

AVALIAÇÃO QUANTITATIVA DE DESEMPENHO DO REGISTRO DE IMAGENS TRIDIMENSIONAIS DE FACES POR MEIO DO ALGORITMO CP-ICP

POLYCARPO SOUZA NETO*, NICOLAS DA SILVA PEREIRA*, GEORGE ANDRÉ PEREIRA THÉ*, JOSÉ MARQUES SOARES *

*Programa de Pós-Graduação em Engenharia de Teleinformática - Universidade Federal do Ceará
Campus do Pici - Acesso Público, Bloco 725, s/n - Pici, CEP 60455-970
Fortaleza, CE, Brasil

Emails: policarponeto.pn@gmail.com, nicolassilva.ti@gmail.com, george.the@ufc.br, marques@ufc.br

Abstract— In 3D face reconstruction applications, an important issue is the matching between different samples of a given face. This is a point cloud registration task and is traditionally solved using the Iterative Closest Point (ICP) algorithm. In order to improve the efficiency of this technique, in this article we propose a preprocessing step to the ICP algorithm. We check the quality of the registration using as metrics the RMSE (Root Mean Square Error) measure, measures derived from the rotation matrix output by ICP, as well as measures based on both the SSIM (Structural Similarity Index) and entropy. Our experiments were carried out on a set of 3D data of faces and considered both rigid and non-rigid registration scenarios.

Keywords— Point cloud registration; Iterative Closest Point; Faces 3D; Non-rigid models; Point cloud downsampling.

Resumo— Em aplicações de reconstrução de face 3D, uma questão importante é a correspondência entre diferentes amostras de uma dada face. Esta é uma tarefa de registro de nuvem de pontos e é tradicionalmente resolvida usando o algoritmo Iterative Closest Point (ICP). A fim de melhorar a eficiência desta técnica, neste artigo propomos uma etapa de pré-processamento para o algoritmo ICP. Verificamos a qualidade do registro usando como métricas a medida RMSE (Root Mean Square Error), medidas derivadas da matriz de rotação gerada pelo ICP, bem como medidas baseadas tanto no SSIM (Structural Similarity Index), quanto na entropia. Nossos experimentos foram realizados em um conjunto de dados 3D de faces e consideramos cenários de registro rígidos e não rígidos.

Palavras-chave— Registro de nuvens de pontos; Iterative closest point; Faces 3D; Corpos não rígidos, Subamostragem de nuvens de pontos.

1 Introdução

O problema do registro de imagens 3D consiste em encontrar uma transformação espacial ótima entre duas nuvens de pontos que as torne alinhadas. Este tópico é relevante para a comunidade de visão computacional e robótica, uma vez que encontra-se presente em discussões relacionadas a aplicações de robótica móvel (Pomerleau et al., 2015), especialmente no contexto de mapeamento de ambientes, bem como em aplicações de biometria facial, reconstrução de faces e caracterização de deformações faciais, o que pode favorecer inclusive o reconhecimento de expressões (Cheng et al., 2017).

O registro de faces é intrinsecamente um problema de alinhamento entre corpos não rígidos; isto significa buscar transformações geométricas de uma nuvem em relação a outra, com o desafio de que, neste caso, há que se corrigir pose e lidar com existência de deformações dependentes das coordenadas espaciais dos pontos da superfícies (Staib and Wang, 2005).

O algoritmo que resolveu primeiro o problema de registro foi o ICP (*Iterative Closest Point*) (Besl and McKay, 1992), que consiste na minimização de uma medida de distância entre duas nuvens de pontos. Na literatura, os vários métodos que buscam a correspondência entre superfícies se

classificação em técnicas *point-to-point*, *point-to-plane* e *kd-tree* (Pomerleau et al., 2013). A existência de grandes volumes de dados nas mais diversas aplicações acaba por implicar em restrições de custo computacional, o que leva ao uso conjunto destas técnicas com estratégias de amostragem de pontos. Alinhado a isso é que a literatura afirma serem os métodos de amostragem um passo de discretização dos dados que permite mais fácil manipulação (Rodolà et al., 2015), podendo ser ainda vistos como formas de otimização do registro entre nuvens de pontos.

É nesse contexto que se encontra o presente trabalho; compara-se aqui um método recentemente proposto pelos autores (Pereira et al., 2015) com a técnica clássica ICP *point-to-point*. O algoritmo autoral CP-ICP exposto neste trabalho foi originalmente modelado para registro de objetos sujeitos a transformações rígidas, o que nos instigou a verificar sua extensão para modelos 3D sujeitos a deformações entre aquisições, tendo sido escolhido no estudo de faces humanas de bases conhecidas. Como será melhor detalhado nas sessões posteriores, o algoritmo CP-ICP tem como principal novidade ser um método de particionamento de nuvens de pontos ao longo de eixos genéricos, seguido pelo registro de sub-nuvens (em vez de nuvens inteiras). Os resultados desses registros serão

avaliados pelas métricas da raiz do erro quadrático médio (RMSE), de medidas baseadas nos ângulos de Euler, de medidas adaptadas da técnica *Structure Similarity Index Measure* (SSIM) e de medidas baseadas na entropia das nuvens de pontos. Os detalhes do algoritmo e das métricas usadas estão nas sessões 3 e 4, as quais são seguidas pela metodologia aplicada aos ensaios e pela discussão dos resultados. O método CP-ICP teve resultados melhores em todos os cenários investigados.

2 ICP (*Iterative Closest Point*)

O algoritmo ICP foi proposto em 1992 (Besl and McKay, 1992) e objetiva encontrar a transformação rígida que otimiza a rotação e a translação entre dois conjuntos de dados. O algoritmo utiliza um dos conjuntos de dados como referência, chamado de conjunto alvo (*model*), e um outro conjunto com uma rotação diferente, chamado aqui de conjunto de entrada (*source*), visando minimizar uma função custo através de um procedimento que sujeita a diferença de uma dada métrica entre iterações sucessivas a um limiar pré-definido.

3 CP-ICP (*Cloud Partitioning Iterative Closest Point*)

No presente trabalho utilizamos uma abordagem de particionamento das nuvens de pontos antes da execução do ICP, chamada *Cloud Partitioning* (CP-ICP); em essência, realiza-se a separação das nuvens de pontos originais em grupos menores (k grupos no total) designados abaixo sub-nuvens e, então, efetua-se o processo de registro para cada sub-nuvem até que um critério de parada seja encontrado. Ao fazer isso, reduz-se o esforço computacional, já que agora as nuvens de pontos são de tamanho reduzido (Pereira et al., 2015).

3.1 Particionamento

Inicia-se com a escolha de um eixo genérico (ζ) que, na versão atual do algoritmo pode ser Z, Y ou X, do sistema de referência da câmera usada na aquisição das nuvens S e M (*source* e *model*). Escolhido o eixo, define-se quais são as coordenadas máxima e mínima ao longo daquele eixo. Essas coordenadas podem ser expressas por S_u , S_l , M_u e M_l , com u e l indicando os extremos superior e inferior, respectivamente. Procede-se ao cálculo da espessura da nuvens em dada direção mediante a subtração das coordenadas extremas naquele dado eixo. Tendo a espessura de cada nuvem no eixo escolhido, definimos o número de cortes η , com isso obtendo um número de sub-nuvens $k = \eta + 1$ de larguras iguais. Nada garante que as fatias das nuvens de entrada e alvo tenha espessuras iguais. Da forma em que foi realizado, o

particionamento descrito enquadra-se como *constrainted partitioning* (Bichot and Siarry, 2013) que tem por finalidade a otimização de uma função custo $F(\vec{q})$.

Uma ilustração do sistema de orientação nas nuvens de face e dos respectivos cortes podem ser vistos na figura 1.




Figura 1: Ilustração da orientação e do particionamento das nuvens de face em Y e Z.

3.2 Análise teórica

Para entender melhor de que forma o particionamento proposto pode levar a economia de esforço computacional, considere N_S e N_M como sendo o tamanho de duas nuvens sujeitas a registro pelo ICP clássico. O custo computacional para o cálculo do ponto mais próximo no ICP clássico é $O(N_S N_M)$ (Besl and McKay, 1992). Por outro lado, o particionamento em sub-nuvens faz com que o registro de um par apenas de sub-nuvens tenha, na etapa de cálculo do ponto mais próximo, um custo equivalente a $O(N_S N_M / k^2)$; este é um limiar inferior do esforço do algoritmo, pois as diversas iterações de registro entre pares de sub-nuvens podem se repetir até k vezes, levando o custo ao máximo de $kO(N_S N_M / k^2)$. Note-se que nesta análise, apenas o cálculo do ponto mais próximo foi considerado, que é o passo mais demorado do ICP.

3.3 Registro

Primeiramente divide-se cada conjunto de dados (entrada e alvo) em k sub-nuvens, onde para cada iteração executa-se o ICP para um par de sub-nuvens, o que produz um certo alinhamento descrito por uma matriz de rotação fornecida como resultado do ICP; esta é, por sua vez, aplicada sobre a nuvem de entrada inteira. Ressalte-se que o alinhamento entre pares de sub-nuvens é feito um contra um, e não um contra todos, ou seja, a i -ésima sub-nuvem é submetida ao registro com outra de mesmo índice.

A nuvem de entrada inteira, que sofreu correção de orientação pela matriz de rotação do k -ésimo alinhamento é comparada com a nuvem alvo mediante cálculo do RMSE entre ambas; quando

este valor passar abaixo do critério de parada estabelecido (RMSE de convergência do ICP) o algoritmo se encerra e o registro realizado é apresentado como resultado.

Nos casos onde o registro obtido não satisfaz a condição de parada, saltamos para a próxima iteração, fazendo alinhamento do próximo par de sub-nuvens. Ressalte-se que, na versão atual, a saída de cada iteração não realimenta, isto é, não serve como *guess* inicial para a iteração sucessiva. Embora se possa suspeitar que esta medida levaria a um ulterior aumento de rapidez na localização do alinhamento ótimo entre sub-nuvens, não há garantias de que esta prática possa ser generalizada para objetos e corpos rígidos de diferentes geometrias. De fato, ensaios anteriores em objetos cujas nuvens de pontos apresentavam discontinuidades, bordas, enfim, transições não-suaves nas coordenadas dos pontos revelaram não haver garantia de que esse refinamento da pose inicial fosse suficientemente generalizável a ponto de merecer ser incluída como etapa do algoritmo.

O diagrama da figura 2 sintetiza o que foi descrito acima.

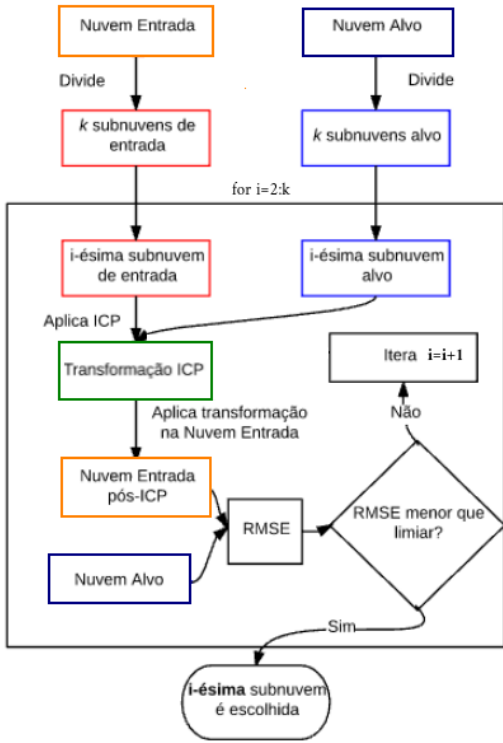


Figura 2: Fluxograma de metodologia de registro baseada no particionamento de nuvens (CP-ICP).

Matematicamente, realizar o *matching* com a técnica CP-ICP é fundamentalmente minimizar uma função custo equivalente a do ICP clássico, com a particularidade de que os pontos a serem associados serão aqueles presentes nas sub-nuvens.

Portanto, na função a seguir:

$$F(\vec{q}) = \sum_{i=2}^k \frac{1}{N} \sum_{j=1}^N \| m_{\vec{k}_j} - (R s_{\vec{k}_j} + T) \| \quad (1)$$

os termos dizem respeito ao conteúdo de sub-nuvens, isto é:

- i é o índice da sub-nuvem;
- k é o número de sub-nuvens;
- N é o número de pontos da sub-nuvens;
- $m_{\vec{k}_j}$ = j -ésimo vetor relacionado a nuvem de pontos alvo;
- $s_{\vec{k}_j}$ = j -ésimo vetor relacionado a nuvem de pontos de entrada;
- R é a matriz de rotação obtida com o ICP;
- T é o vetor de translação obtido com o ICP.

4 Métricas de avaliação de qualidade de registro

4.1 RMSE (Root Mean Square Error)

Como primeira opção de métrica de avaliação, foram utilizados os valores de RMSE entre a nuvem de entrada pós-ICP e a nuvem alvo. A métrica pode ser calculada usando a seguinte equação:

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (\min_{m \in M} \| s_i - m \|_2)^2} \quad (2)$$

onde S é uma superfície arbitrária e s_1, \dots, s_N são pontos coordenados em \mathbb{R}^3 , representando os vértices da superfície ou pontos da nuvem, e M a nuvem de referência.

4.2 Avaliação por ângulos de Euler

Os ângulos de Euler são definidos a partir da matriz de rotação, na forma apresentada a seguir. A inversão do elemento r_{31} desta matriz nos possibilita saber o valor de β . Conhecendo este ângulo, calculamos $\cos(\beta)$ e dividimos isso pelo elemento r_{11} para, então, através de inversão do resultado obter γ . Processo análogo ocorre ao se dividir o elemento r_{32} pelo $\cos(\beta)$, restando fazer a inversão de $\sin(\alpha)$, donde se extrai o valor do ângulo incógnito remanescente. (Corke, 2017).

$$R = \begin{bmatrix} c_y c_z & c_x s_x s_y - c_x s_z & s_x s_z + c_x c_z s_y \\ c_y s_z & c_x c_z + s_x s_y s_z & c_x s_y s_z - c_z s_x \\ -s_y & c_y s_x & c_x c_y \end{bmatrix} \quad (3)$$

onde:

- $c_x = \cos(\alpha)$, $c_y = \cos(\beta)$, $c_z = \cos(\gamma)$,
- $s_x = \sin(\alpha)$, $s_y = \sin(\beta)$ and $s_z = \sin(\gamma)$.

4.3 SSIM (Structural Similarity Index Measure)

Esta métrica de avaliação tem como objetivo fazer a comparação da estrutura de imagens em tons de cinza, analisando algumas características das imagens. Primeiro analisamos a luminância e assumimos o conjunto como um sinal discretizado, estimando a intensidade média. A função de comparação de luminância $l(a, b)$ é definida em função de μ_a e μ_b . Depois estimamos o contraste, que é o desvio padrão do sinal discreto.

A função de contraste $c(a, b)$ é a comparação de σ_a com σ_b . Por fim, cada sinal é normalizado pelo seu desvio padrão, tornando-os sinais de desvio padrão unitário. De acordo com (Wang et al., 2004), as funções $l(a, b)$, $c(a, b)$ e $s(a, b)$ são definidas pelas equações 4 até 6

$$l(a, b) = \frac{2\mu_a\mu_b + C_1}{\mu_a^2 + \mu_b^2 + C_1} \quad (4)$$

$$c(a, b) = \frac{2\sigma_a\sigma_b + C_2}{\sigma_a^2 + \sigma_b^2 + C_2} \quad (5)$$

$$s(a, b) = \frac{2\sigma_{ab} + C_3}{\sigma_a\sigma_b + C_3} \quad (6)$$

A formulação que rege esta métrica na equação 7:

$$SSIM(a, b) = \frac{(2\mu_a\mu_b + C_1)(2\sigma_{ab} + C_2)}{(\mu_a^2 + \mu_b^2 + C_1)(\sigma_a^2 + \sigma_b^2 + C_2)} \quad (7)$$

, onde C_1 e C_2 são constantes adicionadas para cada termo e seus valores são $C_1 = 6.5025$ e $C_2 = 58.5225$. Neste trabalho avaliaremos o SSIM para 5 perspectivas diferentes do registro (imagens 2D das projeções), como pode ser vista na Figura 3.




Figura 3: Representação das perspectivas analisadas do registro. As rotações foram geradas de forma deliberada.

Para cada uma dessas perspectivas são criadas 5 imagens de tamanho 512x512 pixels, sendo estas representações em tons de cinza (despreza-se a coordenada Z e utiliza-se as informações das coordenadas do plano XY) de cada visão. Para uma melhor avaliação, é usada uma técnica morfológica de dilatação para preenchimento dos pontos da figura da nuvem de pontos, criando um modelo totalmente preenchido. A representação da nuvem pode ser vista em 4(a) e o modelo dilatado em 4(b).




Figura 4: Exemplos das imagens analisadas pela métrica SSIM. Em a) modelo de nuvem de pontos oriundos do registro e em b) modelo depois do processo de dilatação.

Cabe neste momento um comentário sobre o porquê de as silhuetas das nuvens servirem ao propósito de métrica de qualidade. Registros insuficientes geram propagações de erros em todos os eixos, mesmo de rotações residuais, o que gera diferenças visuais sensíveis entre a nuvem original e a nuvem de um registro ruim. Resultados satisfatórios de registros nos dão modelos mais semelhantes aos das nuvens de referência. Aplicar transformações morfológicas nos resultados dos registros e comparar esses resultados com a análise morfológica do modelo de referência possibilita avaliar melhor a diferença das regiões criadas pelo registro ruim, o que é medido pela análise de similaridade da técnica SSIM.




Figura 5: Representação de perspectivas registradas.

4.4 Entropia da informação

A entropia representa o grau médio de incerteza a respeito da quantificação da informação presente num dado sistema (Cover and Thomas, 2012); ela é uma função de densidade de probabilidade, e neste trabalho assume a forma discreta apresentada a seguir (ressalte-se que não há que se falar aqui em entropia diferencial):

$$H = - \sum_{l=0}^{L-1} P_l \log P_l \quad (8)$$

onde:

- P é a probabilidade de ocorrência de um dado nível de cinza;

- L é a quantidade de níveis de cinza.

A ideia de utilizar a entropia da visão frontal (imagem 2D) do registro das faces deriva do fato que, no caso onde o alinhamento possui erros, haverá uma quantidade maior de informação na imagem, o que quer dizer que não

houve uma correspondência total dos pontos. No caso onde o *matching* é dito perfeito, teremos sobreposição quase que total dos pontos da nuvem de entrada sobre a nuvem alvo, havendo maior redundância de informação e menos pontos serão contabilizados, logo, um melhor registro e, em termos quantitativos, menor entropia.

5 Metodologia

5.1 Conjunto de dados

Em nossos experimentos foram utilizados 8 indivíduos da base Bosphorus (Savran et al., 2008), cedida aos autores mediante cláusula contratual, todos com faces neutras, sem expressões.

5.2 Rotações em cada nuvem

Para a geração das nuvens de entrada, um conjunto de rotações conhecidas foi aplicada sobre as nuvens de alvo, e estão listadas na tabela a seguir:

Tabela 1: Rotações aplicadas sobre as nuvens alvo.

Rígido (em Z)	Rotações (°)			
	I1	I2	I3	I4
θ	24	30	24	60
Não-rígido (em Y)	I5	I6	I7	I8
θ	24	45	15	30

5.3 Particionamento

O particionamento foi testado em duas direções, Z e Y; a direção X foi deixada de lado, por ora, por causa de dois motivos principais. Primeiramente, para o caso de registro de imagens rígidas, tais quais aquelas das amostras I1 a I4, o eixo sobre o qual são efetuados os cortes não é relevante, pois as proporções geométricas não são alteradas. Além disso, para o caso com pequenas deformações, quais sejam aquelas das amostras I5 a I8, tipicamente os movimentos de rotações ocorrem em torno do eixo Y ou do eixo Z, razão pela qual os cortes foram feitos ao longo desses eixos principais.

O número de sub-nuvens é $k = 7$ para cortes feitos em Z e em Y. Em experimentos anteriores, observamos que há uma influência da quantidade de sub-nuvens na localização daquela ótima; essencialmente, temos visto que, com poucas sub-nuvens, há liberdade de escolha da sub-nuvem que inicia as iterações. Variando a quantidade de sub-nuvens geramos partições cada vez menores que

podem tornar essa comparação de RMSE cada vez mais restritiva, fazendo com que demore ou não exista convergência do algoritmo, o que pode variar ainda para diferentes objetos, já que cada um destes tem geometrias diferentes. Para objetos rígidos onde foi aplicada apenas uma transformação para gerar o conjunto de dados de entrada, como no primeiro experimento, a variação de k não tem tanta influencia dado que os mesmos pontos estarão presentes na nuvem alvo, sendo importante na verdade a complexidade da sub-nuvem, ou seja, a riqueza de detalhes presentes nela que gera uma maior dificuldade no alinhamento e um valor de RMSE que não satisfaz o critério de parada. No caso onde existe não rigidez das faces, dividir as nuvens num certo valor de k , neste caso 7, nos permite alinhar os dois conjuntos de dados por regiões preferenciais pouco mutáveis, como testa, região dos olhos e septo nasal, evitando regiões que variam muito com expressões por exemplo, como é o caso do maxilar, alinhando sempre em uma das sub-nuvens de índices 1 a 4.

5.4 Parâmetros para simulação

Nas simulações tanto do CP-ICP, quanto do ICP a quantidade de iterações é igual a 30, as implementações utilizam ferramentas da PCL (*Point Cloud Library*) (Holz et al., 2015) e a máquina utilizada é a mesma para todos os testes, um notebook Dell Core *i5* – 4200U com 1.60GHz, 8 GB de memória, sistema operacional Linux Ubuntu 16.04 e IDE Qt-Creator 5.

5.5 Avaliação quantitativa

Depois dos experimentos de registro, foi feita a avaliação de qualidade usando as métricas RMSE, SSIM (adaptado), a entropia da imagem frontal do modelo registrado e a avaliação dos ângulos de Euler.

6 Resultados e Discussões

6.1 Experimento com aquisições rígidas dos indivíduos 1 ao 4

Os resultados de avaliação deste experimento encontram-se na tabela 2, tendo as situações de melhor resultado sido destacadas em negrito e em células pela cor verde. Na tabela sintetizamos o desempenho de tempo das duas abordagens de registro; os números revelam a notável economia de esforço computacional, fruto da redução do tamanho das nuvens promovida pelo CP-ICP.

Ainda na tabela 2 avaliamos as medidas de RMSE a fim de investigar a qualidade do registro, verificando assim que o CP-ICP superou o ICP clássico. Retomando a investigação quantitativa da qualidade do registro, observamos nas colunas

centrais da tabela que os valores calculados de similaridade por SSIM para o CP-ICP foram maiores e mais próximos de 1 para I1 e I2, sendo que para I3 e I4 a diferença é pequena entre as duas técnicas, podendo concluir um bom resultado apenas para os dois primeiros indivíduos. Por fim, na última coluna da tabela são reportados os valores de entropia das nuvens registradas por ambas as técnicas. Como nas demais métricas, o CP-ICP obtém um resultado melhor, uma vez que entropia menor significa maior redundância e, portanto, melhor sobreposição, alinhamento entre as nuvens.

Nas figuras 6 e 7 pode-se visualizar os resultados dos registros com o ICP e com o CP-ICP, respectivamente. É perceptível que nas faces registradas com o CP-ICP há uma melhor definição de algumas regiões (como nariz e boca), principalmente nos indivíduos 2 e 4, bem como um menor erro de rotação, especialmente para o indivíduo 4. Em suma, qualitativamente o registro com CP-ICP se mostrou melhor também.

6.2 Experimento com aquisições rígidas dos indivíduos 5 ao 8

Utilizando o mesmo conjunto de métricas do primeiro experimento, passa-se agora a investigação do registro não rígido entre amostras de faces humanas. Para tanto, reportam-se resultados do alinhamento entre nuvens de pontos frutos de diferentes aquisições de outros quatro indivíduos da base de dados.

Quanto ao tempo gasto no registro, a tabela 3 mostra que novamente o registro por meio do CP-ICP é bem mais rápido que o ICP, sendo de 30 a 40 vezes mais rápido, o que significa que a existência de deformação relativa entre as faces sujeitas ao registro não acarretou dificuldades adicionais para o algoritmo atingir a métrica de alinhamento em tempo hábil. Quanto a qualidade do registro, na tabela vemos os valores de RMSE para cada método e cada indivíduo. Quanto ao RMSE, temos uma variação considerável entre os valores obtidos com o ICP e o CP-ICP, principalmente para o indivíduo 6, destacado em vermelho. Novamente, assim como no primeiro experimento, o CP-ICP obteve resultados melhores.

Quanto a métrica baseada na similaridade pelo SSIM, em geral foram obtidas números mais próximos de 1 com o uso do CP-ICP, embora para um dos indivíduos a métrica foi igual nas duas técnicas; estes números atestam novamente melhor qualidade de registro por meio da técnica proposta. Tão elástica quanto no caso de amostras rígidas, novamente percebe-se uma vantagem do CP-ICP quando a qualidade do alinhamento é medida com auxílio da entropia. Trazemos nas figuras 8 e 9 os resultados dos registros relativos a superfícies não rígidas, utilizando o CP-ICP e

ICP nesta ordem. Comparando os *labels* de a até d, observamos por inspeção visual que os resultados com CP-ICP são melhores, principalmente para os indivíduos 5 e 6, onde no caso do registro com ICP (figuras 9(a) e 9(b)) vemos muitas regiões onde o registro não foi suficiente (veja em destaque).

6.3 Avaliação da rotação nos dois experimentos

No gráfico abaixo (figura 10) temos uma representação dos resultados obtidos pelas avaliações das matrizes de rotação para cada modelo em ambos os algoritmos. Nesta figura, o eixo Y traz os valores em graus do ângulo extraído pelas técnicas ICP e CP-ICP; os marcadores quadrados em vermelho representam o *ground-truth* da rotação aplicada em cada indivíduo mostrado nas abscissas.

Os quadrados em vermelho consistem na medida relativa a verdade universal, isto é, a medida de rotação efetuada nas nuvens de entrada. A rotação encontrada pela técnica CP-ICP está marcada com um círculo verde, ao passo que aquela fornecida pelo ICP e trazida como estrela azul.

Podemos observar que para os 8 indivíduos, submetidos a rotações diferentes e em condições de registro rígido e não rígido, o CP-ICP fornece um número sempre mais próximo da verdade universal (ressalte-se indivíduos 2 e 4), o que reforça os resultados de que a técnica gera bons alinhamentos para dados de naturezas distintas.

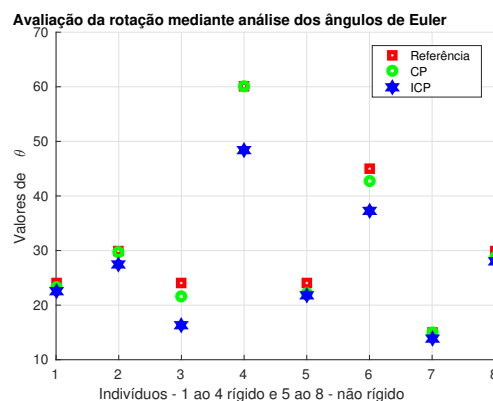


Figura 10: Rotação extraída pelas técnicas de alinhamento nas várias amostras de face ensaiadas.

7 Conclusões

Neste trabalho é apresentada uma variação do ICP que se baseia no particionamento das nuvens de entrada e alvo. A abordagem proposta é comparada com o ICP por meio de um conjunto de métricas. Testando o algoritmo autoral com nuvens de pontos não rígidas, temos melhores resultados em relação ao ICP clássico, tanto de forma quantitativa, quanto pela inspeção visual, conseguindo, ainda, ser mais rápido na resolução da tarefa de registro.

Tabela 2: Resultado da avaliação quantitativa de tempo e por meio das métricas RMSE, SSIM e Entropia para os indivíduos I1 a I4 (caso de registro de faces rígidas).

		Tempo (seg)	RMSE	SSIM		Entropia
				Pontos	Dilat.	
ICP	I1	6,83	1,1781	0,755	0,946	0,3178
	I2	9,83	2,4856	0,626	0,931	0,3858
	I3	8,61	3,6082	0,734	0,911	0,3671
	I4	11,49	7,6141	0,734	0,941	0,3852
CP	I1	0,16	0,9478	0,789	0,944	0,2060
	I2	0,21	1,5533	0,628	0,929	0,2435
	I3	0,89	2,6743	0,735	0,921	0,2375
	I4	0,24	7,4779	0,737	0,948	0,2486




Figura 6: Resultado do registro de faces 3D utilizando o ICP clássico. Os modelos de a) até d) são oriundos do *matching* com o ICP clássico.




Figura 7: Resultado do registro de faces 3D utilizando o CP-ICP. Os modelos de a) até d) são oriundos do *matching* com o CP-ICP.

Tabela 3: Resultado da avaliação quantitativa de tempo e por meio das métricas RMSE, SSIM e Entropia para os indivíduos I5 a I8 (caso de registro de faces não rígidas).

		Tempo (seg)	RMSE	SSIM		Entropia
				Pontos	Dilat.	
ICP	I5	6,97	4,827	0,694	0,895	0,3446
	I6	8,49	16,278	0,719	0,944	0,3621
	I7	6,91	2,709	0,734	0,904	0,3676
	I8	12,09	1,910	0,738	0,948	0,4236
CP	I5	0,19	1,298	0,748	0,895	0,2734
	I6	0,25	1,445	0,743	0,949	0,2937
	I7	0,22	1,746	0,760	0,944	0,2948
	I8	0,27	1,910	0,737	0,948	0,4225

Os resultados confirmaram a expectativa quanto a economia de esforço computacional, enquanto que no tocante a qualidade do registro, a estratégia de particionamento mostrou-se bastante promissora na identificação de uma região ótima para o alinhamento.

Como trabalhos futuros, pode-se citar a necessidade de explorar uma métrica automática para usarmos como critério de parada, fazer cortes que combinem porções de cortes de eixos diferentes a fim de evitar regiões de deformações, testes sobre cenários de oclusão e avaliar o efeito do registro re-




Figura 8: Resultado do registro de faces 3D dos indivíduos 5 ao 8 para diferentes aquisições utilizando o método autoral CP-ICP.




Figura 9: Resultado do registro de faces 3D dos indivíduos 5 ao 8 para diferentes aquisições utilizando o ICP clássico.

alizado pelo CP-ICP em processos de classificação de indivíduos.

Referências

- Besl, P. J. and McKay, N. D. (1992). Method for registration of 3-d shapes, *Sensor Fusion IV: Control Paradigms and Data Structures*, Vol. 1611, pp. 586–607.
- Bichot, C.-E. and Siarry, P. (2013). *Graph partitioning*, John Wiley & Sons.
- Cheng, S., Marras, I., Zafeiriou, S. and Pantic, M. (2017). Statistical non-rigid icp algorithm and its application to 3d face alignment, *Image and Vision Computing* **58**: 3–12.
- Corke, P. (2017). *Robotics, Vision and Control: Fundamental Algorithms In MATLAB® Second, Completely Revised*, Vol. 118, Springer.
- Cover, T. M. and Thomas, J. A. (2012). *Elements of information theory*, John Wiley & Sons.
- Holz, D., Ichim, A. E., Tombari, F., Rusu, R. B. and Behnke, S. (2015). Registration with the point cloud library: A modular framework for aligning in 3-d, *IEEE Robotics & Automation Magazine* **22**(4): 110–124.
- Pereira, N. S., Carvalho, C. R. and Thé, G. A. (2015). Point cloud partitioning approach for icp improvement, *Automation and Computing (ICAC), 2015 21st International Conference on*, IEEE, pp. 1–5.
- Pomerleau, F., Colas, F., Siegwart, R. and Magnenat, S. (2013). Comparing icp variants on real-world data sets, *Autonomous Robots* **34**(3): 133–148.
- Pomerleau, F., Colas, F., Siegwart, R. et al. (2015). A review of point cloud registration algorithms for mobile robotics, *Foundations and Trends® in Robotics* **4**(1): 1–104.
- Rodolà, E., Albarelli, A., Cremers, D. and Torsello, A. (2015). A simple and effective relevance-based point sampling for 3d shapes, *Pattern Recognition Letters* **59**: 41–47.
- Savran, A., Alyüz, N., Dibeklioğlu, H., Çeliktutan, O., Gökberk, B., Sankur, B. and Akarun, L. (2008). Bosphorus database for 3d face analysis, *European Workshop on Biometrics and Identity Management*, Springer, pp. 47–56.
- Staib, L. H. and Wang, Y. M. (2005). Methods for nonrigid image registration, *Handbook of Geometric Computing*, Springer, pp. 571–602.
- Wang, Z., Bovik, A. C., Sheikh, H. R. and Simoncelli, E. P. (2004). Image quality assessment: from error visibility to structural similarity, *IEEE transactions on image processing* **13**(4): 600–612.