

OS EFEITOS DA ILUMINAÇÃO E DA POSE NO RECONHECIMENTO DE FACE HUMANA

INTRODUÇÃO

Embora impulsionado recentemente pelos pesquisadores da área, o reconhecimento de face ainda sofre com problemas não resolvidos, como os efeitos da idade, iluminação, variação na pose e na expressão facial. Neste trabalho discutimos os efeitos que a iluminação e a pose causam na face.

A variação da fonte luminosa que está incidindo na face pode causar alterações significativas na imagem, tais como, aumento do brilho, contraste e mudanças de sombras, ilustrado na figura abaixo



A variação da posição da face também têm efeitos dramáticos na sua aparência, podendo causar problemas no seu formato e/ou dimensionamento. Por exemplo, se a distância entre os olhos em uma imagem frontal é de "1 cm", essa medida não será igual quando a face estiver inclinada ou virada para um dos lados.

Para tentar solucionar estes problemas, são utilizadas diversas abordagens, dentre elas, o Principal Component Analysis (PCA), que tem mostrado ser um método muito eficiente nos sistemas de reconhecimento de faces.

A idéia do uso do PCA consiste em encontrar, a partir de uma matriz covariância, os autovetores e autovalores que melhor representam uma face. Como os autovetores correspondem às faces originais e, como estas são similares na aparência, são conhecidas como "autofaces".

Um aspecto importante do PCA é que, combinando as autofaces é possível reconstruir qualquer face a partir da base de dados. Assim, as autofaces na fase de classificação são utilizadas para obter pesos que classificarão as faces em relação à uma determinada face consulta, como sendo conhecidas ou não.

AUTOFACES

Seja $\Gamma(x,y)$ uma imagem de uma face, representada por um vetor de dimensão nm . Estes vetores definem um subespaço de faces, no qual chamamos de "face space". Cada vetor de comprimento nm , descreve uma imagem $n \times m$ e, é uma combinação linear das faces originais. Como esses vetores são os autovetores da matriz covariância correspondente às faces originais e, como as faces são similares na aparência, elas são chamadas de "autofaces".

Dado uma base de dados de faces, onde M é o número de faces contidas na base de dados, obtém-se a face média definida por

$$\Psi = \sum_{n=1}^M \Gamma_n$$

O quanto cada face presente na base de dados difere-se da face média é dada pelo vetor

$$\Phi_i = \Gamma_i - \Psi$$

O conjunto $\Phi_i, i = 1, \dots, M$ é chamado de PCA, que busca um conjunto de M vetores ortonormais (V) e seus autovalores associados (λ) que melhor descrevem a distribuição dos dados. Estes vetores V são os autovetores da matriz covariância C

$$C = \frac{1}{M} \sum_{n=1}^M (\Phi_n \Phi_n^t) = AA^t$$

onde, $A = [\Phi_1 \ \Phi_2 \ \dots \ \Phi_M]$. Entretanto, este cálculo gera uma matriz C com nm autovetores e autovalores.

Considere os autovetores V_n de AA^t tal que uma forma de diminuir o processamento é dada por AA^t . Ao invés de se calcular os autovetores de AA^t calculam-se de AA , multiplicando ambos os lados de $A^t AV_n = \lambda_n V_n$ por A , ou seja, $AA^t AV_n = \lambda_n AV_n$ onde AV_n são os autovetores de $C = AA$. Seguindo esta análise, construímos a matriz $M \times M$ de $L = AA$, onde $L_{mn} = \Phi_m^t \Phi_n$, e encontramos os M autovetores V_n de L . Desta forma os cálculos ficam reduzidos, a partir do número de pixels da imagem ($n \times m$) para o número de imagens do conjunto de faces (M). Os autovalores associados permitem organizar os autovetores de acordo com sua capacidade de caracterizar as variações entre as faces.

CLASSIFICANDO AS FACES

Uma vez obtida as autofaces, é necessário classificá-las para uma posterior identificação. Os autovetores mais significativos obtidos pela matriz L são escolhidos de acordo com os seus maiores autovalores. Como, para cada face da base de dados há um autovetor associado ao seu maior autovalor, calcula-se a relação destes vetores (V) com a matriz A (matriz que contém a diferença de cada face presente na base de dados com a face média), pela fórmula $P = VA$.

Seguindo, calcula-se $\omega_k = P'(\Gamma_c - \Psi)$ para $k=1,2,\dots,M$. Os resultados obtidos formam um vetor $\Omega' = [\omega_1 \ \omega_2 \ \omega_3 \ \dots \ \omega_M]$, que descreve a contribuição de cada autoface em representar as faces presentes na base de dados. Dada uma nova face Γ_c , calcula-se a contribuição de cada autoface em representar essa nova face por

$$\omega_c = P' (\Gamma_c - \Psi)$$

Depois de calculados os pesos Ω' e ω_c , é preciso determinar quais são as faces que melhor representam a nova face. Assim calcula-se a distância Euclidiana ε por $\varepsilon = \|\omega_c - \omega_k\|$ para $k=1,2,\dots,M$. Gera-se um rank em ordem crescente onde, os menores pesos correspondem à maior similaridade entre as faces da base de dados e a nova face.

ALEXANDRE FIENO DA SILVA

Faculdade de Computação, FACOM, UFU

38400-400 - Uberlândia - MG

alexandre@pos.facom.ufu.br

Célia A. Zorzo Barcelos

celiazb@ufu.br

Ilmério Reis da Silva

Faculdade de Computação, FACOM, UFU

ilmerio@ufu.br