

## 4 Análise

Neste capítulo descrevemos procedimentos para analisar a influência de descritores e otimizar a máquina de aprendizagem. Além disso, descrevemos mais detalhadamente o problema de normalização dos descritores e analisamos parâmetros da interface.

### 4.1 Análise heurística da influência de descritores

Nesta seção descrevemos um procedimento adotado para analisar a influência individual dos descritores na avaliação da função classificadora. Esta análise tem como objetivo descobrir quais descritores mais influenciam a avaliação dos parâmetros. Em seguida, apresentaremos um método para calibrar parâmetros das Máquinas de Suporte Vetorial usando a influência dos descritores.

**Estimativa de influência de descritores** Relacionar variáveis de uma função não linear individualmente é uma tarefa difícil. Os métodos existentes para realizar análise não linear, como Kernel PCA (37), não se aplicam em nosso caso, pois procuramos uma dependência entre parâmetros lineares (descritores) e não linear ( $\hat{f}$ ). Por isso resolvemos adotar uma abordagem heurística.

Dado um conjunto de descritores  $\Phi = \{x_1, x_2, \dots, x_k\} \subset \mathbb{R}^p$  e uma função classificadora  $\hat{f}$ , podemos plotar  $p$  gráficos contendo coordenadas dos descritores e a classificação dada por  $\hat{f}$ , ou seja, cada gráfico  $g_l^\Gamma$  deve conter os pontos  $(x_i^l, \hat{f}(x_i))$ , onde  $x_i$  são pontos de um banco de dados previamente treinado  $\Gamma$  e  $x_i^l$  representa a  $l$ -ésima coordenada do vetor de descritores  $x_i = \varphi(\omega_i)$ .

Cada gráfico  $g_l^\Gamma$  pode nos dar uma intuição visual da dependência do classificador  $\hat{f}$  com a coordenada  $l$  do vetor de descritores. Descritores influentes devem gerar gráficos que apresentem algum padrão, enquanto descritores com menor influência devem gerar gráficos com uma distribuição aleatória dos pontos.

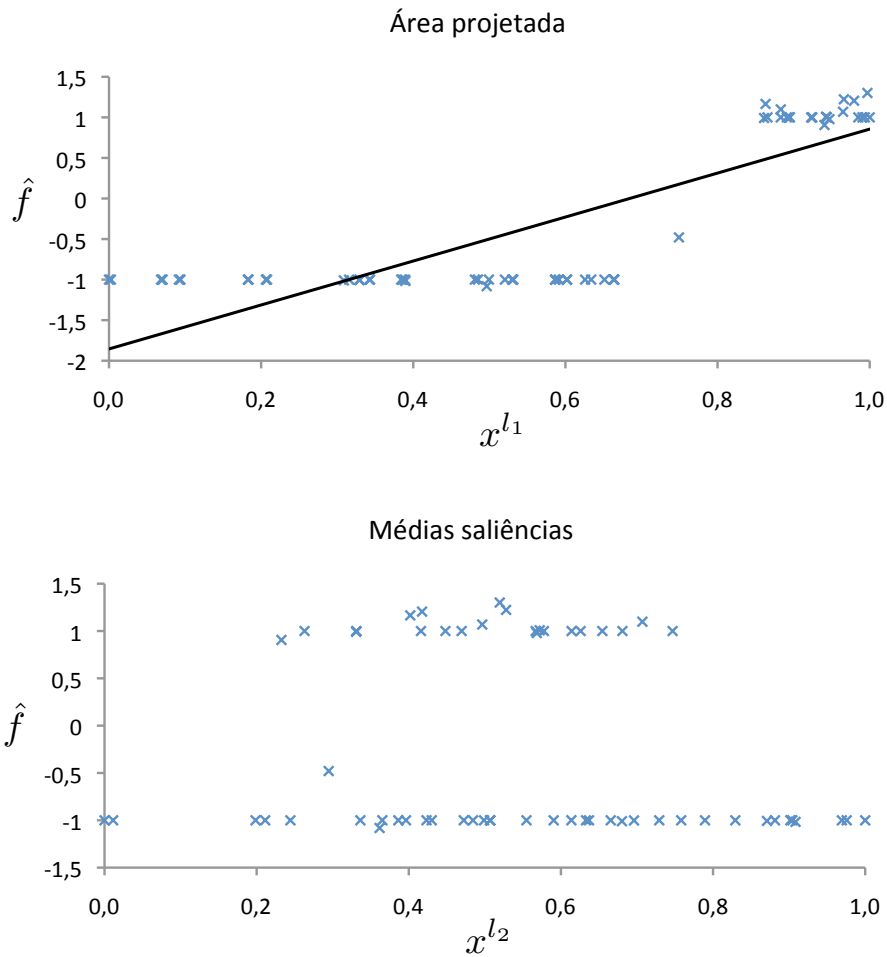


Figura 4.1: Exemplos de gráficos  $g_l^\Gamma$  de influência de descritores: descritor de área projetada na imagem apresentando alta influência, e descritor de médias saliências apresentando baixa influência em um banco de dados obtido através de experiências com um usuário para o problema de otimização de posicionamento de câmera.

Para tentar identificar essas dependências no gráfico, tentaremos aproximar as dependências não lineares com aproximações lineares, ou seja, realizando uma regressão linear em cada gráfico, como exibido na figura 4.1. Para medir a precisão de nossa aproximação, usaremos a variância  $\eta_l^\Gamma$  dos pontos em relação à reta de regressão. Se esta variância for baixa, a aproximação linear é válida. Consideraremos um descritor influente quando o valor absoluto da inclinação  $|\tau_l^\Gamma|$  da reta de regressão for alta e a variância for baixa. Nossa medida de influência é expressa por  $|\tau_l^\Gamma|(2 - \eta_l^\Gamma)$ . O fator 2 permite balancear heurísticamente estas duas propriedades. O uso do produto em vez da soma ponderada não muda essencialmente o resultado da otimização. A figura 4.1 exhibe exemplos de um descritor influente e um descritor pouco influente em um banco de dados obtido a partir de experimentos com um usuário para o




Figura 4.2: Influência de descritores com  $\sigma = 1$  (acima) e com  $\sigma = 8$  (abaixo). A otimização do parâmetro  $\sigma$  do *kernel* Gaussiano maximiza a influência dos descritores.

problema de otimização de posicionamento de câmera.

**Calibração de parâmetros** A formulação das Máquinas de Suporte Vetorial define a função classificadora usando *kernels*, que podem depender de um parâmetro, como por exemplo o  $\sigma$  do *kernel* Gaussiano dado na Equação (3-3). Podemos usar o procedimento de análise de influência para otimizar este tipo de parâmetro.

A figura 4.2 exibe exemplos de gráficos representando a influência de descritores do problema de otimização de posicionamento de câmera. Um descritor é influente quando está na região superior direita, que corresponde a valores altos de  $|\tau|$  e baixos de  $\eta$ . O gráfico de cima foi obtido usando o *kernel* gaussiano com parâmetro  $\sigma = 1$ . O gráfico de baixo exibe o resultado com o parâmetro  $\sigma$  otimizado, onde é possível perceber que, em geral, os descritores têm maior influência do que no gráfico inicial.

Propomos um paradigma onde uma função classificadora será robusta quando sofrer bastante influência do maior número de descritores. Na prática, isto significa que o processo de aprendizagem está aproveitando bem os

dados provenientes dos descritores para aprender as preferências do usuário. Portanto, nosso objetivo é maximizar a influência dos descritores, dada por

$$\sum_{k=1}^p |\tau_k^\Gamma| (2 - \eta_k^\Gamma),$$

onde  $|\tau_k^\Gamma|$  é o valor absoluto da inclinação da reta de regressão do gráfico  $g_k^\Gamma$ , e  $\eta_k^\Gamma$  sua variância.

Este problema de otimização é resolvido usando o método da bisseção, onde subdividimos progressivamente um intervalo grande de valores de  $\sigma$  até se aproximar de um máximo.

## 4.2

### Normalização

No capítulo 3 descrevemos brevemente um procedimento de normalização que deve ser aplicado em cada instância do problema (a função  $\chi$ ). Esta etapa é fundamental para poder usar a aprendizagem obtida pelos descritores em diferentes instâncias.

Intuitivamente, se para uma dada instância um determinado descritor retorna valores reais no intervalo  $[0, 10]$ , ou seja  $\varphi_j(\Omega) \subset [0, 10]$  e em outra instância este valor oscila no intervalo  $[20, 30]$ , nossa função classificadora não será consistente em ambos os casos. Porém, é razoável imaginar que, normalizando ambos os intervalos para o intervalo  $[0, 1]$ , teremos valores correspondentes, do ponto de vista do tipo de informação que o descritor representa.

A etapa de normalização tem como objetivo justamente normalizar todos os intervalos  $\mathcal{I}^l = [\inf(\varphi^l(\Omega)), \sup(\varphi^l(\Omega))]$ , que variam de acordo com a instância do problema. Para realizar uma normalização linear, precisamos conhecer os extremos destes intervalos.

Como não podemos avaliar os descritores em todo o espaço de parâmetros  $\Omega$ , determinamos os valores máximos  $M = (M^1, M^2, \dots, M^p)$  e mínimos  $\hat{M} = (\hat{M}^1, \hat{M}^2, \dots, \hat{M}^p)$  que vão definir os intervalos  $\mathcal{I}^l$  usando o conjunto de descritores  $\varphi(\Psi)$ , onde  $\Psi$  é a amostragem inicial da galeria. Esta normalização deve ser aplicada sempre que uma nova instância do problema for inicializada na galeria. Note que quanto maior a cardinalidade de  $\Psi$ , mais precisos serão os intervalos de normalização.

Após esta etapa, todos os descritores  $x_i = \varphi(\omega_i)$  devem ser normalizados pela função  $\chi: \mathbb{R}^p \mapsto \mathbb{R}^p$  dada por



Figura 4.3: Exemplo ilustrando a organização da interface das Galerias Inteligentes: no centro, em alta resolução, o visualizador permite ao observador examinar mais detalhadamente os parâmetros do mosaico.

$$\chi(x) = \left( \frac{x^1 - \inf(\mathcal{I}^1)}{|\mathcal{I}^1|}, \frac{x^2 - \inf(\mathcal{I}^2)}{|\mathcal{I}^2|}, \dots, \frac{x^p - \inf(\mathcal{I}^p)}{|\mathcal{I}^p|} \right). \quad (4-1)$$

### 4.3

#### Otimização da interface

Nesta seção analisamos parâmetros ligados ao algoritmo genético e geração da interface das Galerias Inteligentes.

Nossa interface gráfica é composta de dois tipos de objeto:

- Mosaico de parâmetros: Uma região da interface onde os parâmetros  $\omega_i$  são representados por suas imagens resultantes  $\pi(\omega_i)$  em baixa resolução.
- Visualizador de parâmetros: Uma região onde o usuário visualiza um determinado parâmetro selecionado  $\omega_i$  através de sua imagem  $\pi(\omega_i)$  em alta resolução.

Diversas maneiras de organizar a disposição desses objetos são encontradas na literatura (26, 39). Adotamos uma disposição onde o visualizador é centralizado na interface, e o mosaico compõe a borda da interface, como ilustrado na figura 4.3.

A quantidade de parâmetros de uma galeria influencia as dimensões das imagens no mosaico, garantindo que todos os parâmetros sejam visíveis. Um aspecto a ser analisado é a quantidade de parâmetros ideal em cada galeria, principalmente na inicial. Para cobrir bem o domínio dos parâmetros  $\Omega$ , a quantidade de amostras do conjunto  $\Psi$  deve ser alta. Porém, este excesso de




Figura 4.4: Exemplo de galeria com excesso de parâmetros.

parâmetros pode gerar duas inconveniências: o trabalho de classificação torna-se exaustivo para o usuário; e o conseqüente ajuste da resolução das imagens  $f(\omega_i)$  do mosaico na interface, tornando-as incompreensíveis pelo usuário, como na figura 4.4.

Uma análise aprofundada desta interface está fora do escopo deste trabalho. Porém, em experimentos simples realizados com usuários, chegamos à conclusão de que galerias com 20 a 36 parâmetros expressam bem a informação para o usuário, além de cobrir razoavelmente bem o espaço de parâmetros em diversos problemas. Eventualmente, os parâmetros podem ser apresentados em galerias sucessivas antes da reprodução. Destacamos que diversos exemplos de galerias, gerados exclusivamente para ilustrar este texto, têm quantidade de parâmetros reduzida para tornarem-se mais visíveis.

A quantidade de parâmetros de cada galeria está diretamente ligada à configuração do algoritmo genético. Em particular, a dimensão de  $\Omega$  tem que ser pequena para permitir que o algoritmo genético funcione corretamente com poucos parâmetros por galeria (ver seção 7.1). No caso da geração da galeria inicial, esta configuração pode ser ajustada diretamente na fase de geração da população inicial. Nas galerias resultantes de reproduções de parâmetros selecionados pelo usuário, é necessário ajustar a quantidade de pais (seleções do usuário) com a quantidade de filhos gerados por cada par de pais. Este cálculo está descrito na seção B.2 do apêndice B, onde a quantidade de filhos  $\nu$  de cada pai pode ser ajustada para se aproximar o máximo possível da quantidade de parâmetros ideal da galeria.