

Capítulo 17

Reconhecimento de Padrões

Como já mencionamos no capítulo 15, um dos passos fundamentais na **Visão Computacional** é a **segmentação** de unidades semânticas a partir das imagens digitais. O conjunto de algoritmos que **reconhecem** e **classificam** estas unidades semânticas em algum padrão é conhecido como **reconhecimento de padrões**.

(Ver Fig. 9.1 do livro-texto de Gonzalez.)

Segundo o dicionário Michelis, **reconhecimento** é o aspecto funcional da memória pelo qual a pessoa tem o sentimento de algo já experimentado e conhecido. Podemos entender o problema de reconhecimento como um problema de **classificação** das unidades semânticas extraídas de uma imagem em relação a um conjunto de padrões previamente modelados e armazenados na máquina. A simplicidade da formulação deste problema não revela o grau de complexidade de uma possível solução. Ela depende da resposta de uma séire de perguntas interdependentes, como:

1. como as máquinas conseguem “aprender” os padrões, tais como alfabetos e sinais de trânsito?
2. como as máquinas conseguem interpretar corretamente as variantes dos padrões aprendidos, como distintas expressões faciais para demonstrar o mesmo sentimento?
3. como as máquinas conseguem associar um padrão extraído de uma imagem com os padrões já aprendidos por ela?
4. como as maquinas conseguem inferir a classe de padrão à qual a unidade semântica pertence, mesmo que os dados da imagem estejam parcialmente corrompidos ou incompletos?

Aprendizagem, inferência, interpretação e associação são habilidades que envolvem tomadas de decisão. Estas tomadas podem ser feitas com base em **padrões quantitativos** ou em **relações estruturais** inerentes à forma de padrão. Na seção 17.1 apresentamos uma noção bem elementar de padrões e classe de padrões.

Em geral, as técnicas orientadas aos padrões quantitativos se reduzem em um problema de encontrar **funções de decisão**, ou **discriminantes**, através das quais uma máquina consegue quantizar o grau de pertinência de um padrão às distintas classes de padrão. Os padrões quantitativos são representados por vetores de medidas numéricas, como a assinatura que vimos na seção 15.4.2. Medidas estatísticas, como média e covariância, e funções densidade de probabilidades são aplicadas para este propósito. As ferramentas desenvolvidas no contexto de **Inteligência Artificial**, como **redes neurais**, abriram a possibilidade de adaptar dinamicamente as funções densidade de probabilidade, e portanto funções de decisão, ao longo de um processo de aprendizagem e/ou treinamento. Na seção 17.2 é dada uma idéia de um classificador baseado em funções de decisão.

Classificações baseadas em relações estruturais, por outro lado, procuram computar o **grau de similaridade** entre dois padrões através dos tipos de relação de adjacência entre os seus elementos constituintes. Por isso, um elemento importante para o sucesso destes classificadores é a representação da conectividade entre tais elementos. Duas representações mais utilizadas são uma sequência de alfabetos ou uma árvore de primitivas, cuja organização segue um conjunto de regras gramaticais, como o código da cadeia que vimos na seção 15.4.1. Com isso, o problema de reconhecimento de um padrão pode ser reduzido a um problema de análise sintática do padrão e a avaliação das “discrepâncias sintáticas” entre os padrões. Na seção 17.3 ilustramos esta idéia através do casamento de dois padrões representados por código da cadeia.

(Ver Fig. 9.5 do livro-texto de Gonzalez.)

17.1 Classe de Padrões

De acordo com Gonzalez e Woods, um **padrão** é uma descrição quantitativa ou estrutural de um objeto ou alguma outra entidade de interesse em uma imagem. Um padrão pode ser **quantitativo**, caracterizado por conter n medidas como ângulo, distância, largura e comprimento, ou **estrutural**, se as informações predominantes são as relações entre os elementos constituintes do objeto de interesse.

Código da cadeia (Seção 15.4.1) é um exemplo típico de descrição estrutural, enquanto os valores relevantes de uma assinatura (Seção 15.4.2) constituem um vetor quantitativo (*pattern vector*).

(Ver Fig. 9.3 do livro-texto de Gonzalez.)

A seleção das n medidas para caracterizar os objetos de interesse é dependente da aplicação. Um conjunto de medidas que seja ótimo para distinguir duas classes de objetos pode não ser adequado para separar outros conjuntos de objetos.

(Ver Fig. 9.2 do livro-texto de Gonzalez.)

Uma **classe de padrões** é uma família de padrões que compartilham algumas propriedades comuns.

Exercício 17.1 *Dê um exemplo de um padrão quantitativo e um padrão estrutural.*

Exercício 17.2 *Quais medidas podem ser utilizadas para definir os padrões de notas da disciplina de EA978?*

17.2 Classificadores de Padrões Quantitativos

Para ilustrar a idéia de um classificador de padrões quantitativos, utilizamos o esquema de representação de assinatura, ou seja, consideramos que um objeto seja representado pela função uni-dimensional $r(\theta)$. Supomos que os ângulos $\theta_1, \theta_2, \dots, \theta_n$, contém características discriminadoras, permitindo a definição de vetores de padrão $\vec{x} = \{x_1, x_2, \dots, x_n\}$, onde $x_1 = r(\theta_1)$, $x_2 = r(\theta_2)$, \dots , $x_n = r(\theta_n)$. Estes vetores de padrões definem um **espaço de padrões** de dimensão n . Para M classes de padrões $\omega_1, \omega_2, \dots, \omega_M$ devemos encontrar M funções de decisão $d_1(\vec{x}), d_2(\vec{x}), \dots, d_M(\vec{x})$, tal que se um padrão \vec{x}_k pertence à classe ω_i , então a função de decisão $d_i(\vec{x}_k)$ assume o máximo

$$d_i(\vec{x}_k) > d_j(\vec{x}_k), \forall j \neq i.$$

(Ver Fig. 9.3 do livro-texto de Gonzalez.)

Exercício 17.3 *Definir um vetor de padrões de dimensão 4 para o padrão extraído no Exercício 15.4.*

Os classificadores se diferem principalmente nas suas funções de decisão. Uma forma simples de classificação é por **distância mínima**. Cada classe

de padrões ω_j é representada por um **vetor protótipo** \vec{m}_j que é o “médio” de todos os vetores da classe

$$\vec{m}_j = \frac{1}{N_j} \sum_{i=0}^{N_j} \vec{x}_i,$$

onde N_j é o número de vetores de padrões da classe ω_j . E definimos como a função de decisão $d_i(\vec{x})$ da classe ω_j a distância euclidiana do padrão \vec{x} em relação ao seu vetor protótipo \vec{m}_j

$$d_i(\vec{x}) = \|\vec{x} - \vec{m}_j\|.$$

A função de decisão por distância mínima induz o particionamento do espaço de padrões em M células de Delaunay. Os padrões contidos numa célula pertencem a um mesma classe de padrão.

(Ver Fig. 9.6 do livro-texto de Gonzalez.)

Exercício 17.4 Considere que o espaço de padrões de quadrados, dado no Exercício 17.3, contenha 3 classes de padrão, cujos vetores protótipos são $(1, 1, 1, 1)$, $(4, 4, 4, 4)$ e $(8, 8, 8, 8)$, respectivamente. Determine a função de decisão para cada classe.

17.3 Classificadores Estruturais

Os classificadores estruturais são amplamente utilizados em aplicações para as quais os objetos apresentam relações estruturais mais discriminadores do que as suas medidas, como distinguir padrões cheios dos padrões vazados ou padrões circulares dos padrões retangulares.

Para ilustrar o princípio básico destes classificadores, utilizamos o código da cadeia que vimos na seção 15.4.1 para fazer o casamento entre duas fronteiras. Dizemos que dois códigos da cadeia, A e B , tem um **grau de similaridade** k quando k alfabetos da cadeia são coincidentes. Definimos ainda como a **distância** entre os dois códigos da cadeia A e B o inverso do seu grau de similaridade

$$D(A, B) = \frac{1}{k}.$$

Exercício 17.5 Qual é o grau de similaridade entre os seguintes códigos: 03030303, 03033133 e 00330033?

Denotando o comprimento do código A e B por $|A|$ e $|B|$, respectivamente, o número Q de alfabetos que não se casam é

$$Q = \max(|A|, |B|) - k.$$

Portanto, se $Q = 0$, os códigos A e B se casam.

Com base em k e Q , é definida uma **medida de similaridade**

$$R = \frac{k}{Q} = \frac{k}{\max(|A|, |B|) - k},$$

que tende a infinito quando o casamento (*matching*) entre os dois padrões é perfeito, e 0 quando nenhum dos alfabetos é coincidente. Uma vez que o casamento é feito, alfabeto por alfabeto, o ponto inicial de cada fronteira é importante. Quando não há garantia de que o ponto inicial seja coincidente, deve-se comparar exaustivamente uma cadeia com todas as possíveis variações da outra, deslocando-a ciclicamente em dois sentidos, através do cômputo do máximo das medidas de similaridade.

(Ver Fig. 9.25 do livro-texto de Gonzalez.)

Exercício 17.6 *Determine a medida de similaridade entre os padrões do Exercício 17.5.*