

T6.1 – Reconhecimento de Padrões

Proc. Sinal e Imagem
Mestrado em Informática Médica

Miguel Tavares Coimbra

Resumo



1. Introdução ao reconhecimento de padrões
2. Representação do conhecimento
3. Reconhecimento estatístico de padrões
4. Aprendizagem máquina

1. Introdução ao reconhecimento de padrões

1. Introdução ao reconhecimento de padrões
2. Representação do conhecimento
3. Reconhecimento estatístico de padrões
4. Aprendizagem máquina

Introdução


- Consigo manipular imagens.
- Quero agora tomar decisões!



- Classificar/Identificar características.
- Reconhecer padrões.


Características de nível baixo

- Objectivas
- Reflectem directamente as características da imagem
 - Cor
 - Textura
 - Forma
 - Movimento (?)
 - Etc.



Características de nível médio

- Algum grau de subjectividade
- Tipicamente são resultados de problemas que implicam mais do que uma solução possível
- Exemplos:
 - Segmentação
 - Fluxo óptico
 - Identificação
 - Etc.



Características de nível alto

- Interpretação semântica da situação
- Comportamento
- Contexto
- Exemplos:



Como é que os seres humanos fazem isto tão bem?

- Esta pessoa é epiléptica.
- O vírus avança de forma inteligente para o núcleo da célula.
- Esta pessoa está a fugir daquela.

A ponte semântica

- Problema fulcral da investigação actual!

Baixo nível:

- Cor
- Textura
- Forma
- ...



Alto nível:

- Interpretação
- Decisão
- Compreensão
- ...

E agora??
Como cruzar esta ponte!



2. Representação do conhecimento

1. Introdução ao reconhecimento de padrões
- 2. Representação do conhecimento**
3. Reconhecimento estatístico de padrões
4. Aprendizagem máquina

Conhecimento

- O reconhecimento não é possível sem **Conhecimento**.
 - Acerca dos objectos a reconhecer.
 - Acerca das classes de objectos.
 - Acerca do contexto do reconhecimento.

Mas o que é isso
de *conhecimento*?
Como o
represento?
Como o calculo?



Sintaxe e Semântica

- **Sintaxe**

- A sintaxe de uma representação especifica os símbolos que podem ser usados, e a forma como estes podem ser combinados em *palavras*.

- **Semântica**

- A semântica de uma representação especifica a codificação de *significado* nesta, assim como a forma que as *palavras* podem ser combinadas em *frases*.

Representação

- Uma **Representação** é uma conjunto de convenções sintáticas e semânticas que tornam possível a descrição de algo.


A língua portuguesa é uma **representação** com **sintaxe** e **semântica** bem definida.



Como *representar* isto?

Representação do conhecimento


- Como representar matematicamente o conhecimento?
- Várias técnicas:
 - Características
 - Gramática e linguagens
 - *Predicate Logic*
 - Regras
 - *Fuzzy Logic*
 - *Redes semânticas*
 - *etc*



E agora?
Como escolher?

Características

- Não são uma representação pura.
- São blocos fundamentais de representações mais complexas.
- Tipicamente:
 - Representação escalar de uma grandeza.



Tamanho: 5
Curvatura: 2,3
Cor dominante: 8,23
etc.

Regras

- Baseadas em **pares condição-acção.**

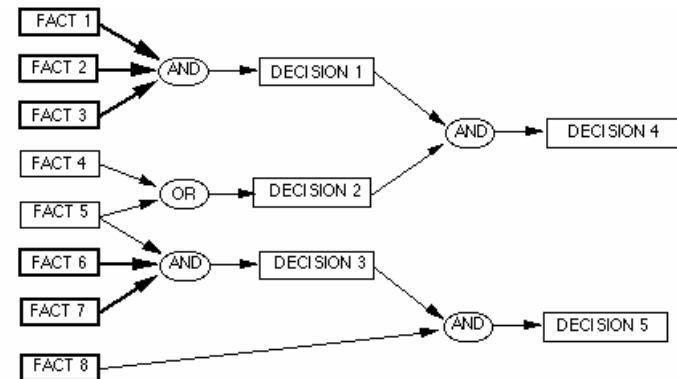
Se condição x for verdadeira, *então* realizar acção y.

- **Vantagens:**


- Simples
- Intuitiva

- **Desvantagem:**

- Obtenção das regras nem sempre trivial.



Forward-Chaining



Backward-Chaining


Fuzzy Logic

- Regras: Decisões binárias (sim ou não).
- E se não tivermos certezas?
 - *Fuzzy Logic*
Se condição x Então acção y Com confiança z
- Exemplo: Regras vs. Fuzzy Logic
Regras: Se o objecto é redondo então é uma bola.
FL: Se o objecto é muito redondo então é uma bola com grande probabilidade.
- **Fuzzy Logic**: Framework matemático para lidar com esta incerteza.

3. Reconhecimento estatístico de padrões

1. Introdução ao reconhecimento de padrões
2. Representação do conhecimento
3. Reconhecimento estatístico de padrões
4. Aprendizagem máquina

Porto pertence a Portugal?



Porto pertence a Portugal

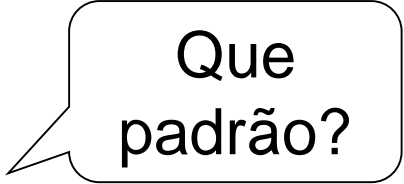
- Quero tomar decisões.
 - Porto pertence a Portugal?
- Sei algumas coisas
 - Um mapa-mundo que inclua cidades e países.
- Posso tomar uma decisão!
 - Porto pertence a Portugal.

Tinha suficiente conhecimento *a priori* para tomar esta decisão.

E se eu não tiver um mapa?



- Continuo a querer tomar uma decisão.
- Observo que:
 - Amarante tem coordenadas x_1, y_1 e pertence a Portugal.
 - Viseu tem coordenadas x_2, y_2 e pertence a Portugal.
 - Vigo tem coordenadas x_3, y_3 e pertence a Espanha.
- E classifico:
 - Porto está perto de Amarante e de Viseu portanto **Porto pertence a Portugal.**
- E se eu tentar classificar Valença?

Reconhecimento estatístico de padrões

- Usei **estatísticas** para tomar uma decisão.
 - Posso tomar decisões mesmo sem ter conhecimento a priori de todo o processo.
 - Posso cometer erros.
- Como **reconheci este padrão?** 
 - **Aprendi** com observações anteriores nas quais sabia o resultado da classificação.
 - **Classifiquei** uma nova observação.

Características de uma observação

- Reduzi cada observação a um conjunto fundamental de características.
- Vectors numéricos.
 - Condensam matematicamente uma ou várias características.
 - Formam um espaço vectorial.



Exemplo: Cada *bin* de um histograma é uma **característica**. Um histograma completo é um **vector de características**


De volta ao nosso exemplo

- Classifiquei o Porto como pertencente a Portugal.
- Que característica usei?
 - Localização espacial
- De forma mais formal
 - Defini um vector F com uma característica F_1 , que possui dois coeficientes f_{1x} , f_{1y} :

$$F = [F_1] = [f_{1x}, f_{1y}]$$

Espaço de características

- **Vector de características**
 - Dois coeficientes.
 - Pode ser visto como um ‘espaço’ de características com dois eixos ortogonais.
- **Espaço de características**
 - Hiper-espaço com N dimensões em que N é o número total de coeficientes do meu vector de características.

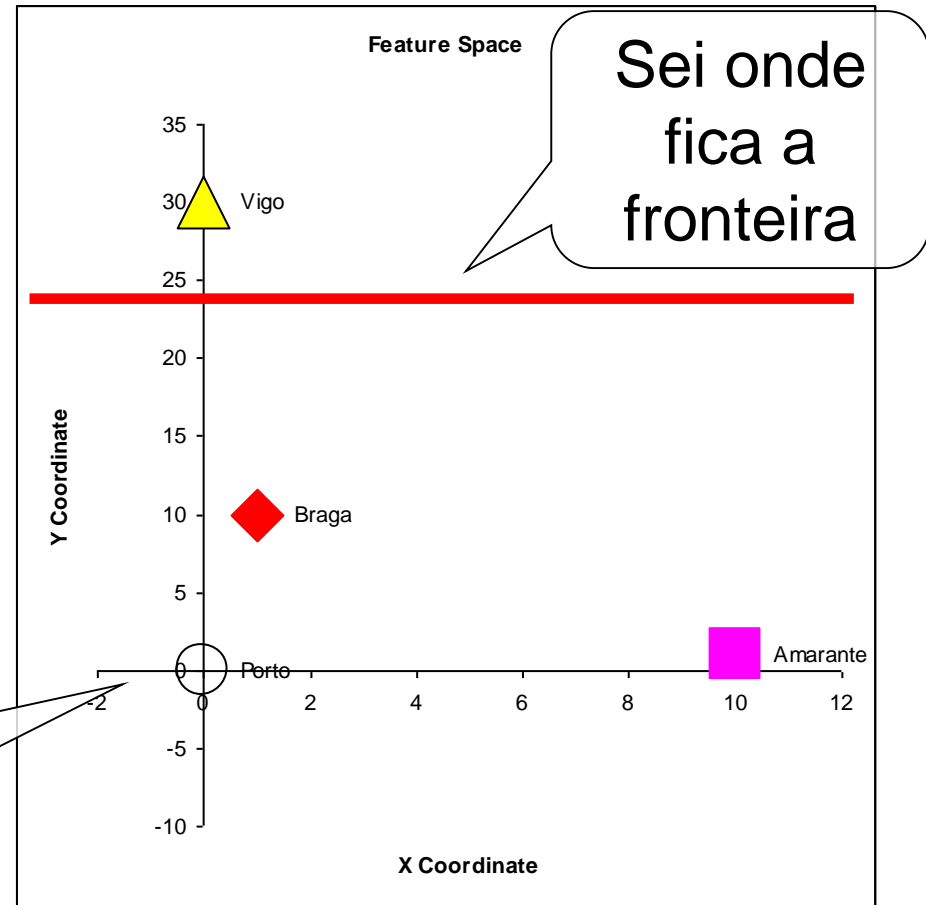


Conhecimento *A Priori*

- Tenho um **modelo** preciso do meu espaço de características baseada no meu conhecimento ***a priori***.


Cidade pertence a Espanha se $F_{1Y} > 23$

Porto **pertence** a Portugal!




E se eu não tiver um modelo?

- Tenho que **aprender** com as minhas observações.
 - Derivar um modelo.
 - Classificar directamente.
- **Fase de treino**
 - Aprender os parâmetros do modelo.
- **Classificação**




Classes de objectos

- No nosso exemplo as cidades pertencem a:
 - Portugal
 - Espanha
- Tenho duas **classes** de cidades.
- Uma **classe** representa um sub-espaço do meu espaço de características.



Classificadores

- **Classificador:**
 - Atribui uma classe a um objecto.
 - Concretiza um *padrão*.
- **Como criar um classificador?**
 - ‘Ensinar’ o classificador com dados de treino.
 - Utilizar técnicas de auto-aprendizagem (e.g. Clustering).




Classificador estatístico

- Dispositivo com:
 - n entradas
 - 1 saída
- As entradas são as **características** do objecto.
- A saída é a **classe** a que o objecto pertence.
- Fase de treino
 - O classificador ‘aprende’ com exemplos a identificar uma classe.
- Exemplo:
 - Distância Euclideana ao vector com as médias das características de uma classe.

Cluster analysis

- Não necessita de dados de treino.
- Tenta distinguir os objectos em classes diferentes usando muito exemplos não anotados.
- Mais popular:
 - *K-means clustering*.



Adaptado de *Wikipedia*

4. Aprendizagem máquina


1. Introdução ao reconhecimento de padrões
2. Representação do conhecimento
3. Reconhecimento estatístico de padrões
4. **Aprendizagem máquina**

Soft-Computing Machines

- Métodos avançados de computação.
- Tentam modelar o sistema automaticamente, utilizando apenas dados de treino.
- Muito eficazes para sistemas complexos!
- Exemplos:
 - Redes neuronais.
 - Support Vector Machines


Redes neuronais

- **Constituídas por elementos simples.**
 - Neurónios.
- **Elevado grau de conectividade.**
 - Sistema complexo!
- **Inspiração biológica.**
 - Cérebro humano.



Neurónios

- N entradas.
- 1 saída.
- Faz um a soma ponderada das entradas.
 - Pesos
- Limiar de disparo.
 - *Threshold*



$$x = \sum_{i=1}^N v_i w_i - \theta \quad f(x) = \begin{cases} 1 & \Leftarrow x \leq 0 \\ 0 & \Leftarrow x > 0 \end{cases}$$

Feed-forward networks

- **Fase de Treino**

- Rede ‘alimentada’ com dados pré-annotados.
- Auto-aprendizagem dos pesos.
- Auto-aprendizagem do limiar de decisão.

- ***Backpropagation***


- **Classificação**

- Entrada: *Vector de características* desconhecido.
- Saídas: Neurónios disparam caso a classificação seja positiva.


Custo computacional elevado!

Support Vector Machines

- Calcula o **hiperplano de decisão** que maximiza a **margem de separação** entre classes.
- Aumenta o **número de dimensões** do espaço de características.
 - Separação das classes.





Qual o melhor hiperplano?



Fuzzy systems


- Usam regras *Fuzzy*.
- Usam probabilidades em vez de decisões.
- Decisão final:
 - *Defuzzification*.

Melhor capacidade para lidar com a incerteza.



Optimização

- Modelo do objecto a analisar.
 - *Best-Fit*
- Minimização de uma função de erro.
- *Hill-climbing* tem limitações.
- Optimização:
 - Algoritmos genéticos.
 - *Simulated annealing*.
 - Etc.



Resumo

- A ponte semântica.
- Características, regras e *Fuzzy-logic*.
- Espaço de características.
- Criação de um classificador estatístico.
- Aprendizagem máquina.