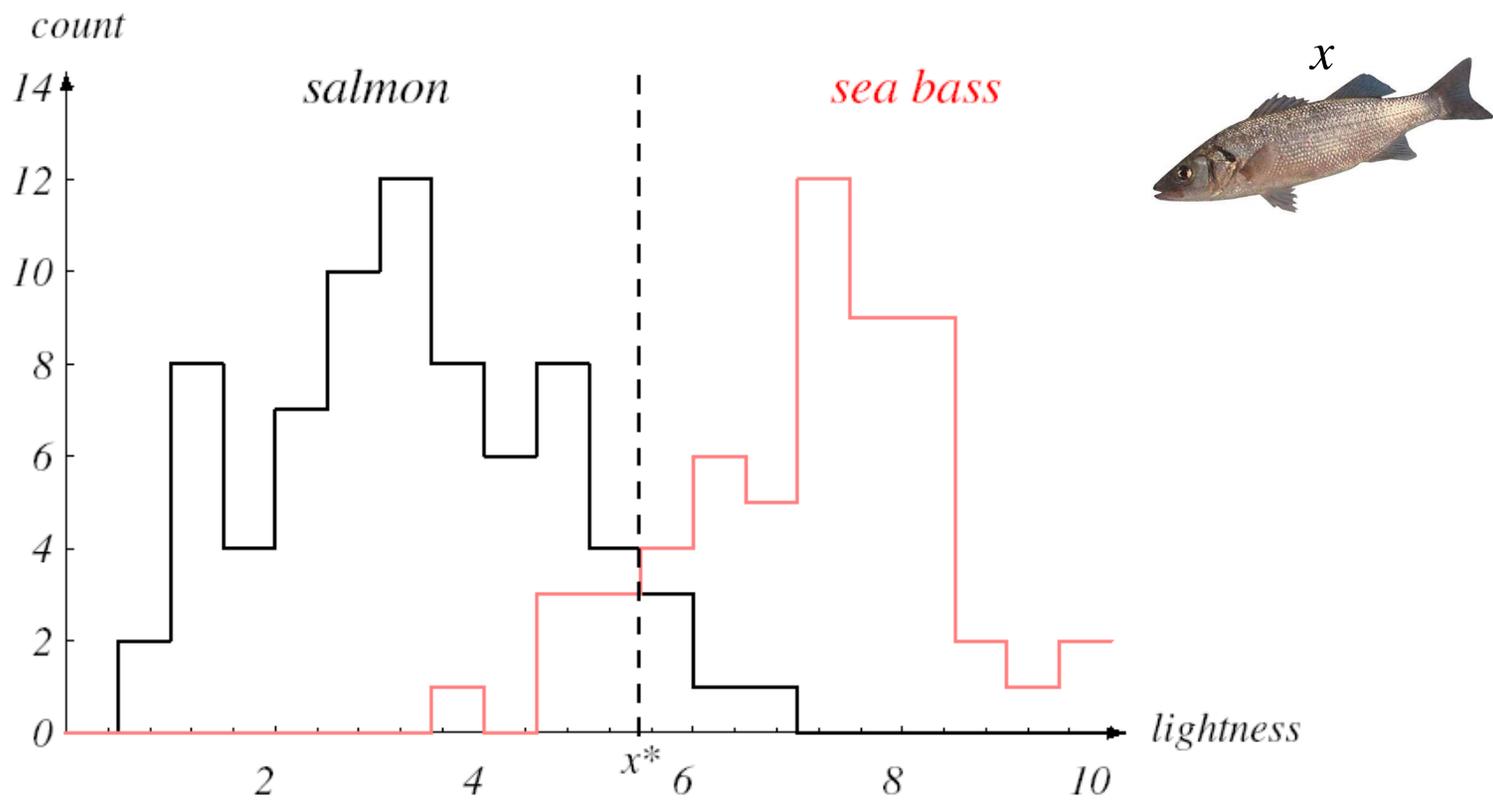


- Classificação selecionando o **comprimento** como atributo



- Isoladamente o **comprimento** é uma característica pobre

- Classificação selecionando a **luminosidade** como atributo



- Limiar de decisão e custo
 - valores menores de luminosidade para o limiar de decisão
 - minimizar custo
 - reduz número de *sea bass* classificados como *salmon*

- Tarefa da teoria de decisão

- Limiar ótimo x^* pode produzir resultado insatisfatório

- Seleccionando a **luminosidade** e **largura** como atributos



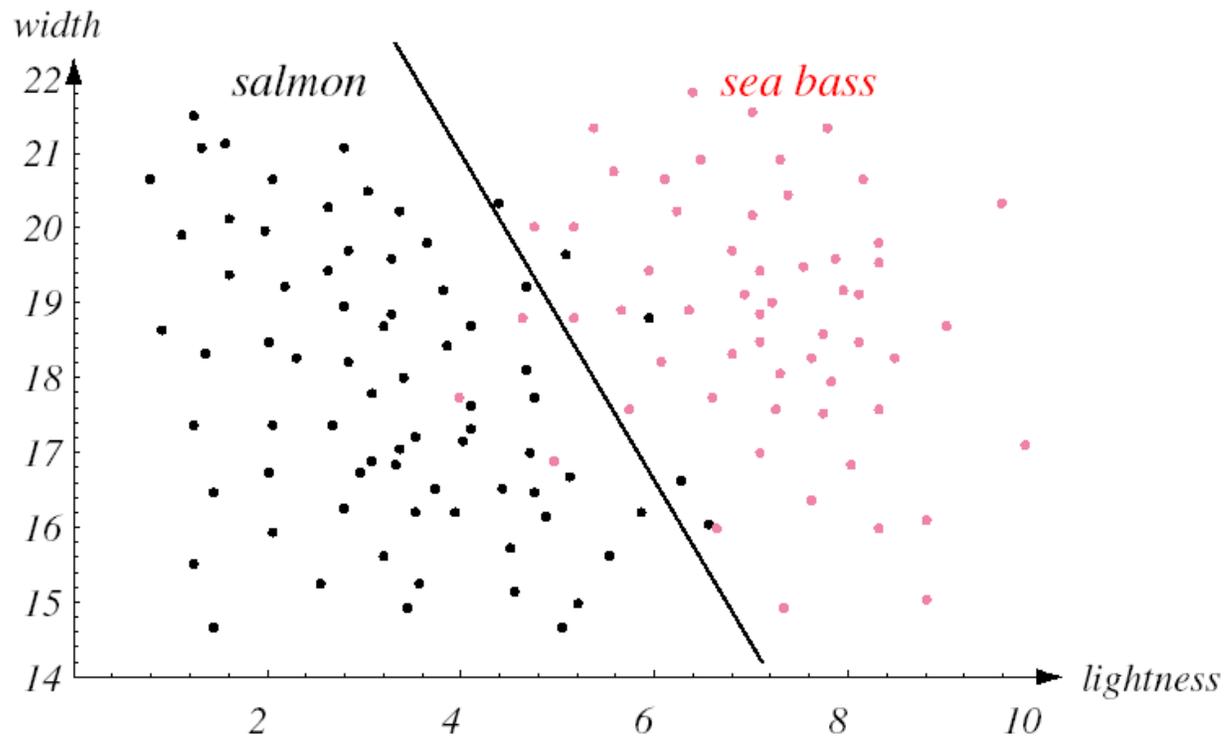
$$Peixe \equiv \mathbf{x} = \begin{pmatrix} x_1 \\ x_2 \end{pmatrix}$$

$x_1 =$ luminosidade

$x_2 =$ largura

$\mathbf{x} =$ vetor de atributos \in espaço de atributos

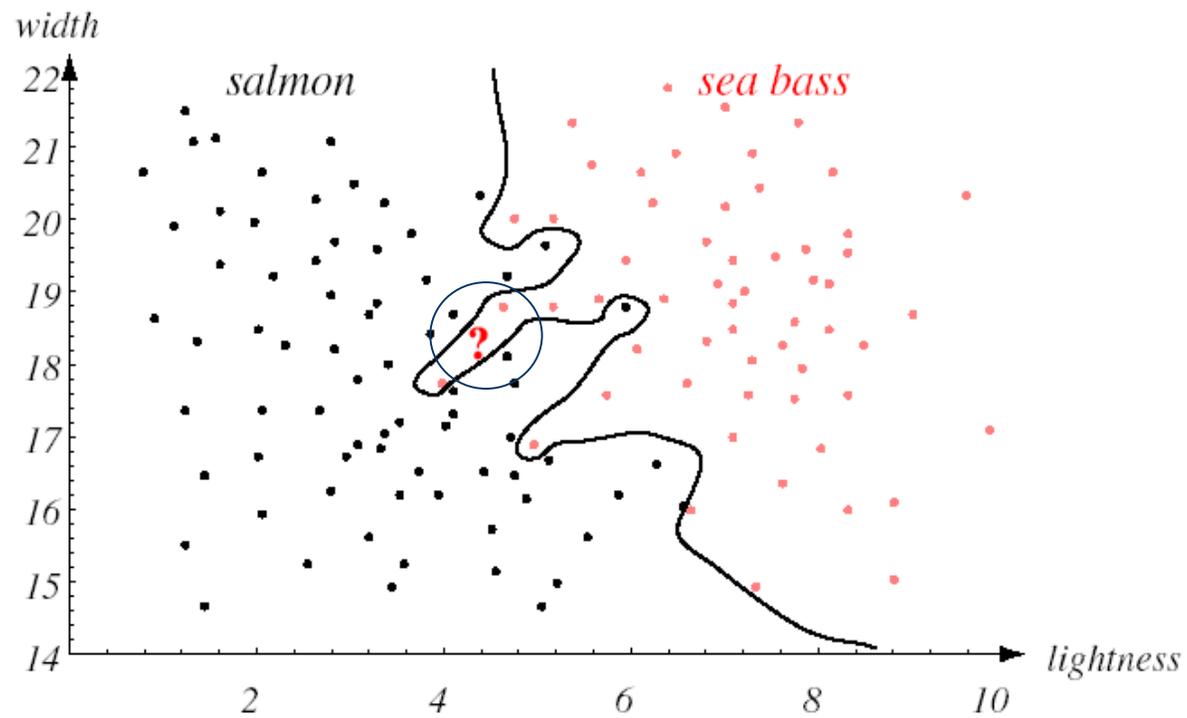
- Seleccionando a **luminosidade** e **largura** como atributos



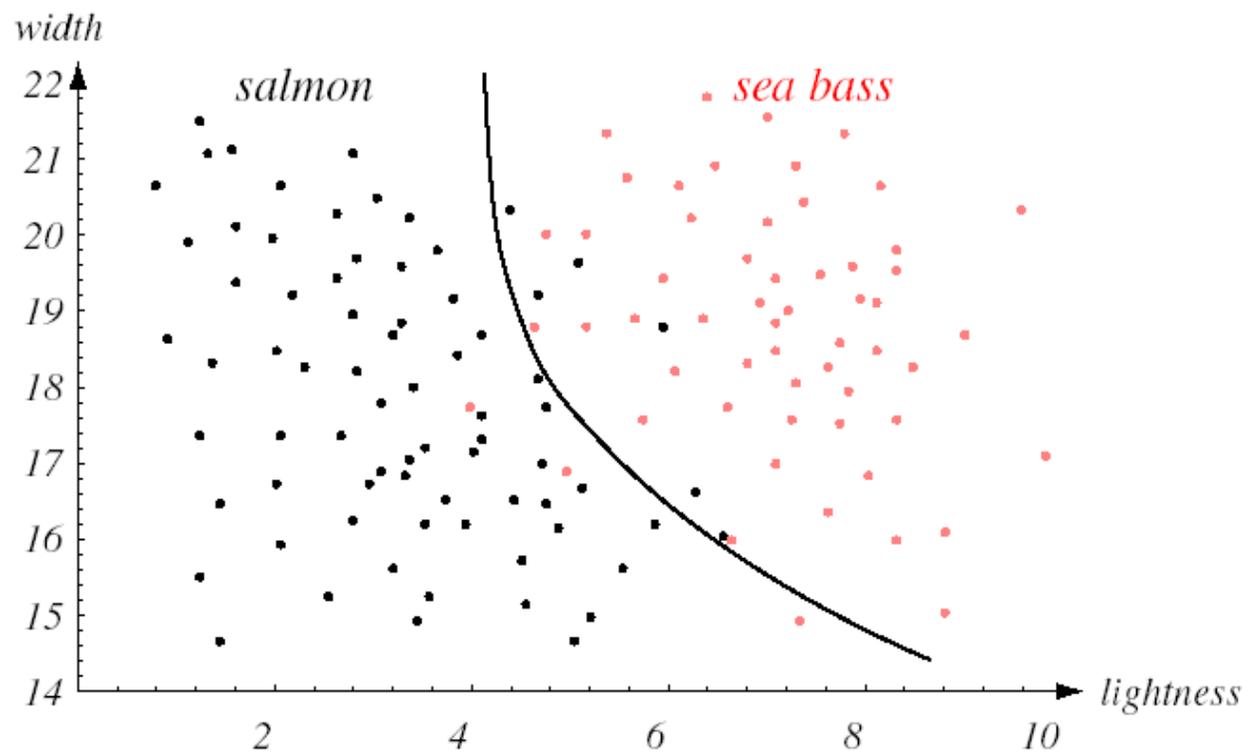
- Adição de outros atributos não correlacionados
 - precaução para não acrescentar atributos redundantes
 - dimensão do espaço de atributos
 - custo computacional

- Ideal
 - superfície de decisão produz desempenho ótimo
 - desempenho: na classificação de novas entradas
 - generalização: mais importante que perfeição

■ Perfeição (padrões de treinamento)



■ Generalização (novos padrões)



- Classificador geral de padrões

- tarefa muito difícil
- classificação: tarefa é recuperar o modelo que gera o padrão
- técnicas de classificação dependem do tipo dos modelos

- Exemplos de modelos

- estatísticos (densidades de probabilidades)
- neurais
- sintáticos (regras lógicas)

- Representação e qualidade da classificação

- lista de atributos
- partes e suas relações
- vetor de números reais

- Áreas relacionadas

- processamento de imagens
- memória associativa
- regressão
- interpolação
- estimação de densidades

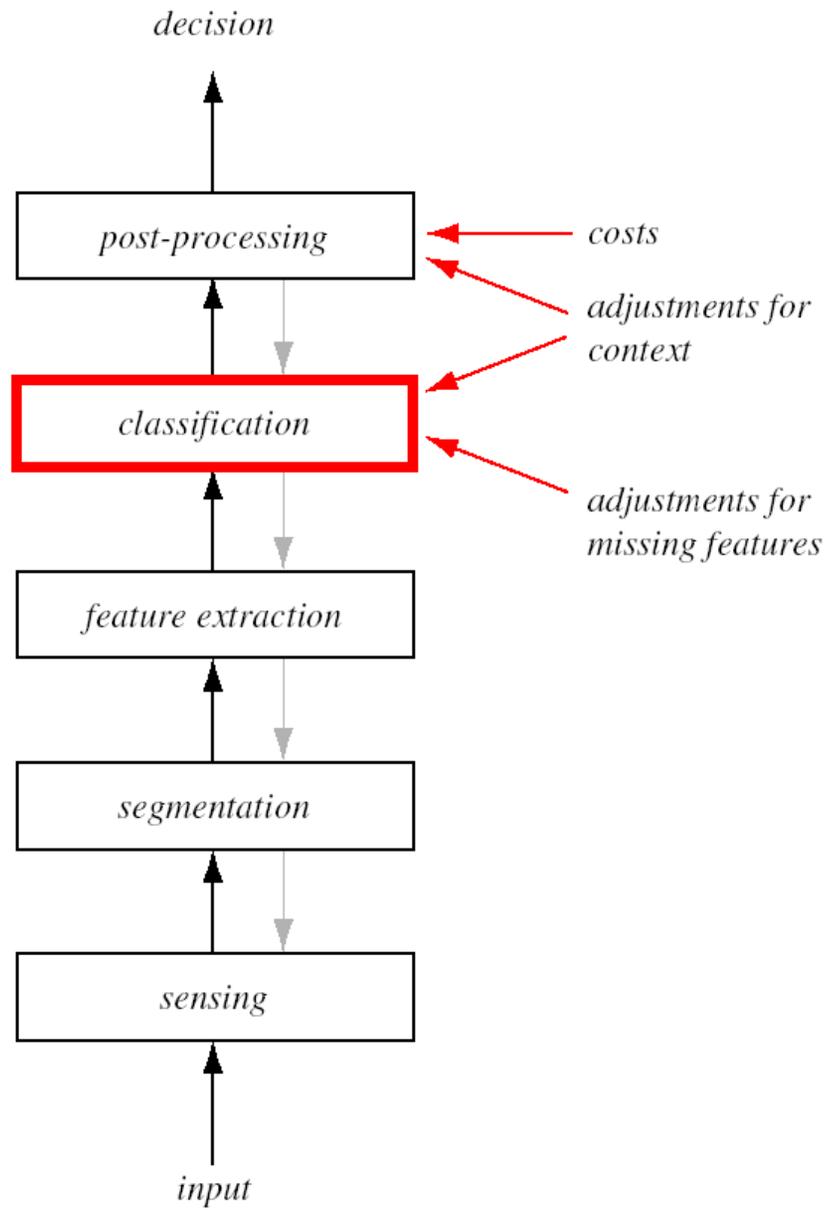
3-Sistemas de reconhecimento de padrões

- Sensoriamento

- transdutores (câmeras, microfones, etc.)
- PR depende da resolução, sensibilidade, distorção, *bandwith*

- Segmentação

- padrões separados, sem sobreposição



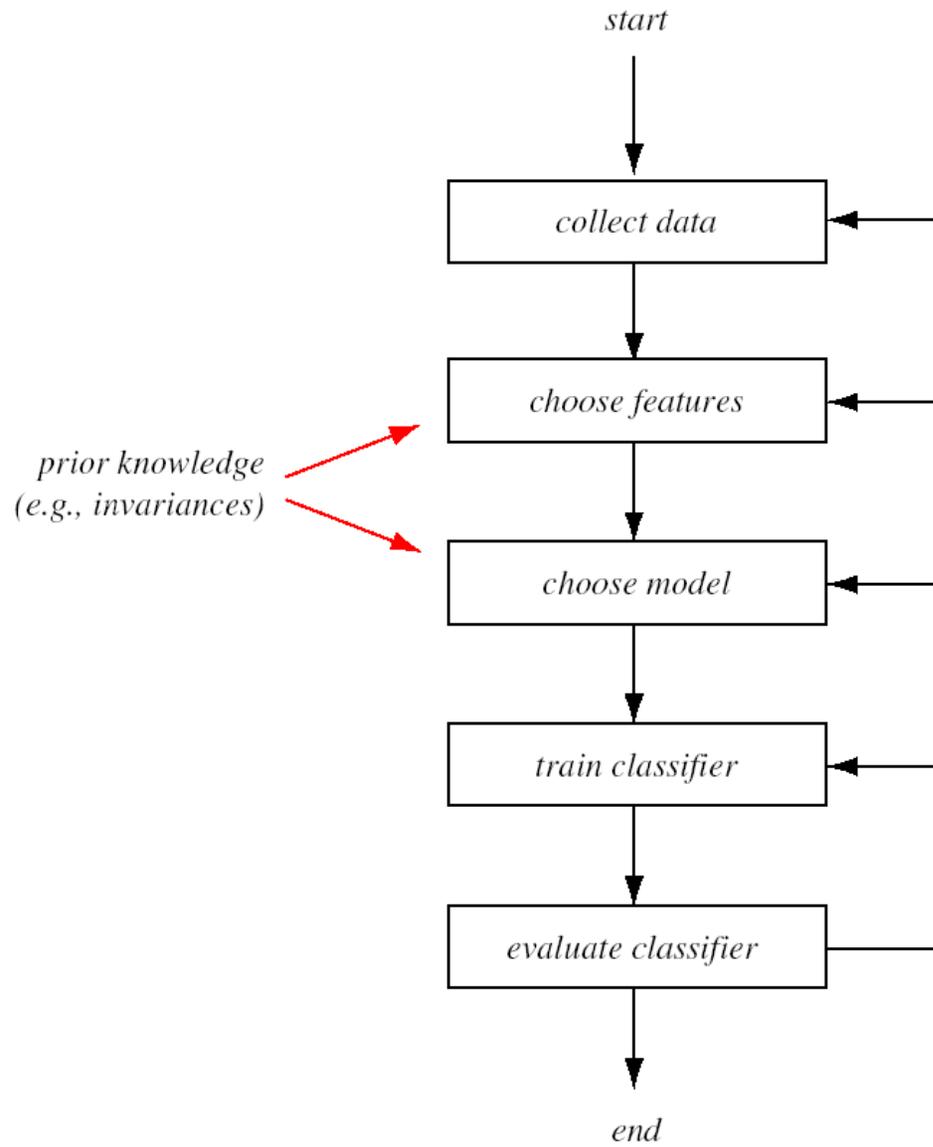
- Extração de características
 - atributos discriminantes
 - invariância à translação, rotação, escala, taxa, deformação

- Classificação
 - usa vetor de atributos fornecido pelo extrator
 - atribui objeto à uma categoria

- Pós-Processamento
 - explora informação do contexto para melhorar desempenho
 - minimiza risco (*total expected cost*)
 - múltiplos classificadores

4-Ciclo de projeto

1. Aquisição de dados
2. Escolha de atributos
3. Escolha do modelo
4. Treinamento
5. Avaliação



- Aquisição de dados
 - conjunto de dados suficiente e representativo
 - treinamento e teste do sistema

- Escolha de atributos
 - depende das características do domínio do problema
 - simples de extrair
 - invariantes à transformações irrelevantes
 - imunidade a ruído

■ Escolha do modelo

- modelo escolhido \neq modelo real ?
- necessário novo modelo ?
- metodologias para orientar escolhas

■ Treinamento

- usar dados para determinar o classificador
- diferentes metodologias e procedimentos
 - treinamento e escolha de modelos
- não existem metodologias e procedimentos universais

■ Avaliação

- taxa de erro de classificação
- importante para medir desempenho e identificar melhorias

■ Complexidade computacional

- muito importante na prática
- compromisso simplicidade (algoritmo) × desempenho (qualidade)
- complexidade: aprendizagem (lab) × tomada de decisão (campo)
- complexidade temporal e espacial de algoritmos
 - número de atributos
 - classes
 - padrões ou categorias

5-Aprendizagem e adaptação

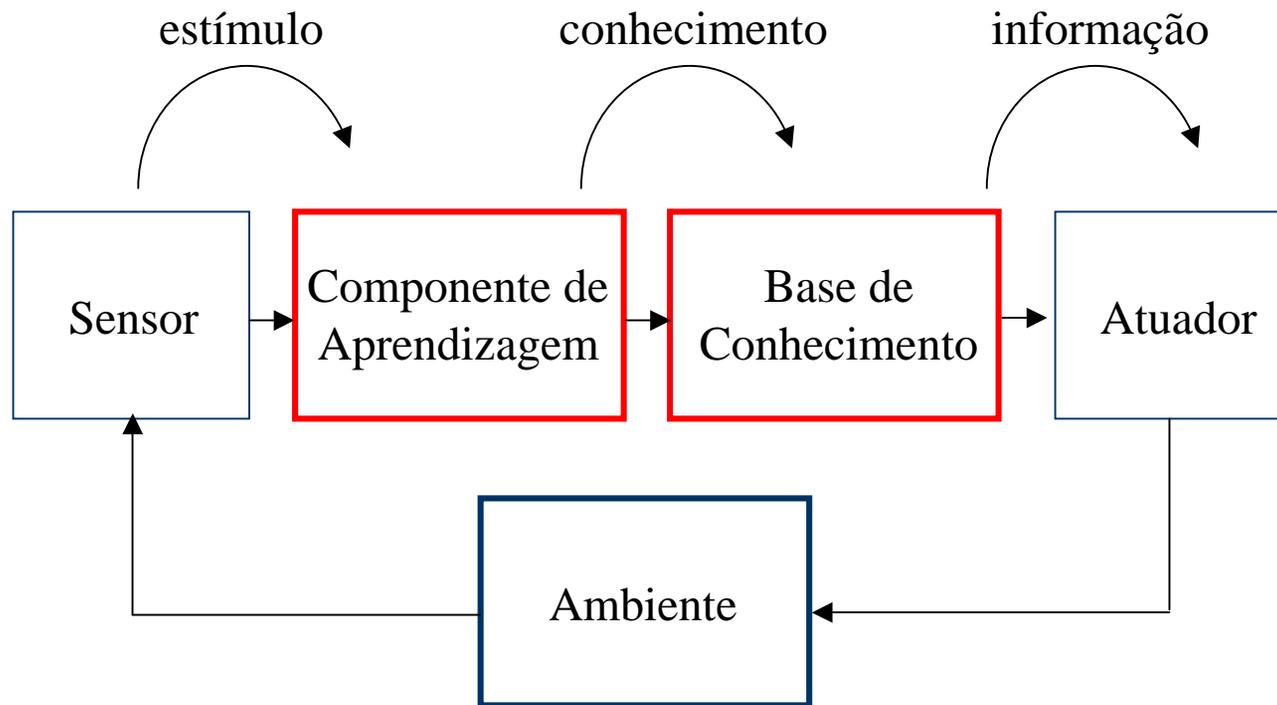
- Aprendizagem

Processo onde os parâmetros livres de um modelo são determinados por um processo de estimulação pelo ambiente com o qual o modelo interage.

Tipo de aprendizagem: determinado pela maneira pela qual os parâmetros são ajustados.

Utiliza memória para utilizar e explorar experiência anterior.

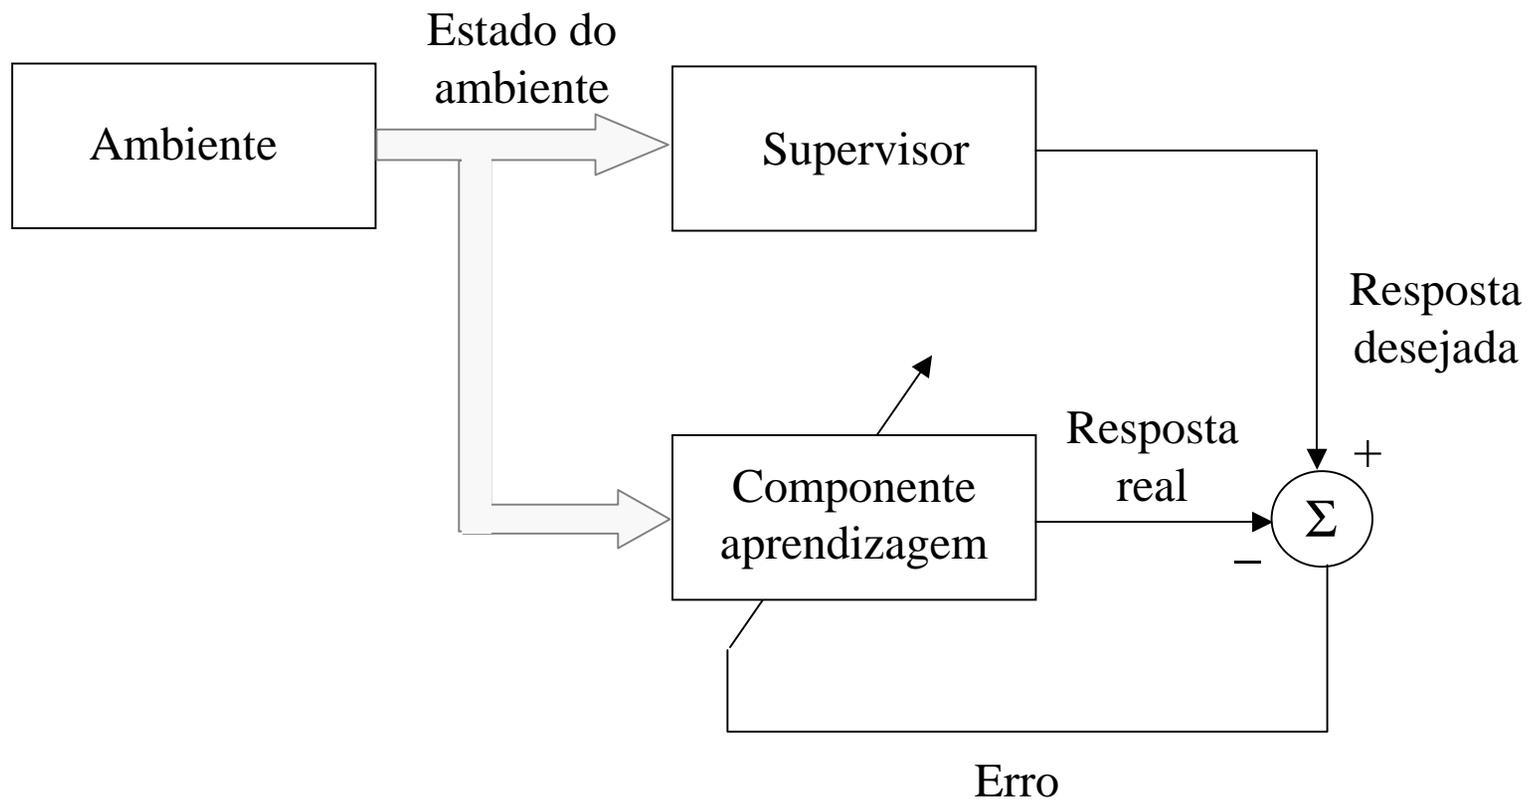
Modelo simples de aprendizagem de máquina



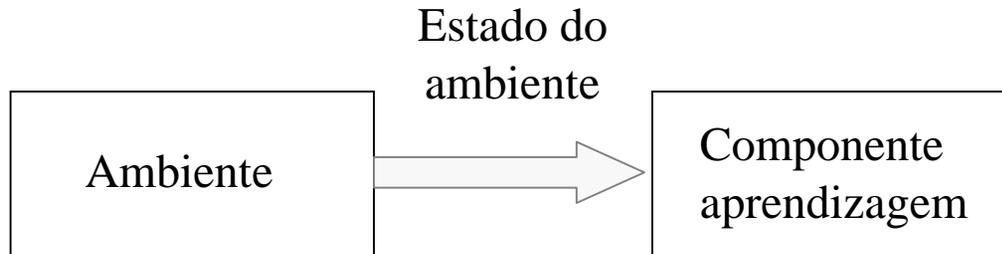
- Processo de aprendizagem
 - paradigmas aprendizagem
 - supervisionada
 - autorganizada
 - reforço
 - algoritmos de aprendizagem
 - correção de erro
 - Hebbiano
 - competitivo
 - Boltzmann

Learning refers to some form of algorithm to reducing the error on a set of training data. (Duda, Hart and Stork, 2001)

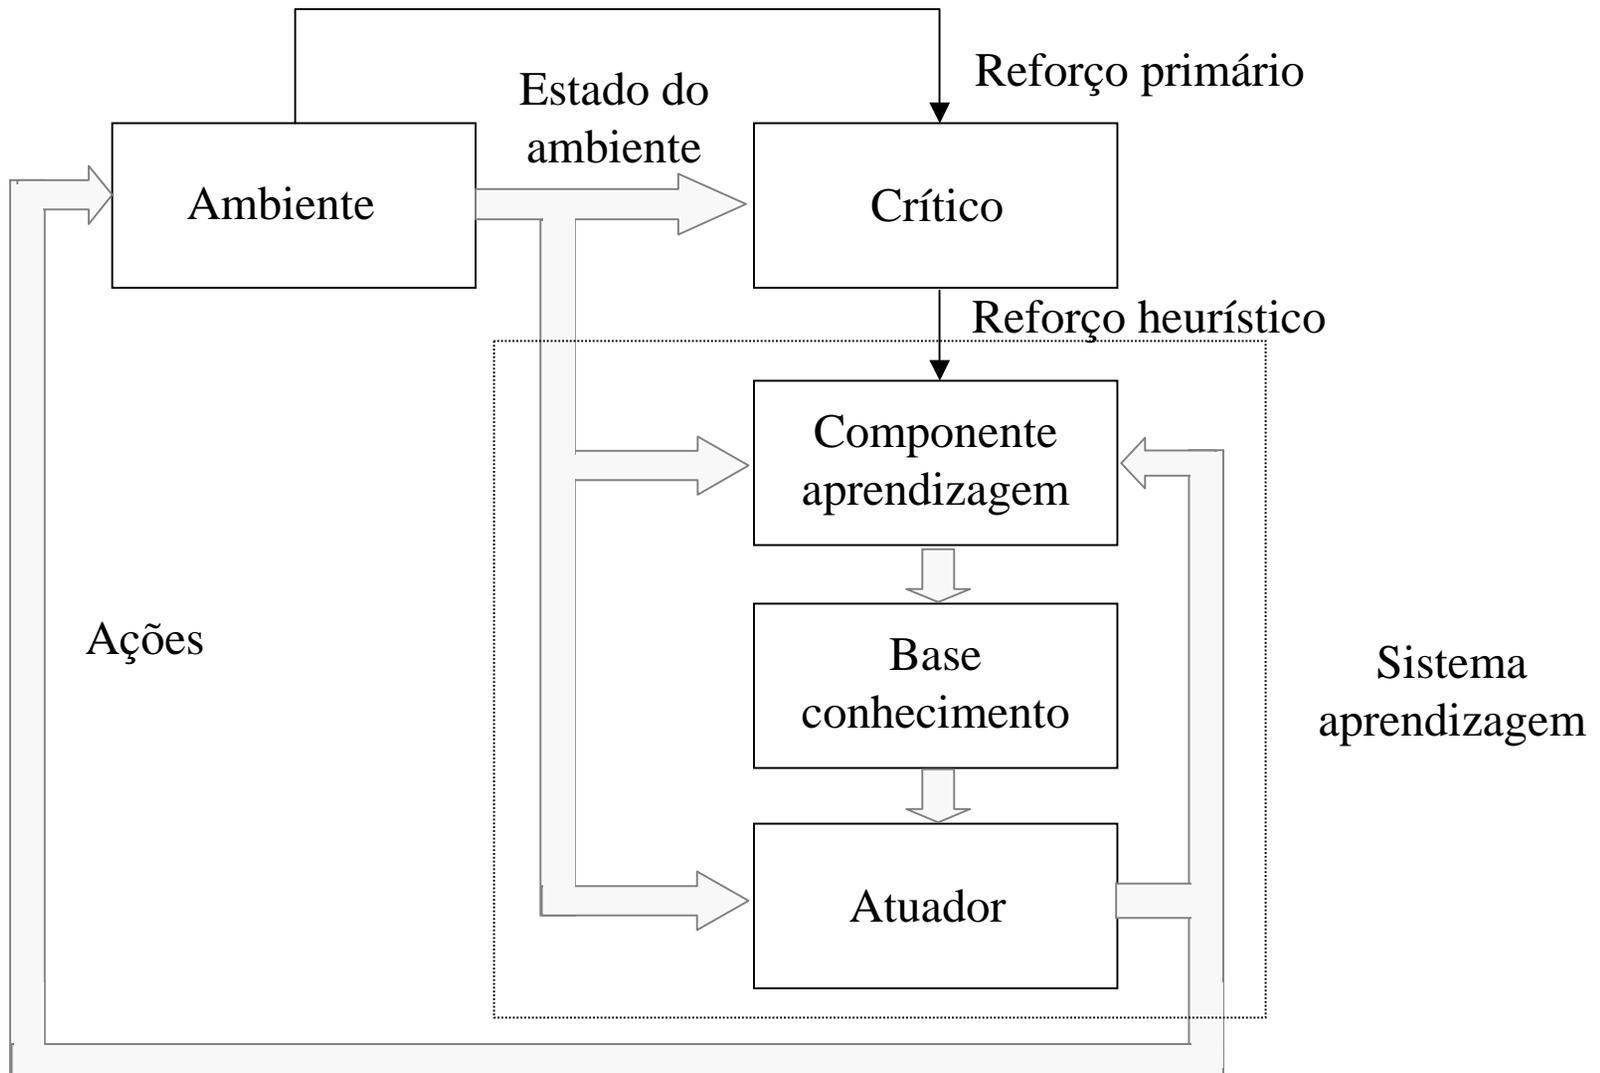
Aprendizagem supervisionada



Aprendizagem autorganizada (não supervisionada)



Aprendizagem por reforço (AHC)



■ Adaptação

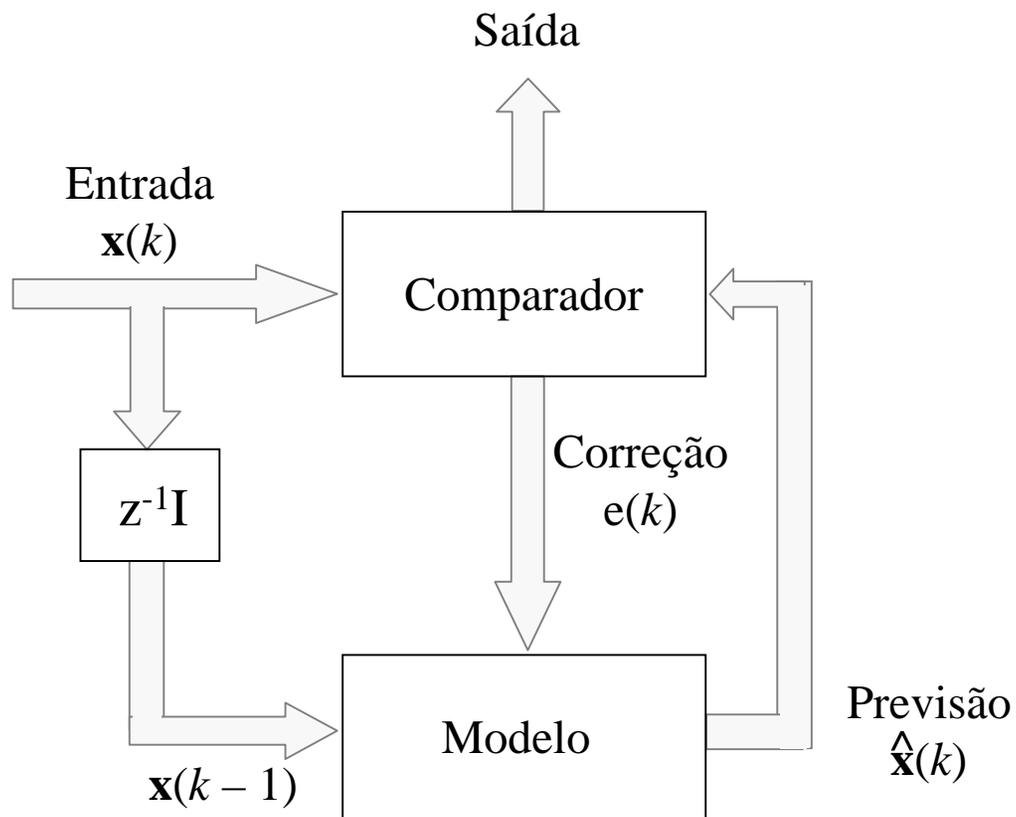
Processo onde os parâmetros livres de um modelo são determinados por um processo de estimulação por um ambiente não estacionário.

Características estatísticas do ambiente variam com o tempo.

Necessário adaptar continuamente os parâmetros livres do modelo em tempo real.

Modelo adaptativo responde a estímulos/entradas distintas de uma nova forma (ambiente não estacionário)

Sistema adaptativo



6-Conclusão

- Complexidade, número, magnitude de problemas de RP
- Existem soluções (e provas) para muitos problemas
- Teorias (matemáticas) já descobertas e desenvolvidas
- Muitos problemas importantes ainda por resolver

Observação

Este material refere-se às notas de aula do curso CT 720 Tópicos Especiais em Aprendizagem de Máquina e Classificação de Padrões da Faculdade de Engenharia Elétrica e de Computação da Unicamp e do Centro Federal de Educação Tecnológica do Estado de Minas Gerais. Não substitui o livro texto, as referências recomendadas e nem as aulas expositivas. Este material não pode ser reproduzido sem autorização prévia dos autores. Quando autorizado, seu uso é exclusivo para atividades de ensino e pesquisa em instituições sem fins lucrativos.