

APRENDIZADO DE VARIEDADES RIEMANNIANAS

Lucas Pereira Carlini¹, Gastão Florêncio Miranda Junior², Gilson Giraldd³, Carlos Eduardo Thomaz¹

¹Laboratório de Processamento de Imagens, Centro Universitário FEI (FEI), São Bernardo do Campo, SP

²Departamento de Matemática, Universidade Federal do Sergipe (UFS), Sergipe, Brasil

³Laboratório Nacional de Computação Científica (LNCC), Petrópolis, RJ

lucaspcarlini10@gmail.com, cet@fei.edu.br

Resumo: *Aprendizado de Variedades é um conjunto de técnicas não-lineares de redução de dimensionalidade de dados. Um dos mais utilizados algoritmos de aprendizado de variedades denomina-se Riemannian Manifold Learning (RML). Este trabalho implementa um novo método para o RML de seleção de vizinhos seguros que mostra resultados igualmente satisfatórios e menor sensibilidade à densidade de amostragem da variedade.*

1. Introdução

Há um grande interesse no uso de sistemas computacionais para classificar e reconhecer características de faces humanas devido ao fato de que o cérebro humano realiza tais funções de maneira instantânea e eficiente. Para o computador realizar essas tarefas, é necessário o uso de diversos métodos de extração de tais características.

Neste contexto, este trabalho tem como objetivo inicial estudar técnicas de redução de dimensionalidade com o intuito de extrair as características da face humana para a classificação posterior da mesma. São elaborados dois modelos: geométrico e estatístico. No modelo geométrico [1], é estudado as dimensões da face humana com a hipótese de que tais dimensões formam um conjunto de características antropométricas. Já no modelo estatístico, é utilizado um algoritmo de redução de dimensionalidade denominado *Principal Component Analysis* [2], no qual procura-se extrair uma combinação de informações intrínsecas da face humana por meio do uso dos conceitos estatísticos de variância e covariância.

Como objetivo principal deste estudo, tem-se uma proposta de melhoria para o algoritmo de Aprendizado de Variedades Riemannianas (*Riemannian Manifold Learning, RML*) [3] [4]. O RML necessita de parâmetros de entrada determinados experimentalmente para seu bom funcionamento. Visando esse fato, o presente trabalho tem como objetivo implementar um novo método baseado em análise massivamente univariada das diferenças locais estatisticamente significantes entre os dados [2].

2. Metodologia

O modelo geométrico utilizado no experimento é apresentado na Figura 1 - Modelo Geométrico. Para a delimitação dos pontos fornecidos, utiliza-se da base de imagens de faces da FEI [5] em conjunto com a dissertação de E. Quiroga [1]. Os pontos utilizados são: região do nariz (cor vermelha): cavidade nasal esquerda e direita, e contorno superior lateral esquerdo e direito; região do olho (cor azul): canto externo, centro superior, canto interno e centro inferior do olho esquerdo e direito; região da boca (cor verde): canto externo esquerdo e

direito da boca. Com isso, foi realizado o cálculo da distância euclidiana dos pontos de cada grupo para a definição das três métricas de estudo.




Figura 1 - Modelo Geométrico.

Por outro lado, o modelo estatístico, utilizando-se do *PCA* [2], leva em consideração a variância de todos os pixels da imagem. Com isso, são encontradas as direções (ou componentes) que apresentam maior variação, permitindo que as redundâncias dos dados sejam desprezadas. Nos experimentos feitos, foram considerados as três principais componentes que representam as maiores variâncias dos dados.

Focando no principal objetivo deste trabalho, tem-se um novo método para uma etapa específica do algoritmo *RML* [3] [4]. Em algoritmos de aprendizado de variedades é necessária a reconstrução da estrutura local dos dados com o intuito dos mesmos serem mapeados, e com isso representá-los em um espaço de dimensão menor. O *RML* utiliza para essa reconstrução um algoritmo de detecção de saltos baseado em conceitos vindos do *PCA*, explicado detalhadamente em [3] e [4]. É presumido que o dado não pertencente à estrutura local (chamado de curto-circuito) se encontra mais distante dos demais, por esse motivo utiliza-se da idéia de saltos. No entanto, o algoritmo necessita de parâmetros de entrada que funcionam como restrições para a estimação das propriedades locais dos dados. Essas propriedades são a dimensão intrínseca local e vizinhança segura. O algoritmo tem as seguintes etapas: **1.** Cálculo dos vizinhos mais próximos ao ponto de estudo x_i , conjunto K -*NN* (x_i); **2.** Cálculo dos pontos visíveis a x_i , conjunto VN (x_i); **3.** Obtenção do conjunto seguro SN (x_i), utilizando da detecção de saltos.

Com o intuito de evitar esses parâmetros empíricos, a proposta de substituição da etapa 3 (dita acima) utiliza-se da Distribuição Normal Multivariada [6]. O novo método possui como idéia principal construir uma área estatisticamente segura ao redor do ponto (ou dado) que está sendo estudado. Para isso, aplica-se o *PCA* local no conjunto VN (x_i) para reduzir a dimensionalidade e ortogonalizar o mesmo, e em seguida, é calculado a média, variância e desvio padrão para cada dimensão de tais dados.

A vizinhança segura é definida pela equação (1), ilustrada na Figura 2 - Proposta.

$$SN(x_i) = \{y \in VN(x_i); x_{ij} - \sigma_j \leq y_j \leq x_{ij} + \sigma_j, j = 1, \dots, d\} \quad (1)$$

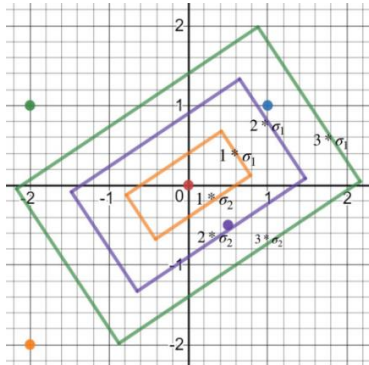


Figura 2 - Proposta.

3. Resultados Obtidos

Para o modelo geométrico, foi obtida com sucesso a classificação de expressão facial da base de faces da FEI. Após analisar os resultados, foi constatado que apenas a informação referente à distância entre os pontos da boca era necessária. Portanto, tal informação é considerada discriminante em relação às outras.

Para a classificação por gênero, foi obtido sucesso quando utilizado o modelo estatístico. Observando os resultados, foi concluído que apenas a primeira componente principal do *PCA* carrega as características necessárias para tal classificação, podendo as outras serem desprezadas.

Analisando agora os resultados obtidos pelo algoritmo proposto como parte do *RML* para a reconstrução da estrutura local dos dados, foram constatados bons resultados na remoção de pontos de curto-circuito. Para esses experimentos foi utilizado também bases de dados sintéticos, vastamente exploradas na literatura afim [3] [4]. Um exemplo de navegação parcial na variedade é encontrado na Figura 3 – Navegação.




Figura 3 – Navegação.

Foram constatadas também situações em que o algoritmo proposto pode apresentar falhas, sendo as mesmas causadas pela definição imprecisa da estrutura da base de dados. Essas situações foram corrigidas com o uso de poucos desvios padrões para a construção da área estatisticamente segura.

Uma comparação dos resultados encontrados em imagens de faces pelo algoritmo proposto (sequência

superior) e original (sequência inferior) é mostrada na Figura 4 – Navegação em Faces.




Figura 4 – Navegação em Faces.

É possível observar que o algoritmo proposto tende a preservar as características locais dos dados (ou faces), como a expressão facial e semelhança entre os indivíduos. Já o algoritmo original tende a preservar as características globais, alternando entre as expressões faciais de pessoas com diferentes características em sua fisionomia.

4. Conclusões

Na primeira parte deste trabalho foi realizado um estudo sobre características discriminantes e redução de dimensionalidade de imagens de faces. Tal estudo permitiu uma compreensão maior sobre os conceitos fundamentais de Aprendizado de Variedades necessários para a criação de um novo método de seleção de vizinhos seguros para o *RML*.

O algoritmo proposto apresentou uma metodologia alternativa, e igualmente satisfatória, de reconstrução da estrutura local da variedade onde os dados estão contidos, priorizando as similaridades de característica-por-característica dos dados, junto com uma menor complexidade de implementação.

5. Referências

- [1] QUIROGA, E. Z. T. Análise Multilinear Discriminante de Formas Frontais de Imagens 2D de Face. (Dissertação de Mestrado) Centro Universitário FEI, 2012.
- [2] JOHNSON, R. A.; WICHERN, D. W. Applied Multivariate Statistical Analysis Sixth Edition.
- [3] LIN, T.; ZHA, H. Riemannian Manifold Learning. IEEE Trans. Pattern Analysis and Machine Intelligence, vol. 30, no. 5, 2008.
- [4] MIRANDA JUNIOR, G. F.; GIRALDI, G. A. Aprendizado de Variedades: Aspectos Geométricos e Aplicações. Laboratório Nacional de Computação Científica - LNCC/MCTI, Novembro de 2012.
- [5] <https://fei.edu.br/~cet/facedatabase.html>. Acesso em 01 set. 2017.
- [6] TONG, Y. L. The multivariate normal distribution. Springer Series in Statistics. New York: Springer-Verlag, 1990.

Agradecimentos

À instituição Centro Universitário da FEI pela concessão da bolsa, e ao meu orientador pelo conhecimento que adquiri sob a orientação do mesmo.

¹ Aluno de IC do Centro Universitário FEI. Projeto com vigência de 08/17 a 07/18.