

# Face Slicing on Facial Recognition: An Action Units Based Investigation of the Possible Improvements by Selecting the Face Regions in a Point Cloud 3D Data

Patricia J. O. Martins<sup>1</sup>, José M. Soares<sup>2</sup>, George A. P. Thé<sup>2</sup>

<sup>1</sup>Instituto Federal de Educação, Ciência e Tecnologia do Ceará (IFCE)  
Campus Canindé - CE – Brazil  
Programa de Pós-graduação em Engenharia de Teleinformática (PPGETI - UFC)

<sup>2</sup>Departamento de Engenharia de Teleinformática (DETI)  
Universidade Federal do Ceará (UFC) – Fortaleza, CE – Brazil

patricia.martins@ifce.edu.br, {marques, george.the}@ufc.br

**Abstract.** *In this paper is proposed an investigation on slicing process applied on 3D Point Cloud data, representing individuals faces, on individual face recognition problem. For this, we compare results from classification using either sliced or no sliced faces. Also we compare two slicing types: Triaxial Slicing and Pizza Overlapped Slicing - here proposed. The purpose of the comparisons is to investigate if selecting specific regions of the 3D face can improve classification results. The results are promising, indicating that a refinement of the technique can generate a robust classification of individuals to face variations.*

**Resumo.** *Neste artigo é proposta uma investigação para fatiamento de nuvens de pontos 3D, que representam rostos, dentro do problema de reconhecimento de faces. Para isso, é feita uma comparação entre os resultados de classificação com e sem fatiamento das faces, utilizando características geométricas no processo de extração de informação. Também foram comparados dois tipos de segmentação em subnuvens, o fatiamento Triaxial e o fatiamento em Pizza com Superposição - aqui proposto. O objetivo das comparações é investigar se a seleção de regiões específicas da face 3D pode aprimorar os resultados da classificação. Os resultados mostram-se promissores, indicando que um refinamento da técnica pode gerar uma classificação de indivíduos robusta a variações da face.*

## 1. Introdução

O reconhecimento de faces 3D tem ganho popularidade na indústria e na academia. Porém, um dos desafios nesse domínio é a grande variabilidade na superfície da face causada por expressões, como um sorriso, medo ou nojo, ou por algum tipo de oclusão. Assim, os reconhecedores de faces devem ser suficientemente robustos a deformações dessa natureza para a classificação.

Estudos sobre expressões faciais catalogaram regiões de alta variabilidade na face do indivíduo quando ele apresenta uma expressão facial e podem ser usados para contornar este problema. Um exemplo disso são as Unidades de Ação (*Action Units* - AU), as quais estão definidas no Sistema de Codificação de Ação Facial (*Facial Action Coding*

*System* - FACS) [Ekman and Friesen 1978], que permite a associação de unidades de ação muscular da face e expressões emocionais. Esses AUs são frequentemente considerados em sistemas de reconhecimento de expressões faciais.

A região ao redor dos olhos, sobrancelhas e boca apresentam grande variação em diferentes expressões e também são as regiões que contêm mais informações sobre a face, sendo áreas bastante utilizadas na seleção de *landmarks* em reconhecimento de faces 2D [Zhao et al. 2003], [Shepley 2019].

Assim, estima-se que haja a possibilidade de extrair essas informações, tornando um reconhecedor de faces mais robusto a expressões faciais diferentes. As imagens 3D oferecem informação de características geométricas da face capazes de melhorar o desempenho de sistemas de reconhecimento em comparação àqueles baseados em imagens 2D [Hariri et al. 2016] [Soltanpour et al. 2017].

Há diferentes formas de realizar a segmentação na face, como as técnicas apresentadas em (*Extended Gaussian Image* - EGI), [Lee and Milios 1991], [G. Gordon 1991], [Tanaka et al. 1998], [Jafri and Arabnia 2009] e nos *surveys* [Bowyer et al. 2004], [Kavita 2016] e [Reddy et al. 2018]. Muitos desses trabalhos utilizam apenas faces neutras (sem expressões faciais), pois é o tipo de face mais comum em bases de dados tradicionais [Bowyer et al. 2004]. Neste trabalho, adotam-se os termos segmentação e fatiamento como a separação de um subconjunto da nuvem de pontos obtido por meio de um critério de seleção.

No que se refere aos métodos de extração de características, três principais categorias são apresentadas na literatura: com base em atributos holísticos ou globais, com base em atributos locais e métodos híbridos. Os trabalhos que se baseiam em atributos locais focam na extração dos atributos da face ou de regiões relevantes desta (região dos olhos e nariz ou *keypoints*, por exemplo). Por não requererem modelos completos da face, métodos baseados em atributos locais lidam melhor com situações de oclusão, auto-occlusão e expressões, sendo mais apropriados para propósitos de identificação e verificação [Soltanpour et al. 2017]. Além disso, por tratar de nuvens de pontos com menos amostras, o seu processamento é mais rápido.

A face não é um corpo rígido e as regiões de alta variabilidade prejudicam a classificação. Visto que as taxas de acerto são maiores quando são utilizadas faces neutras [Soltanpour et al. 2017], o desafio de identificar indivíduos com diferentes expressões é encontrar a melhor forma de extrair informações da face mesmo quando ela apresenta variações em sua superfície. Nesse sentido, selecionar segmentos da face e analisar as AUs pode ser útil.

Este trabalho tem como objetivo propor uma forma de segmentação de faces representadas por nuvens de pontos para extração de características e classificação de indivíduos. Essa nova forma de segmentação é denominada de "fatiamento em pizza com sobreposição". Além disso, diferentes formas de segmentação são analisadas, buscando-se segmentos específicos, mais adequados para o problema do reconhecimento de faces. Extratores geométricos, utilizados em outros domínios de aplicação com o uso de nuvens 3D, também são investigados para o contexto de reconhecimento de faces.

A organização deste artigo é a seguinte: a Seção 2 sumariza os passos realizados no processamento dos dados; a Seção 3 detalha a etapa de pré-processamento; a Seção 4

detalha as duas formas de segmentação utilizadas, uma já existente e outra proposta neste trabalho; a Seção 5 detalha os extratores de características geométricas; a Seção 6 detalha os classificadores utilizados; a Seção 7 apresenta os resultados experimentais e a discussão sobre os resultados alcançados; e a Seção 8 expõe as conclusões.

## 2. Metodologia

Um aspecto fundamental deste trabalho é a identificação de regiões da face, capturada como nuvem de pontos em 3D, que mais influenciam no processo de identificação de indivíduos e de emoções que suas faces esboçam. As AUs no rosto podem formar emoções que prejudicam a identificação de um indivíduo. Estima-se, portanto, que a redução ou a anulação da influência dessas regiões podem gerar um resultado positivo no processo de classificação, tornando-o mais robusto a expressões faciais.

Para isso, neste trabalho, busca-se definir regiões (subnuvens) durante o processo de segmentação da face da nuvem de pontos que representam a face. Considera-se a ponta do nariz como referência para definição do eixo central e recortam-se partes da nuvem de pontos ao redor dele, como em segmentos de pizza, a fim de destacar informações de AUs da face.

Para testar essa hipótese, é necessária a utilização de um conjunto de dados de faces 3D. No intuito de verificar a influência dos extratores de características geométricos, são também utilizados diferentes tipos de extratores em conjunto com o novo tipo de corte. O objetivo é verificar se há um resultado de classificação que indica melhorias em relação a casos sem segmentação ou com outro tipo de segmentação. Caso isso ocorra, fica identificada como promissora essa composição de fatiamento em pizza.

Muitas bases de dados têm sido utilizadas com o propósito de realizar o reconhecimento facial de imagens 3D, como: BU-3DFE de [Yin et al. 2006], FRGC v2.0 de [Phillips et al. 2005], Bosphorus de [Savran et al. 2008], 3DMAD de [Erdogmus and Marcel 2013], GavabDB de [Moreno and Sánchez 2004], entre outros. A Bosphorus certamente é uma das mais desafiadoras, pois traz uma diversidade de expressões que não é vista em outra base de dados com a mesma finalidade. Isso exposto, optou-se por iniciar o estudo proposto neste artigo com a base de dados Bosphorus.

A Bosphorus possui amostras 3D com as respectivas coordenadas dos pontos chave localizadas nas Unidades de Ação (Action Units - AU), definidas por [Ekman and Friesen 1976]. Entre esses pontos chave está a ponta do nariz, que é utilizada na abordagem proposta neste trabalho durante o pré-processamento e a extração de características. A base consiste em 4.666 amostras faciais de 105 indivíduos em diversas condições distintas, capturadas usando o *scanner Inspeck 3D*.

O conjunto de dados escolhido é composto pelas amostras neutras, todas as emoções (raiva, tristeza, alegria, medo, nojo e surpresa) e também unidades de ação da parte baixa do rosto (*Lower Face Action Units - LFAU*), unidades de ação da parte alta do rosto (*Upper Face Action Units - UFAU*) e unidades de ação combinadas (*Combined Action Unit - CAU*). Das 4.666 amostras disponíveis na base, portanto, são utilizadas 2.902. As demais amostras contêm elementos distintos do propósito desse estudo, como oclusão e diferentes graus de rotação. Parte-se do pressuposto de que o rosto capturado está alinhado em relação a sua base e que não há oclusão.

As etapas de processo de classificação realizadas na base de dados são exibidas na Figura 1;

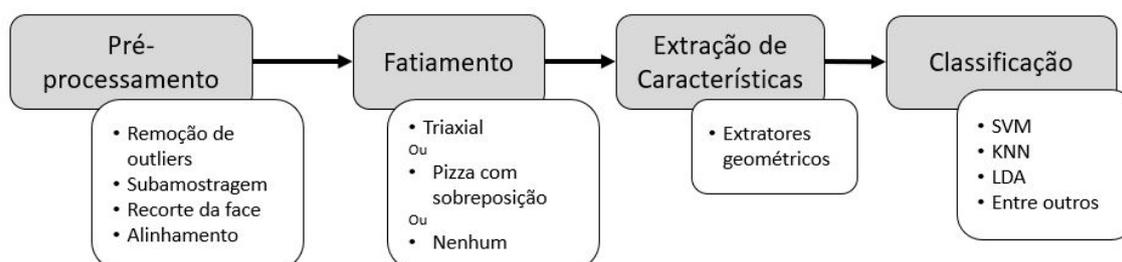


Figura 1. Etapas do processo de classificação de uma imagem 3D

## 2.1. Cenários de experimentação

Com o intuito de manter formas de comparação com outros trabalhos, utilizamos os cenários mais comuns descritos em [Soltanpour et al. 2017].

O primeiro experimento é o **Rank-1**, o mais completo e complexo uma vez que utiliza como base de dados de treinamento apenas uma amostra neutra por indivíduo. É considerado o mais complexo porque o método deve ser de tal forma robusto que, com apenas uma amostra de um indivíduo, seja possível reconhecer outras amostras do mesmo indivíduo com ou sem expressões. Dessa forma, os atributos devem ser praticamente invariantes a grandes deformações da face. Utiliza-se a primeira amostra neutra de cada indivíduos como sendo para formar o conjunto de treinamento. Neste caso, há dois tipos de sub-experimentos: **Rank-1a**, Neutro vs Neutro, e **Rank-1b**, Neutro vs Não-Neutro. O terceiro experimento é o **ROC-I**, o mais comum e basicamente faz o confronto entre as amostras Neutras e Não-Neutras.

## 3. Pré-processamento

A base passou por algumas etapas de pré-processamento, utilizando funções da biblioteca PCL (*Point Cloud Library*) [Rusu and Cousins 2011], construída na linguagem C++:

1. Remoção de outliers utilizando a função `pcl::RadiusOutlierRemover` com raio de busca igual a cinco milímetros e mínimo de dez vizinhos dentro do raio.
2. Subamostragem utilizando a função `pcl::VoxelGrid` com cada *voxel* igual a um cubo de aresta dois milímetros.
3. Recorte da face para remover *background*, partindo da ponta do nariz e com raio 80mm, no formato de esfera.
4. Alinhamento das amostras em duas etapas, na tentativa de deixar o alinhamento mais preciso. Em ambas as etapas são usadas um corte de esfera com 35mm de raio, deslocada em 1,5 cm acima da ponta do nariz (+y) e utiliza-se o algoritmo *Iterative Closest Point* (ICP) [Besl and McKay 1992].

A primeira etapa alinha todas as primeiras amostras de faces neutras na coordenada (0, 0, 0), utilizando os seguintes parâmetros: número máximo de iterações igual a 400,  $\epsilon = 0,0001$ , *threshold* de rejeição de outliers do *RANdom Sample Consensus* (RANSAC) de 1 e máxima correlação de 40.

A segunda etapa do alinhamento é feita com todas as demais amostras, mas desta

vez utilizando os seguintes parâmetros: número máximo de iterações igual a 400,  $\epsilon = 0,0001$ , *threshold* de rejeição de outliers do RANSAC de 1 e máxima correlação de 30 . Foi utilizada a função implementada na biblioteca PCL *pcl::IterativeClosestPoint*, que internamente utiliza o RANSAC, algoritmo iterativo usado para estimar parâmetros de um modelo matemático de um conjunto de dados contendo *outliers*. Este algoritmo foi publicado por Fischler e Bolles em 1981 [Fischler and Bolles 1981].

Nas etapas de recorte e de alinhamento da face é necessário utilizar a coordenada na ponta do nariz, fornecidas na própria base de dados Bosphorus.

## 4. Fatiamento

Após a etapa de alinhamento é realizado o fatiamento da face em diferentes segmentos. Esse procedimento ajuda no processamento mais rápido das imagens, pois ao invés de trabalhar com toda a nuvem de pontos, trabalha com seções individuais ou um conjunto delas, com uma menor quantidade de pontos.

Foram avaliados dois tipos diferentes de fatiamento: o fatiamento triaxial, proposto em [Siqueira et al. 2018], e o fatiamento em pizza com sobreposição, que consiste na proposta apresentada neste artigo. Ambos os fatiamentos são descritos nas subseções a seguir.

### 4.1. Fatiamento Triaxial

O fatiamento triaxial é composto de fatias frontais, ao longo do eixo z, fatias sagitais, ao longo do eixo x, e fatias transversais, ao longo do eixo y. A ideia por trás do método está relacionada à natureza das deformações na superfície da face sob variações de expressão. Diferentes regiões sofrem diferentes perfis de deformação ao longo de direções preferíveis, enquanto a expressão facial muda. Aqui utilizam-se os mesmos parâmetros do autor. Cada fatia tem uma largura de  $20mm$  e o fatiamento triaxial é apresentado na Figura 2.

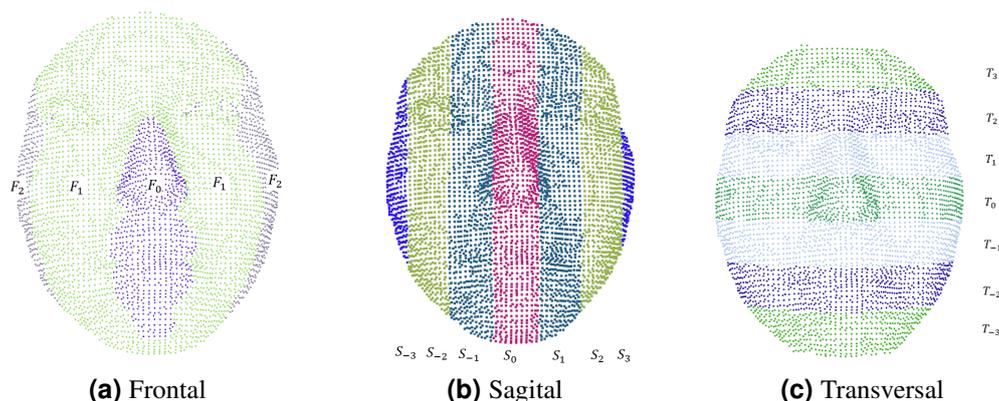


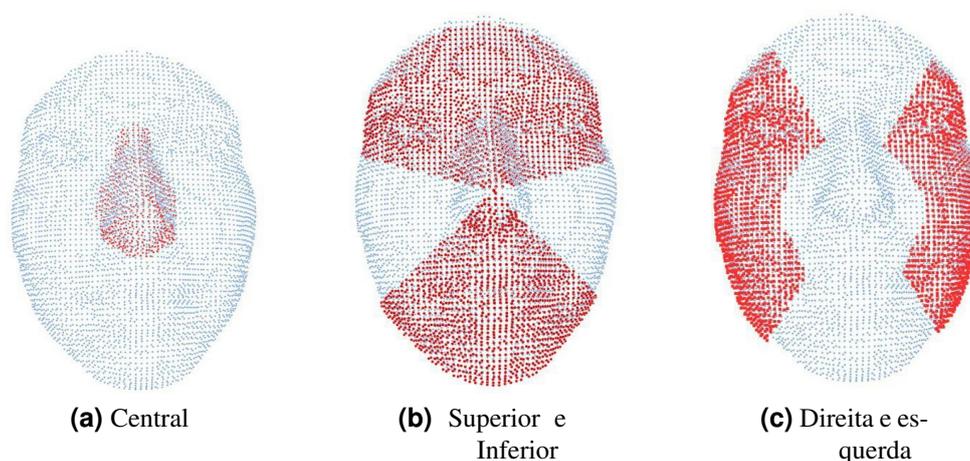
Figura 2. Fatiamento triaxial, seções frontais, sagitais e transversais.

### 4.2. Fatiamento em Pizza com sobreposição

O fatiamento proposto é inspirado nas regiões de maior deformação na face durante a expressão de emoções e permite a seleção de parâmetros independentes para cada

eixo da face, podendo assim permitir a sobreposição de fatias. Essa sobreposição é inspirada nos movimentos da face, pois uma AU participa de mais de uma emoção [Ekman and Friesen 1978]. Assim, um mesmo conjunto de músculos pode ser acionado na expressão de raiva e de medo, por exemplo. Os parâmetros escolhidos e apresentados na lista a seguir foram escolhidos por critérios subjetivos para se obter um caso inicial (Figura 3), no intuito de que mais testes possam ajudar a determinar valores que gerem resultados melhores; e essa é uma das variáveis a ser testada.

- Fatia superior possui raio de corte externo de 80mm e abertura de 150°
- Fatia inferior possui raio de corte externo de 80mm e abertura de 90°
- Fatia esquerda possui raio corte interno de 40mm e abertura de 120°
- Fatia direita possui raio corte interno de 40mm e abertura de 120°
- Fatia central é uma esfera centrada na ponta do nariz com raio de 35mm e deslocamento para cima (em +y) de 15mm.



**Figura 3. Fatiamento em pizza com sobreposição, seções central, Superior e Inferior, e Direita e Esquerda**

## 5. Extratores de Características

A maioria dos extratores utilizados neste trabalho é obtida por meio da manipulação dos autovalores e autovetores da matriz de covariância da fatia da nuvem, o que torna a extração rápida comparada ao cálculo de momentos invariantes. Essas auto-características (*eigen-features*) também foram testadas com outras bases de dados [Lin et al. 2014]. Esses extratores foram inspirados nos descritores escolhidos por [Hackel et al. 2016]. Eles são utilizados como detectores de borda em cenários de detecção de contornos em nuvem de pontos de larga escala de ambientes externos, no intuito de destacar construções em seu meio.

Esse processo de detecção de contornos faz com que as características extraídas por esse método forneçam informações geométricas locais em relação à nuvem de pontos. Com isso, esses extratores de características são utilizados com o objetivo de gerar informações importantes sobre o contorno do rosto e mudanças nas AUs quando há a expressão de uma emoção.

As características usadas são as seguintes:

- $G_1$  Somatório:  $\lambda_1 + \lambda_2 + \lambda_3$
- $G_2$  Omnivariância:  $(\lambda_1 \cdot \lambda_2 \cdot \lambda_3)^{1/3}$
- $G_3$  Autoentropia:  $\sum_{i=1}^3 \lambda_i \cdot \ln(\lambda_i)$
- $G_4$  Anisotropia:  $(\lambda_1 - \lambda_3)/\lambda_1$
- $G_5$  Planaridade:  $(\lambda_2 - \lambda_3)/\lambda_1$
- $G_6$  Linearidade:  $(\lambda_1 - \lambda_2)/\lambda_1$
- $G_7$  Variação de superfície:  $\lambda_3/(\lambda_1 + \lambda_2 + \lambda_3)$
- $G_8$  Esfericidade:  $\lambda_3/\lambda_1$
- $G_9$  Verticalidade:  $1 - |\langle [0 \ 0 \ 1], \mathbf{e}_3 \rangle|$

## 6. Classificação

Seguindo os cenários descritos na Seção 2, o processo de classificação realizado consiste na fase de treinamento com parte da base de dados e teste com a classificação dos dados não usados em treinamento.

Desse teste são computados os acertos e erros dos classificadores a fim de termos uma avaliação quantitativa dos resultados. Foram utilizados múltiplos classificadores por dois motivos: primeiro, para tornar o problema independente de classificador, permitindo assim uma avaliação mais confiável dos resultados quanto ao fatiamento proposto; segundo, para estimar o nível de complexidade de classificador necessário para solucionar o problema. Assim, foram selecionados alguns classificadores comumente utilizados, tanto entre os mais elementares como entre os mais complexos.

Para a realização de um processo exaustivo treinamento, testes e geração de resultados, foi utilizada a biblioteca sklearn [Pedregosa et al. 2011], implementada em linguagem Python. Uma boa parcela desses classificadores são variantes de *Support Vector Machine* (SVM). Os classificadores são:

- SVM, com Kernel RBF (aqui chamado de SVM\_RBF);
- SVM, com Kernel Polinomial (aqui chamado de SVM\_poly);
- SVM, com Kernel Sigmoidal (aqui chamado de SVM\_sig);
- SVM, com Kernel Linear (aqui chamado de SVM\_lin);
- SVM, com Kernel Polinomial, com configuração padrão (aqui chamado de SVM\_pd);
- SVM, com Kernel Linear, com configuração padrão (aqui chamado de SVM\_ld);
- Linear Discriminant Analysis (aqui chamado de LDA);
- KNN, com vizinhança tamanho 1 (aqui chamado de KNN1);
- KNN, com vizinhança tamanho 3 (aqui chamado de KNN3);
- Um comitê de classificadores SVM com kernel RBF na configuração "Um contra todos" (aqui chamado de OneVsRest);
- Gaussiano do tipo Naive Bayes (aqui chamado de GausNB);
- Floresta Aleatória (aqui chamado de RandomForest);
- Árvore de Decisão (aqui chamado de DTree).

O classificador LDA é utilizado somente no caso ROC-I, discutido na Seção 2. O motivo é que esse classificador necessita de mais de uma amostra por classe para o treinamento.

## 7. Resultados

O primeiro experimento realizado utilizou a face inteira, todas as fatias definidas pelo fatiamento triaxial, fatias frontais, sagitais e transversas, e todas as fatias definidas pelo fatiamento em pizza com sobreposição, lado esquerdo, lado direito, lado superior, lado inferior e fatia central. Todos os extratores definidos na Seção 5 foram utilizados e os resultados são exibidos na Tabela 1. Sendo *A* o cenário Rank-1a, *B* o cenário Rank-1b e *C* o cenário ROC-I. Os melhores resultados estão em negrito. Os dois resultados que apresentam fatiamento têm taxas de acerto maiores que os resultados da Face Inteira, em todos os cenários.

**Tabela 1. Resultados obtidos de todos os fatiamentos.**

classi.	Face Inteira			Triaxial			Pizza S.		
	A (%)	B (%)	C (%)	A (%)	B (%)	C (%)	A (%)	B (%)	C (%)
SVM-rbf	<b>60,82</b>	<b>23,63</b>	21,71	<b>93,30</b>	<b>61,04</b>	6,11	<b>73,71</b>	<b>39,34</b>	29,16
SVM-poly	57,22	21,40	19,75	77,32	44,72	51,29	60,82	34,15	39,03
SVM-sig	15,46	5,42	6,38	46,39	23,32	5,46	13,40	4,38	4,38
SVM-lin	<b>60,82</b>	23,63	<b>24,13</b>	<b>93,30</b>	<b>61,04</b>	64,77	<b>73,71</b>	<b>39,34</b>	43,07
SVM_pd	57,22	21,40	16,79	77,32	44,72	31,31	60,82	34,15	23,36
SVM_ld	<b>60,82</b>	<b>23,63</b>	20,86	<b>93,30</b>	<b>61,04</b>	64,77	<b>73,71</b>	<b>39,34</b>	43,07
KNN-1	<b>60,82</b>	<b>23,63</b>	22,90	<b>93,30</b>	<b>61,04</b>	63,81	<b>73,71</b>	<b>39,34</b>	40,91
KNN-3	6,70	15,14	22,94	11,86	29,04	52,86	12,89	22,90	36,69
OneVsRest	51,03	19,13	18,29	90,72	59,66	51,29	<b>73,71</b>	35,46	33,50
GausNB	<b>60,82</b>	<b>23,63</b>	13,37	<b>93,30</b>	<b>61,04</b>	22,97	<b>73,71</b>	<b>39,34</b>	15,17
RandomF	29,90	12,52	18,17	36,60	19,21	29,77	30,93	17,83	25,36
DTree	15,98	8,22	16,67	22,16	12,10	16,37	16,49	8,99	17,63
LDA	-	-	23,78	-	-	<b>73,15</b>	-	-	<b>53,59</b>

Na Tabela 2 são especificadas novas configurações para o Fatiamento de Pizza com Sobreposição. A Config.1 são os parâmetros detalhados na Seção 4 e as Config. 2, 3, 4 foram propostas variando alguns parâmetros isoladamente.

Para avaliar o desempenho do método de fatiamento proposto, realizamos o experimento com diferentes configurações de ângulos e raios internos e externos, descritos na Tabela 2. Na Tabela 3, são apresentados os melhores resultados para cada configuração testada. A Configuração 1 apresentou os melhores resultados e foi escolhida para uma avaliação individual da taxa de acerto de cada fatia. Esses resultados são apresentados na Tabela 4.

É possível observar na Tabela 4, as diferenças sutis entre os resultados para o lado direito e para o lado esquerdo, sendo o lado direito mais significativo na identificação do indivíduo que o lado esquerdo. Essa assimetria entre os lados pode ser ressaltada e ajudar tanto na identificação de indivíduos, objetivo deste trabalho, como na identificação de emoções. Trabalhos como [Sackeim et al. 1978], investigam essa assimetria, propondo o uso de imagens compostas por apenas um dos lados da face concatenando a esse mesmo lado duplicado e espelhado. Os resultados mostram que nas imagens compostas com o lado esquerdo da face são percebidas expressões mais significativas.

**Tabela 2. Configurações do fatiamento em pizza com sobreposição utilizados.**

Fatia	Parâmetro	Config.1	Config.2	Config.3	Config.4
Direita	ângulo (°)	120	90	90	120
	corte interno (mm)	40	40	30	30
Esquerda	ângulo (°)	120	90	90	120
	corte interno (mm)	40	40	30	30
Em cima	ângulo (°)	150	120	120	150
	corte externo (mm)	80	80	100	100
Em baixo	ângulo (°)	90	120	120	90
	corte externo (mm)	80	80	100	100
Centro	corte externo (mm)	35	35	40	45
	Deslocamento em +y (mm)	15	15	15	15

**Tabela 3. Melhores resultados obtidos com fatiamento em pizza com sobreposição nas diferentes configurações escolhidas.**

	Config.1	Config.2	Config.3	Config.4
Rank-1a (A)	73,71%	68,04%	67,01%	66,49%
Rank-1b (B)	39,34%	39,61%	33,31%	28,70%
ROC-I (C)	53,59%	51,67%	46,18%	42,45%

[Ekman 1980] publicou um artigo questionando a metodologia e as conclusões de [Sackeim et al. 1978]. Nesse artigo, Ekman alerta para outras possibilidades que justificariam essa percepção sobre as faces com apenas lados esquerdos, como diferenças anatômicas e nervos periféricos. Ele também ressalta as diferenças entre expressões emocionais espontâneas e movimentos faciais voluntários, como emoções "posadas".

Apesar das diferentes opiniões sobre a origem dessa assimetria, ela foi detectada estatisticamente em mais de um experimento [Hager and Ekman 2005]. A assimetria das expressões emocionais da face, com maior expressividade do lado esquerdo, também foi verificada quantitativamente por [Makioka et al. 2016]. Nesse estudo, Makioka et al. propôs medidas objetivas para avaliação da assimetria facial e realizou dois experimentos utilizando a base de dados BU-3DFE e as expressões neutra, raiva, felicidade, tristeza e surpresa. O primeiro experimento utilizou 15 participantes, que avaliaram qualitativamente imagens espelhadas de cada lado da face. O segundo experimento utilizou redes neurais multicamadas para gerar máscaras de emoções e essas máscaras aumentaram a taxa de reconhecimento em 4%.

Nos testes realizados nesta investigação, os melhores resultados foram obtidos com o fatiamento Triaxial combinando as fatias sagitais e transversais, abordagem proposta por [Siqueira et al. 2018], confirmando a melhor configuração encontrada pelo autor. Na Tabela 5 são apresentadas essa e outras configurações, utilizando extractores de características diferentes das do autor. Além da Seleção de segmentos ST ( $S_0, -S_1, S_1, -S_2, S_2, -S_3, S_3, T_0, -T_1, T_1, -T_2, T_2, -T_3, T_3$ ), foram testadas outras seleções: F ( $F_0, F_1, F_2, F_3$ ), F1 ( $F_1$ ), Direita ( $S_1, S_2, S_3$ ), Esquerda ( $-S_1, -S_2, -S_3$ ), Superior ( $T_1 e T_2$ ), Inferior ( $-T_2, -T_3$ ) e Central ( $T_0, S_0$ ).

**Tabela 4. Resultados obtidos com fatiamento em pizza com sobreposição na Config. 1 e utilizando cada segmento individualmente.**

Fatia	Cenário	Taxa de Acerto
Superior	A	43,81%
	B	18,44%
	C	21,86%
Inferior	A	44,85%
	B	17,33%
	C	20,55%
Lado Direito	A	36,6%
	B	19,09%
	C	21,17%
Lado Esquerdo	A	30,93%
	B	18,75%
	C	21,9%
Central	A	30,93%
	B	18,75%
	C	20,4%

**Tabela 5. Resultados obtidos com fatiamento triaxial e outros conjuntos de fatia.**

Fatia	A	B	C
$ST$	96,39%	62,31%	65,31%
$F$	67,53%	40,68%	49,94%
$F_1$	57,73%	24,78%	27,31%
Direita	76,29%	37,65%	39,38%
Esquerda	74,74%	33,15%	36,27%
Superior	58,25%	41,14%	50,17%
Inferior	53,61%	15,1%	16,37%
Central	46,91%	22,97%	30,08%

## 8. Conclusão

Este trabalho tratou do reconhecimento de faces 3D através de métodos baseados em superfície local utilizando suas características geométricas. Verificamos que técnicas de fatiamento são úteis na identificação de indivíduos e encontramos um resultado sobre a assimetria da face que condiz com estudos realizados por outros pesquisadores.

Foi possível verificar que o fatiamento da nuvem de pontos 3D de uma face pode aprimorar os resultados de classificação consideravelmente em comparação com os dados sem fatiamento.

Além disso, o método proposto de fatiamento em Pizza com Sobreposição se mostrou promissor, apesar de não superar os resultados do método de fatiamento Triaxial. Observou-se que, ao seccionar a face considerando as AUs, é possível melhorar o resultado de classificação em relação ao não fatiamento. Isso sugere que o aprofundamento das investigações direcionando para a detecção de informações sobre as diversas AUs, permitirá um refinamento da técnica, podendo-se chegar a uma classificação robusta a variações

de emoção, uma vez que será possível considerar com maior precisão as regiões de maior variabilidade na face.

## 9. Agradecimentos

O presente trabalho foi realizado com o apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de financiamento 001.

## Referências

- Besl, P. J. and McKay, N. D. (1992). A method for registration of 3-d shapes. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 14(2):239–256.
- Bowyer, K. W., Chang, K., and Flynn, P. (2004). A survey of approaches to three-dimensional face recognition. In *null*, pages 358–361. IEEE.
- Ekman, P. (1980). Asymmetry in facial expression. *Science*, 209:833–834.
- Ekman, P. and Friesen, W. V. (1976). Measuring facial movement. *Environmental psychology and nonverbal behavior*, 1(1):56–75.
- Ekman, P. and Friesen, W. V. (1978). *Facial Action Coding System: A Technique for the Measurement of Facial Moviment*. Consulting Psychologists Press, Palo Alto.
- Erdogmus, N. and Marcel, S. (2013). Spoofing in 2d face recognition with 3d masks and anti-spoofing with kinect. In *2013 IEEE Sixth International Conference on Biometrics: Theory, Applications and Systems (BTAS)*, pages 1–6.
- Fischler, M. A. and Bolles, R. C. (1981). Random sample consensus: A paradigm for model fitting with applications to image analysis and automated cartography. *Commun. ACM*, 24(6):381–395.
- G. Gordon, G. (1991). Face recognition based on depth maps and surface curvature. *SPIE Proc. Geometric Methods Comput. Vision*, 1570:234–247.
- Hackel, T., Wegner, J. D., and Schindler, K. (2016). Contour detection in unstructured 3d point clouds. In *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, pages 1610–1618.
- Hager, J. C. and Ekman, P. (2005). The asymmetry of facial actions is inconsistent with models of hemispheric specialization. In *What the Face Reveals Basic and Applied Studies of Spontaneous Expression Using the Facial Action Coding System (FACS)*, pages 40–58. Oxford University Press.
- Hariri, W., Tabia, H., Farah, N., Benouareth, A., and Declercq, D. (2016). 3d face recognition using covariance based descriptors. *Pattern Recognition Letters*, 78:1–7.
- Jafri, R. and Arabnia, H. (2009). A survey of face recognition techniques. *JIPS*, 5:41–68.
- Kavita, M. M. K. (2016). A survey of face recognition techniques. *International Journal of Scientific and Research Publications (IJSRP)*, Volume 6.
- Lee, J. and Milios, E. (1991). Matching range images of human faces. In *[1990] Proceedings Third International Conference on Computer Vision*, pages 722 – 726.
- Lin, C.-H., Chen, J.-Y., Su, P.-L., and Chen, C.-H. (2014). Eigen-feature analysis of weighted covariance matrices for lidar point cloud classification. *ISPRS Journal of Photogrammetry and Remote Sensing*, 94:70 – 79.

- Makioka, T., Kuriyaki, Y., Uchimura, K., and Satonaka, T. (2016). Quantitative study of facial expression asymmetry using objective measure based on neural networks. In *2016 International Symposium on Intelligent Signal Processing and Communication Systems (ISPACS)*, pages 1–4.
- Moreno, A. and Sánchez, A. (2004). Gavabdb: a 3d face database.
- Pedregosa, F., Varoquaux, G., Gramfort, A., Michel, V., Thirion, B., Grisel, O., Blondel, M., Prettenhofer, P., Weiss, R., Dubourg, V., Vanderplas, J., Passos, A., Cournapeau, D., Brucher, M., Perrot, M., and Duchesnay, E. (2011). Scikit-learn: Machine learning in Python. *Journal of Machine Learning Research*, 12:2825–2830.
- Phillips, P. J., Flynn, P. J., Scruggs, T., Bowyer, K. W., Jin Chang, Hoffman, K., Marques, J., Jaesik Min, and Worek, W. (2005). Overview of the face recognition grand challenge. In *2005 IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR'05)*, volume 1, pages 947–954 vol. 1.
- Reddy, A. M., Kishore, M. R., Sreenivasulu, P., and Jyothi, V. (2018). A survey of face recognition system. *International Journal of Engineering Research in Computer Science and Engineering (IJERCSE)*, Volume 5.
- Rusu, R. B. and Cousins, S. (2011). 3d is here: Point cloud library (pcl). In *In Robotics and Automation (ICRA), 2011 IEEE International Conference on*, pages 1–4. IEEE.
- Sackeim, H., Gur, R., and Saucy, M. (1978). Emotions are expressed more intensely on the left side of the face. *Science*, 202(4366):434–436.
- Savran, A., Alyüz, N., Dibeklioğlu, H., Çeliktutan, O., Gökberk, B., Sankur, B., and Akarun, L. (2008). Bosphorus database for 3d face analysis. In Schouten, B., Juul, N. C., Drygajlo, A., and Tistarelli, M., editors, *Biometrics and Identity Management*, pages 47–56, Berlin, Heidelberg. Springer Berlin Heidelberg.
- Shepley, A. J. (2019). Face recognition in unconstrained conditions: A systematic review.
- Siqueira, R., Alexandre, G. R., Soares, J. M., and Thé, G. A. P. (2018). Triaxial slicing for 3-d face recognition from adapted rotational invariants spatial moments and minimal keypoints dependence. *IEEE Robotics and Automation Letters*, 3(4):3513–3520.
- Soltanpour, S., Boufama, B., and Wu, Q. M. J. (2017). A survey of local feature methods for 3d face recognition. *Pattern Recognition*, 72.
- Tanaka, H. T., Ikeda, M., and Chiaki, H. (1998). Curvature-based face surface recognition using spherical correlation. principal directions for curved object recognition. In *Proceedings Third IEEE International Conference on Automatic Face and Gesture Recognition*, pages 372–377.
- Yin, L., Wei, X., Sun, Y., Wang, J., and Rosato, M. J. (2006). A 3d facial expression database for facial behavior research. In *Proceedings of the 7th International Conference on Automatic Face and Gesture Recognition, FGR '06*, pages 211–216, Washington, DC, USA. IEEE Computer Society.
- Zhao, W., Chellappa, R., Phillips, P. J., and Rosenfeld, A. (2003). Face recognition: A literature survey. *ACM Comput. Surv.*, 35(4):399–458.