Adaboost and multi-orientation 2D Gabor-based noisy iris recognition

Resumo por:

Vinícius M. de Almeida e Vinícius Queiroz

Sobre o artigo

- **Autores:** Qi Wang, Xiangde Zhang, Mingqi Li, Xiaopeng Dong, Qunhua Zhou, Yu Yin.
- **Publicação:** 2012 Pattern Recognition Letters (A1)
- **Citações:** 24
- Segundo lugar na competição NICE:II, dentre 67 participantes

Introdução

- Apresenta um método de reconhecimento de íris em imagens com ruídos utilizando Adaboost e 2D Gabor-based;
- Sistema dividido em 4 fases:
 - segmentação e normalização
 - divisão da íris
 - extração de características (2D Gabor-based)
 - reconhecimento (Adaboost);
- Foi utilizada a base de dados UBIRIS v2;

Método proposto (Resumo)

- Segmentação da íris e pupila
 - Segmentação Íris
 - Avaliação da pupila para segmentação;
 - Normalização Íris;
 - Rubber sheet para normalização da AS-Íris;
 - Rubber sheet simplificado para normalização da IAS-Íris;
- Construção do conjunto de Características
 - Verificando divergência de textura;
 - Divisão da íris;
 - Construção do conjunto de características;
- Aprendizado Adaboost
- Processo de reconhecimento
- Decidability

Segmentação da Iris (1º)

- Para estimar as bordas foi usando uma mascara passada pela competição;
- Dectecção de ruidos pelo algoritmo circular de Gabor;
- Segmentação das palpebras por RANSAC;
- Por final a pupila e as bordas foram detectadas pelo operador íntegro-diferencial (Daugman)

Avaliação da segmentação da pupila

- A função para cálculo do *error* utilizada é:

$$Err = \frac{\sum_i \sum_j O(i,j) \cdot C(i,j)}{\sum_i \sum_j O(i,j)}$$

$$O(i,j) = \begin{cases} 1, & (i,j) \text{ lies in pupil and } I(i,j) \text{ is not noise} \\ 0 & \text{otherwise} \end{cases}$$

Onde O é o limiar encontrado na operação anterior, e C e a mascara classificada manualmente

- Compara o *error* com constante T_{Err} ;
- Classifica em dois tipos:
 - AS-Iris : Error menor que T_{Err} ;
 - IAS-Iris : Error maior que T_{Err} ;

Normalização da Iris

Transforma as coordenadas da Imagem $X(r,0)$ e $Y(r,0)$ segundo a classificação com as formulas abaixo:

- Rubber sheet para normalização da AS-Iris

$$x(r, \theta) = (1 - r)x_{pupil}(\theta) + rx_{outer}(\theta)$$

$$y(r, \theta) = (1 - r)y_{pupil}(\theta) + ry_{outer}(\theta)$$

Coordenadas das pupilas (pupil) e dos limites externos(outer)

- Rubber sheet simplificado para normalização da IAS-Iris

Devido ao error desconsidera as coordenadas das pupilas

$$x(r, \theta) = rx_{outer}(\theta)$$

$$y(r, \theta) = ry_{outer}(\theta)$$

Verificando divergencia da textura

- A textura e codificada pelo em um plano 2D pelo filtro multidirecional de Gabor.

$$G(x,y) = \frac{1}{2\pi\delta_x\delta_y} \exp\left(-\frac{1}{2}((x')^2\delta_x^2+(y')^2)\right) \times \exp(\sqrt{-1} \times 2 \times \pi \times w \times x')$$

Onde $x'=x\cos\theta+y\sin\theta$, $y'=-x\sin\theta+y\cos\theta$ na direção de gabor, e $\sigma_x \sigma_y$ e a variação de altura e largura

Fig. 1. Gabor filters with $\theta = i\pi/8$, $i = 0, 1, 2, \dots, 7$.

Verificando divergencia da textura

- Após codificado o resultado e normalizado com a seguinte formula:

$$C_{(Re,Im)}(x, y) = \text{sgn}_{(Re,Im)}[I(x, y) * G(x, y)] \quad \text{sgn}(x) = \begin{cases} 1, & x \geq 0 \\ 0, & x < 0 \end{cases}$$

Fig. 2. Examples of Gabor filters with $\theta = 0, \pi/2$ and codes of normalized iris.

Verificando divergência da textura

- Mede a divergencia de cada parte da iris
- Por final é feito um uma verificação da divergencia sobre a seguinte formula:

$$HD = \frac{\|XOR(code_A, code_B) \cap mask_A \cap mask_B\|}{\|mask_A \cap mask_B\|}$$

Onde $code_A$ e $code_B$ são os codigos binarios das iris A e B, e $mask_A$ e $mask_B$ suas mascaras de ruidos

Divisão da Iris

- Regiões internas são mais detalhadas que externas;
- Divide a iris em $M \times N$ partes;
- A partir da normalização rubber sheet.

Q. Wang et al./Pattern Recognition Letters 33 (2012) 978–983

Fig. 3. Examples of iris division. (a) Division of AS-Iris, (b) normalization of (a), (c) division of IAS-Iris, and (d) normalization of (c).

Construção do conjunto de características

- Utiliza o dados calculados pelo formula HD;
- feitos varias orientações diferentes da iris $\theta = ip/L$, $i=0, 1, 2, \dots, L-1$, como demonstrado na figura;
- Apos isto computa HD para cada divisão;

$$\text{Let } F_{\text{patch}} = \{HD_1^0, HD_1^1, \dots, HD_1^{L-1}, \dots, HD_{MN}^0, HD_{MN}^1, \dots, HD_{MN}^{L-1}\}$$

- Para cada orientação $|F_{\text{patch}}| = M \times N \times L$;
- A característica é $F_{\text{WP}} = F_{\text{Whole}} \cup F_{\text{patch}}$
- Onde a característica F_{WP} e composta por $(M \times N + 1) \times L$ HDs.

Aprendizagem por Adaboost

- Seleciona um subconjunto de características
- Conjunto de treinamento rotulado em intra-classe ou inter-classe.
- Retorna a dissimilaridade entre as duas entradas.

Dissimilaridade e decidibilidade

$$\sum_{t=1}^{t=T} \alpha_t h_t(x) \in [-1, 1]$$

$$S(x) = 0.5 * \left(1 - \sum_{t=1}^{t=T} \alpha_t h_t(x) \right) \in [0, 1].$$

$$d' = \frac{|\mu_1 - \mu_2|}{\sqrt{\frac{\sigma_1^2 + \sigma_2^2}{2}}}$$

Fig. 4. Flow chart of recognition process of propose method.

Experimentos

- Adaboost_{AS}
 - Da base de treino contendo 1000 imagens, foram selecionadas 810, com pupilas bem segmentadas.
 - Rubbersheet com $M=3$, $N=4$, $L=8$.
 - Selecionou-se 2325 pares de intra-classe e 2075 pares de inter-classe para treinamento
- Adaboost_{IAS}
 - Utilizaram as mesmas 810 imagens para treino.
 - Mas aplicou rubbersheet com $M=4$, $N=4$, $L=8$.
 - Selecionou a mesma quantidade de pares de intra-classe e inter-classe.

Resultados

Fig. 5. Decidability curve with an increasing dimension of feature.

Resultados

Table 1

The four most discriminative features selected by Adaboost_{AS}.

Rank of feature	Region	Orientation of Gabor
1	Whole	$\theta = 0$
2	D2	$\theta = 7\pi/8$
3	D3	$\theta = 0$
4	L3	$\theta = 7\pi/8$

Table 2

The 4 most discriminative features selected by Adaboost_{IAS}.

Rank of feature	Region	Orientation of Gabor
1	D3	$\theta = 0$
2	Whole	$\theta = 0$
3	D3	$\theta = \pi/4$
4	L4	$\theta = 3\pi/4$

Resultados

Fig. 6. Distribution of dissimilarity of Adaboost_{AS} on the selected 810 images from NICE:II training database.

Fig. 7. Distribution of dissimilarity of Adaboost_{IAS} on the selected 810 images from NICE:II training database.

Obrigado!

Dúvidas?

Referências

[1] - Q. Wang, X. Zhang, M. Li et al., Adaboost and multi-orientation 2D Gabor-based noisy iris recognition [J], Pattern Recognition Letters, 33(8), 2012, 978-983