Registro Automático de Superfícies Usando Spin-Images

Thales Vieira UFAL / PUC-Rio / IMPA Adelailson Peixoto (orientador) UFAL Luiz Velho T (orientador) IMPA

Thomas Lewiner (orientador) PUC-Rio

Resumo

Este trabalho descreve um método baseado em três etapas para registro e reconstrução de modelos a partir de malhas capturadas de scanners 3D. Malhas obtidas a partir de diferentes pontos de visão de um scanner têm sua representação em sistemas de coordenadas locais. Portanto, para a reconstrução final do modelo, é necessário realizar um alinhamento dessas malhas, ou registro, de modo que todas as malhas estejam representadas em um sistema de coordenadas global. O algoritmo mais popular para realizar registro de nuvens de pontos é o algoritmo ICP. Porém, um dos requisitos desse algoritmo é uma estimativa inicial do alinhamento das malhas, que muitas vezes é feita manualmente. Para automatizar esse processo, descritores spin-image são utilizados para identificar pontos correspondentes entre as malhas, que serão utilizados para estimar os alinhamentos iniciais entre essas malhas com sobreposição. Após este posicionamento inicial, o alinhamento é refinado por uma das variantes do algoritmo ICP, e finalmente o modelo é reconstruído usando métodos de reconstrução de superfícies como Poisson, MPU ou VRIP.

1. Introdução

De modo geral, a modelagem de objetos tridimensionais é uma tarefa trabalhosa quando realizada a partir de softwares CAD. O uso de scanners 3D para captura da geometria de objetos tridimensionais vem sendo bastante explorado e desenvolvido nos últimos anos, tendo como principal aplicação a modelagem de objetos gráficos a partir da captura da geometria de objetos reais. Consequentemente, esses equipamentos apresentamse como uma alternativa às técnicas de modelagem convencionais.

Os scanners 3D são capazes de gerar malhas de triângulos que representam a geometria visível de um objeto a partir do ponto de vista do scanner, utilizando o conceito de *range images*, como em [6] e [7]. As

range images pertencem a uma classe especial de imagens digitais, onde cada pixel da imagem expressa a distância entre o ponto de visão e um ponto da cena. A partir dessas imagens, é possível criar malhas triangulando-se seus pixels adjacentes.

Porém, é impossível realizar uma varredura completa da geometria de um objeto qualquer a partir de um único ponto de vista do scanner, devido a limitações como obstruções, por exemplo. Isso justifica a necessidade de captura de várias range images para a reconstrução de um objeto (Figura 1). Essas range images vão gerar malhas m_i cujos pontos são descritos em sistemas de coordenadas locais S_i . Portanto, para garantir a coerência global do modelo reconstruído, essas malhas precisam ser registradas, ou alinhadas, de acordo com um sistema de coordenadas global.

O problema de registro de superfícies consiste em determinar as transformações espaciais que otimizam os alinhamentos em um conjunto de malhas que representam um mesmo objeto (Figura 2).

Do ponto de vista matemático, dadas duas malhas m_A e m_B , onde o sistema de coordenadas de m_A é fixado como sistema de coordenadas global, o registro de superfícies consiste em encontrar o melhor movimento rígido T,



Figura 1. Malhas representando range images capturadas de diferentes pontos de visão.



Figura 2. Registro de superfícies.

composto por uma rotação e uma translação, que, aplicado a m_B , otimize seu alinhamento em relação a m_A no sistema de coordenadas global.

Um dos algoritmos mais utilizados para resolver este problema é o ICP (*Iterative Closest Point*) [1]. Através de um processo iterativo, o algoritmo original ICP cria pares $P_i = \{x_{A_i}, x_{B_i}\}$ de pontos correspondentes nas 2 malhas, usando como critério a distância euclidiana, e encontra uma transformação que minimiza a distância entre os pares de pontos correspondentes. A transformação encontrada é aplicada as pontos da malha m_B e o processo é repetido até que as transformações encontradas sejam desprezíveis (i.e. próximas da identidade).

Porém, o ICP não garante a convergência ao erro mínimo global. Um dos requerimentos iniciais deste algoritmo é que as malhas tenham uma estimativa inicial do alinhamento. A robustez do algoritmo ICP está diretamente ligada à qualidade deste posicionamento inicial. Portanto, esse requisito descarta a possibilidade de alinhamento automático entre superfícies usando apenas este método.

Dado um conjunto de malhas que representam um determinado objeto, este trabalho apresenta uma estratégia para alinhar automaticamente todos os pares de malhas que possuam regiões de sobreposição, e gerar um modelo final. A solução integra três módulos independentes. Inicialmente, é utilizada uma estratégia baseada em descritores de superfície *Spin-Images* [4] para geração de correspondências entre pontos das malhas. Essas correspondências são utilizadas para calcular uma estimativa inicial do alinhamento entre malhas com regiões de sobreposição considerável. Em seguida, o algoritmo ICP é executado para refinar o alinhamento. Finalmente, o modelo final é reconstruído usando métodos de reconstrução como o VRIP [2], Poisson [5] ou MPU [8].

A principal contribuição deste trabalho é a integração das técnicas de posicionamento inicial, alinhamento e reconstrução, definindo um pipeline completamente automático para registro e reconstrução de modelos obtidos a partir de scanners 3D. Além disso, algumas melhorias foram desenvolvidas nas etapas de posicionamento inicial e alinhamento, como, por exemplo, a seleção de pontos de alta curvatura local para criação dos descritores, e a otimização de parâmetros sugeridos nos métodos originais. Finalmente, este trabalho apresenta uma análise de todo o procedimento e exibe alguns modelos registrados e reconstruídos.

A próxima seção apresenta uma visão geral do pipeline e uma breve descrição das etapas mais exploradas neste trabalho. Em seguida, serão apresentados alguns resultados obtidos (Seção 3) e alguns comentários finais e trabalhos futuros que estão sendo realizados atualmente (Seção 4).

2. Descrição Geral do Método

Esta seção apresenta uma visão geral do procedimento adotado para registro automático de superfícies e reconstrução de objetos tridimensionais, além de uma breve descrição das etapas mais relevantes e exploradas neste trabalho.

2.1. Visão Geral

O pipeline explorado neste trabalho tem como dados de entrada um conjunto de malhas que representam diferentes visões de um objeto. O procedimento pode ser dividido em três etapas:

- Na primeira etapa, as malhas são testadas duas a duas para verificar a existência de áreas de sobreposição e estimar um posicionamento inicial. Uma outra abordagem que pode ser utilizada para acelerar esta etapa considera que sejam conhecidos inicialmente os pares de malhas com sobreposição, como no caso de malhas obtidas a partir da rotação sequencial de um objeto ao redor de um eixo. Neste caso, apenas os pares com sobreposição conhecida terão seus alinhamentos calculados.
- 2. A segunda etapa recebe as malhas pré-alinhadas e executa uma variante do algoritmo ICP para refinar os alinhamentos, minimizando uma métrica de erro.
- 3. A terceira etapa aplica algum método de reconstrução de superfícies às nuvens de pontos correspondentes às malhas alinhadas. Esta superfície é o resultado final do procedimento.

A Figura 3 exibe um diagrama descrevendo este pipeline. As subseções seguintes descrevem as etapas envolvidas.

2.2. Posicionamento Inicial

Dado um conjunto de malhas $M = \{m_i\}$, onde cada malha é representada em um sistema de coordenadas local, é necessário determinar os pares de malhas que



Figura 3. Procedimento para registro automático e reconstrução de superfícies.

possuem regiões de sobreposição. A abordagem utilizada para resolver este problema consiste em determinar pares de pontos pertencentes a diferentes malhas que representem um mesmo ponto do objeto real. Esse procedimento é realizado comparando-se as malhas duas a duas.

Para cada duas malhas, são criados dois conjuntos de spin-images associadas a pontos orientados da superfície. As spin-images de um conjunto são comparadas com as spin-images do outro conjunto. Correspondências entre pontos cujas spin-images sejam parecidas são criadas. Em seguida, são realizadas filtragens para garantir a consistência das correspondências. As correspondências remanescentes são agrupadas segundo critérios que garantam o cálculo de uma transformação consistente e com precisão razoável. Finalmente, testes de sobreposição são realizados para validar a transformação obtida. Caso a transformação seja inconsistente, uma nova tentativa de agrupamento é realizada, até que não hajam mais possibilidades de agrupamento ou que se encontre uma transformação válida.

Se em algum momento a quantidade de correspondências for insuficiente ou se as transformações sejam todas inválidas, as malhas são consideradas sem sobreposição. A Figura 4 exibe um diagrama ilustrando este procedimento para cada par de malhas.

2.2.1. Descritores Spin-image. Neste trabalho, essas correspondências são detectadas pela comparação de

descritores *spin-images*, que são imagens bidimensionais em tons de cinza criadas por pontos orientados da superfície. Essas imagens fornecem uma descrição local da geometria da superfície e são invariantes por movimentos rígidos. Esta última característica viabiliza o uso deste descritor para identificação de pontos correspondentes em malhas representadas em diferentes sistemas de coordenadas. Portanto, pontos de diferentes malhas com spin-images similares têm boa probabilidade de serem correspondentes, como na Figura 5.

Dado um ponto orientado p em uma superfície, selecionam-se os pontos numa determinada vizinhança de p. Esses pontos serão projetados num plano de acordo com um sistema de coordenadas radial, dada pela aplicação $S_O: \mathbb{R}^3 \to \mathbb{R}^2$, representada pela equação

$$S_O(x) = \left(\sqrt{\|x-p\|^2 - (n \cdot (x-p))^2}, n \cdot (x-p)\right),$$
(1)

onde O = (p, n) é o ponto orientado gerador do descritor. Esta aplicação é chamada *spin-map*.

A imagem desta aplicação é um conjunto de pontos do plano que serão transformados em imagens bidimensionais em tons de cinza, para permitir uma comparação robusta em relação a variações de amostragem e ruído. Usando esta abordagem, o plano é dividido em pequenas caixas, onde cada caixa será representada por um pixel na imagem, cujo tom de cinza é associado à quantidade normalizada



Figura 4. Primeira etapa: alinhamento inicial de um par de malhas.



Figura 5. Pontos correspondentes e suas *spin-images*.

de pontos contidos na caixa associada. A Figura 6 exibe a imagem de uma aplicação Spin-map e sua respectiva spinimage.

Alguns parâmetros são bastante relevantes para a geração de spin-images com boa descrição geométrica da superfície. É fundamental um bom ajuste do tamanho das caixas, da largura da imagem e do ângulo suporte. O produto dos dois primeiros parâmetros dá origem à distância suporte, que determina o tamanho da vizinhança utilizada para criação da spin-image. O último parâmetro limita o ângulo entre a normal do ponto orientado gerador da spin-image e a normal de cada ponto da superfície. Se esses parâmetros estiverem bem ajustados, será possível realizar comparações robustas entre as imagens.

O método de comparação utilizado neste trabalho baseiase no coeficiente de correlação linear, dado pela equação

$$R(P,Q) = \frac{N \sum p_i q_i - \sum p_i \sum q_i}{\sqrt{\left(N \sum p_i^2 - \left(\sum p_i\right)^2\right) \left(N \sum q_i^2 - \left(\sum q_i\right)^2\right)}}$$

onde p_i e q_i são os tons de cinza dos pixels de P e Q, e N é a quantidade de pixels da imagem. Este coeficiente deve variar entre -1, quando as imagens são totalmente diferentes, e 1, quando as imagens forem idênticas. Portanto, valores mais altos de R indicam imagens mais parecidas.

Devido a presença de oclusões nas visões, é necessário desconsiderar regiões de uma superfície que não estejam presentes na outra superfície. Uma maneira de resolver parcialmente esse problema é desconsiderar pixels vazios (em branco) das imagens P ou Q no cálculo do coeficiente de correlação linear.

Porém, para tornar esta medida de similaridade mais confiável de acordo com a quantidade de pixels analisados, a seguinte função é utilizada:

$$C(P,Q) = (atanh(R(P,Q)))^2 - \lambda \left(\frac{1}{N-3}\right),$$

onde N é a quantidade de pixels na região de sobreposição e λ é um peso associado à variância das imagens.

Para cada ponto p da primeira malha, é criado um histograma com as medidas de similaridade entre sua spinimage e a spinimage gerada pelos pontos da segunda malha. Os outliers deste histograma serão considerados correspondentes ao ponto p.

2.2.2. Seleção de Features. A comparação de todas as *spin-images* de uma malha com todas as *spin-images* de uma segunda malha é um algoritmo quadrático. Portanto, é conveniente a seleção de pontos das malhas para geração de *spin-images* de acordo com algum critério. Neste trabalho, uma métrica baseada na curvatura local da superfície foi o parâmetro utilizado para seleção dos pontos de alta curvatura. Esta métrica é dada por

$$m(x) = \kappa_1^2(x) + \kappa_2^2(x),$$

onde $\kappa_1^2(x)$ e $\kappa_2^2(x)$ são as curvaturas principais de um ponto x da superfície.



Figura 6. Imagem da aplicação Spin-map com sua respectiva Spin-image.

2.2.3. Filtragens. Após a geração dos pares de pontos com *spin-images* similares, são realizadas filtragens para garantir a consistência das correspondências.

A primeira filtragem elimina as correspondências que tenham similaridades abaixo da metade da maior similaridade existente entre as correspondências.

A segunda filtragem realiza um teste de consistência geométrica entre as correspondências baseado na seguinte afirmação: duas correspondências $C_1 = [s_1, m_1]$ e $C_2 = [s_2, m_2]$ serão consideradas geometricamente consistentes se $||s_1 - s_2|| - ||m_1 - m_2||| < \varepsilon$, para ε suficientemente pequeno, onde s_1 e m_1 são pontos correspondentes das malhas, assim como s_2 e m_2 . Em termos de coordenadas *spin-map*, isso é equivalente a analisar as funções

$$d_{gc}(C_1, C_2) = \frac{\|S_{m_2}(m_1) - S_{s_2}(s_1)\|}{(\|S_{m_2}(m_1)\| + \|S_{s_2}(s_1)\|)/2}, \quad (2)$$
$$D_{gc}(C_1, C_2) = max(d_{gc}(C_1, C_2), d_{gc}(C_2, C_1)),$$

onde S é a aplicação spin-map definida na Equação 1 e a função max retorna o maior de seus parâmetros. Se $D_{gc}(C_1, C_2) < T_{gc}$, onde T_{gc} é um treshold, então C_1 e C_2 são geometricamente consistentes.

Para cada correspondência C, se a quantidade de correspondências consistentes a ela for maior que um certo threshold, então C é considerada, por si só, uma correspondência consistente.

2.2.4. Agrupamento e Cálculo da Transformação. Após as filtragens, as correspondências apresentam um bom grau de consistência. O próximo passo a ser executado é o agrupamento de algumas correspondências utilizando critérios que garantam o cálculo de uma boa transformação. Cada grupo criado com pelo menos três correspondências deve ser capaz de gerar uma transformação.

Nesta etapa, são utilizados dois critérios: a consistência geométrica, através da Equação 2, e a distância entre as correspondências. Quanto mais espalhadas as correspondências estiverem, maiores as chances de se obter uma boa transformação, minimizando o efeito de ruídos. Esses dois requisitos são combinados para gerar as funções

$$w_{gc}(C_1, C_2) = \frac{d_{gc}(C_1, C_2)}{1 - e^{-\left(\left(\|S_{m_2}(m_1)\| + \|S_{s_2}(s_1)\|\right)/(2\gamma)\right)}}$$
$$W_{gc}(C_1, C_2) = max(w_{gc}(C_1, C_2), w_{gc}(C_2, C_1))$$

Se C_1 e C_2 forem geometricamente consistentes e distantes, W_{gc} será pequeno. A variável γ deve ser definida em k vezes a resolução da malha. Esse valor estimula o agrupamento de correspondências distantes pelo menos k vezes a resolução da malha. Neste trabalho, foi utilizado k = 4.

Para cada correspondência consistente C_i , será possível gerar um grupo G_i , contendo inicialmente C_i . Para cada

correspondência consistente C_j , se $W_{gc}(C_i, C_j) < T_{gc}$, adiciona-se C_j ao grupo G_i .

As correspondências pertencentes à G_i serão os dados de entrada para o Algoritmo de Horn [3]. Este método utiliza quatérnios e mínimos quadrados para calcular o movimento rígido que minimiza a distância entre as correspondências, dada pela função

$$f(\vec{q}) = \frac{1}{n} \sum_{i=1}^{n} \|p_{2,i} - R(\vec{q}_R)\vec{p}_{1,i} - \vec{q}_T\|^2, \qquad (3)$$

onde n é a quantidade de correspondências, $p_{k,i}$ são pontos da malha k, e $R(\vec{q}_R)$ é a matriz de rotação associada ao quatérnio \vec{q}_R .

Uma transformação será considerada válida se a região de sobreposição entre as duas superfícies após a aplicação da transformação for maior que uma certa razão da área das superfícies. Um ponto p pertencente a uma malha m_1 estará na região de sobreposição das malhas $m_1 e m_2$ se existir $q \in m_2$ tal que $||p - q|| < D_v$, onde D_v é um *threshold* de distância, geralmente definido entre 1 e 2 vezes a resolução da malha. A Figura 7 ilustra este procedimento.



Figura 7. Agrupamento e validação.

2.3. Refinamento do Registro

Uma vez que as malhas estão pré-alinhadas, é possível aplicar o algoritmo ICP para refinar os alinhamentos entre as malhas. Esta seção dá uma breve descrição do algoritmo ICP implementado neste trabalho.

Seja $M_1 = {\vec{p}_i}$ o conjunto de pontos da malha m_1 e $M_2 = {\vec{q}_i}$ o conjunto de pontos da malha m_2 . A variante do algoritmo ICP implementada neste trabalho segue os passos abaixo, para cada iteração k:

- 1. Para cada ponto $\vec{p_i}$, determine seu ponto mais próximo $\vec{x_i} \in M_2$;
- 2. Rejeite os pares nos quais o ângulo entre as normais de $p_i e x_i$ for maior que 45°;
- Rejeite os pares cuja distância seja maior que um threshold determinado como múltiplo da resolução da malha;
- Encontre a transformação q_k que minimiza a distância entre os pares de pontos (p_i, x_i) usando o algoritmo de Horn e encontre o erro d_k dado pela Equação 3;
- 5. Aplique a transformação $\vec{q_k}$ aos pontos de M_1 ;
- 6. Se $d_k d_{k-1} < \tau$, onde τ é um *threshold* pequeno, o processo pára. Senão, volte para o primeiro passo.

A transformação resultante será a composição das transformações $\vec{q_i}$, ou seja, $\vec{q} = \vec{q_k} \circ \vec{q_{k-1}} \circ \cdots \circ \vec{q_1}$.

Para acelerar a primeira etapa, uma kd-tree [9] é utilizada para busca dos pontos mais próximos. Desse modo, sendo na quantidade de pontos da primeira malha e m a quantidade de pontos da segunda malha, o custo computacional é reduzido de O(nm) para $O(n \log m)$.

Além disso, uma das melhorias deste método em relação ao algoritmo original é a rejeição dos pares de acordo com um threshold definido como múltiplo da resolução da malha, seguindo a idéia do teste de validação de transformação da seção anterior. Esta condição pode ser utilizada porque está se assumindo que as malhas estão inicialmente com um posicionamento razoável. Esta é uma maneira de descartar as correspondências que não pertencem à região de sobreposição das malhas, aumentando a robustez do ICP. O uso de um múltiplo entre 1 e 2 vezes a resolução da malha é uma boa referência para garantir que dois pontos correspondentes numa região de sobreposição não sejam descartados.

2.4. Reconstrução do Modelo

A etapa final do procedimento é a reconstrução de uma única malha a partir das malhas alinhadas pelo ICP. Dados os pares de malhas alinhados e suas respectivas transformações, é possível, através de composição de transformações, representar todas as malhas num sistema de coordenadas global, desde que o grafo de alinhamento seja conexo.

Três métodos utilizados neste trabalho foram o VRIP [2], o MPU [8] e a Reconstrução de Poisson [5].

3. Resultados e Discussão

Esta seção discute alguns aspectos relevantes do procedimento e exibe resultados obtidos neste trabalho. A etapa mais delicada para o sucesso do procedimento é a definição dos parâmetros envolvendo criação de *spinimages*, filtragem de correspondências e algoritmo ICP. Foram testadas malhas normalizadas na caixa unitária com resolução entre 0,01 e 0,03, onde a resolução é definida como a mediana dos comprimentos das arestas, e quantidade de vértices entre 800 e 15.000 pontos, gerando reconstruções de até 300.000 pontos. Foram testadas malhas capturadas de objetos reais por um scanner 3D e malhas geradas artificialmente por um scanner virtual.

3.1. Criação de Spin-images

Uma das etapas mais importantes do procedimento é a criação de *spin-images* que apresentem boa descrição da geometria da superfície.

O tamanho das caixas que resultou na maior taxa de correspondências consistentes foi entre 0.05 e 0.1, para malhas na caixa unitária. Em [4], este parâmetro é dado em função da resolução da malha. Porém, dada uma malha representando uma visão de um objeto, é possível se obter malhas semelhantes com diferentes resoluções realizando-se simplificações ou refinamentos da malha original. Essas diferentes resoluções implicariam diferentes tamanhos de caixas, se dadas como um múltiplo da resolução. Porém, como a mesma geometria está sendo analisada em quaisquer resoluções, seria desejável que este parâmetro se mantivesse constante. Portanto, a resolução da malha não é uma boa referência para definir este parâmetro.

O segundo parâmetro envolvido na criação das *spinimages* é a largura da imagem. Dado um tamanho de caixa, quanto maior a largura da imagem, maior será a região da superfície descrita, e mais consistentes as comparações entre os pontos da superfície. Este valor deve ser definido de acordo com as dimensões da malha, fornecendo a maior descrição possível da região de sobreposição entre as duas malhas. Neste trabalho, imagens com largura entre 10×10 e 15×15 pixels apresentaram bons resultados.

Finalmente, o ângulo suporte é um parâmetro que deve ser definido garantindo-se a maior descrição possível da superfície comum entre as duas malhas em uma vizinhança do ponto orientado. O ângulo suporte que apresentou melhores resultados nas malhas analisadas foi de 60°. A Figura 5 exibe duas visões do *bunny* com pontos



Figura 8. Pontos de alta curvatura contidos em ambas as visões de um objeto.

correspondentes e suas *spin-images* similares, criadas com tamanho de caixa 0.09, largura da imagem de 13×13 pixels e ângulo suporte de 60° .

Outro parâmetro fundamental é a quantidade de pontos selecionados nas malhas para criação de *spin-images*, levando em consideração a seleção por curvatura local. Este tópico exige uma discussão mais detalhada, envolvendo a região de sobreposição entre as visões e a curvatura das malhas.

Para registrar duas malhas, uma quantidade razoável de pontos selecionados em uma das malhas deve pertencer ao conjunto de pontos selecionados na outra malha. Usando o critério de curvatura local, isso implica que as regiões de curvatura mais acentuada devem pertencer à região de sobreposição das malhas. Esse deve ser o critério utilizado no momento de captura das malhas. Quanto menor a região de sobreposição entre duas malhas, maior será a a região do modelo capturada por duas malhas. Quanto maior a região de sobreposição entre as duas malhas maiores as chances de haver pontos de alta curvatura em ambas as malhas, o que deve implicar no sucesso do registro dessas malhas. Portanto, o procedimento mais adequado para a captura das malhas é usar a menor região de sobreposição possível, de modo que regiões de alta curvatura estejam contidas na região de sobreposição, como na Figura 8, onde parte do fucinho e das pernas do cavalo está contido nas duas malhas, que têm os pontos de alta curvatura destacados.

Na maioria dos modelos analisados, foi possível registrar as malhas com sucesso considerando-se de 10% a 15% do total de pontos das malhas. Valores acima deste patamar tornam o processo mais caro computacionalmente e sem grandes melhorias na qualidade do alinhamento. Só é interessante aumentar este valor nos casos em que o registro não é realizado com sucesso.

3.2. Filtragem de Correspondências

Os parâmetros analisados no processo de filtragem foram o *threshold* de consistência geométrica (T_{gc}) , a proporção das correspondências $(prop_{GC})$ que devem ser geometricamente consistentes a uma dada correspondência para que esta passe na filtragem, e a área mínima de sobreposição entre as malhas para que a transformação seja validada.

O valor determinado para o *threshold* de consistência geométrica T_{gc} é fundamental no processo de filtragem. Valores altos não filtram correspondências inconsistentes, gerando transformações inválidas. Valores muito baixos podem excluir correspondências consistentes, que são valiosas para o cálculo da transformação. Valores no intervalo entre 0.1 e 0.15 apresentaram os melhores resultados.

Do mesmo modo, é necessário definir corretamente o parâmetro $prop_{GC}$ para a filtragem correta das correspondências. Este apresentou bons resultados entre 20% e 25% da quantidade de correspondências.

Finalmente, a área mínima de sobreposição para validar as transformações deve ser definida de acordo com a área de sobreposição esperada. Nos modelos analisados, pelo menos 30% dos pontos das malhas registradas com sucesso estavam contidos em regiões de sobreposição.

Apesar de todas as filtragens e validações aplicadas, existem casos onde o registro é inconsistente. A Figura 9 exibe um exemplo onde as duas malhas apresentam lados opostos de um objeto que apresentam uma certa simetria, fazendo com que *spin-images* de diferentes pontos sejam iguais. Como os lados são simétricos, os testes de consistência geométrica também são validados. Finalmente, a transformação encontrada também resulta em uma grande região de sobreposição. Porém, o alinhamento é claramente inconsistente.



Figura 9. Registro inconsistente devido à simetria.

3.3. Algoritmo ICP

Dadas duas malhas inicialmente posicionadas, o algoritmo ICP implementado neste trabalho apresentou ótimos resultados no alinhamento final das malhas. Para este sucesso, foi fundamental a correta identificação das regiões de sobreposição que foram utilizadas no registro.

Como já foi descrito no capítulo 4, a detecção das regiões de sobreposição é feita usando-se um *threshold* de distância que descarta pares de pontos distantes. Este *threshold* apresentou bons resultados com valor definido entre 1 e 1.5 vezes a resolução da malha. O uso de *kd-trees* também foi fundamental para a performance desta etapa.

3.4. Invariância por Resolução

Um último aspecto que merece destaque é o registro de malhas com diferentes resoluções. Definindo-se corretamente o tamanho das caixas das *spin-images* e sua resolução, o efeito de diferentes resoluções é normalizado pelas *spin-images*. Malhas com alta resolução implicam muitos pontos em cada caixa. Malhas com baixa resolução adicionam poucos pontos em cada caixa. Como o tom de cinza de cada pixel é normalizado de acordo com a maior quantidade de pontos em uma caixa, as imagens serão parecidas. A Figura 10 exibe uma malha com 3.000 pontos e uma malha com 1.000 pontos, e o resultado do alinhamento.

Para otimizar o custo computacional do alinhamento, que pode ser bastante caro em mm malhas com mais de 10.000 pontos, uma alternativa interessante é calcular os alinhamentos em versões simplificadas das malhas, e aplicar as transformações encontradas nas malhas originais. Malhas que apresentaram resultados robustos com boa performance tinham, em média, 3.000 pontos.

3.5. Resultados

Esta subseção apresenta alguns modelos alinhados e reconstruídos. A Figura 11(a) exibe o alinhamento de uma versão em baixa resolução do bunny, composta por 13 malhas com aproximadamente 900 pontos cada uma. A Figura 11(b) exibe sua reconstrução.

A Figura 12(a) exibe o alinhamento de 7 malhas obtidas artificalmente do modelo de uma mão, com aproximadamente 3.000 pontos cada uma, A Figura 12(b) exibe sua reconstrução com 10.000 pontos usando o método MPU.

Outro exemplo sintético é exibido na Figura 13(a), com sua respectivamente reconstrução exibida na Figura 13(b), onde foram utilizadas 12 malhas com aproximadamente 5.000 pontos cada uma. A Figura 14(a) contém o alinhamento de 5 malhas obtidas por um scanner 3D de uma cabeça, com aproximadamente 3.500 pontos cada uma. Sua reconstrução usando a reconstrução de Poisson tem 12.000 pontos e é exibida na Figura 14(b).

Finalmente, a Figura 15(a) exibe uma boneca representada por 12 malhas alinhadas, com 15.000 pontos cada, obtidas por um scanner 3D. Sua reconstrução com 180.000 pontos é exibida na Figura 15(b).

4. Conclusão e Trabalhos Futuros

Este trabalho apresentou um procedimento para registro automático e reconstrução de superfícies a partir de malhas capturadas de scanners 3D. Utilizando descritores *spin images*, o método utilizado é capaz de suprir o principal requisito do algoritmo ICP: uma estimativa inicial do alinhamento.

Na primeira etapa, estima-se um posicionamento inicial das malhas. A segunda etapa refina o alinhamento entre as malhas usando uma variante do algoritmo ICP. Esses primeiros módulos foram implementados neste trabalho. A terceira etapa realiza a reconstrução do modelo, dadas as malhas alinhadas.



(a) Malhas com 3.000 pontos e 1.000 pontos.



(b) Malhas registradas.

Figura 10. Registro de malhas com diferentes resoluções.

De modo geral, o posicionamento inicial automático apresentou bons resultados com os modelos analisados. A variante do algoritmo ICP gerou resultados robustos quando aplicada a malhas com bom posicionamento inicial. Finalmente, a qualidade final dos alinhamentos permitiu a reconstrução de modelos consistentes com os objetos originais.

Segue abaixo uma lista de melhorias que poderiam ser aplicadas ao método apresentado:

- Grafo de alinhamento: Atualmente, dado um conjunto de n malhas, o registro é testado e efetuado duas a duas, resultando num algoritmo quadrático. A implementação de uma estrutura de grafo pode otimizar esse processo.
- Análise de spin-images com textura: Uma análise das spin-images com textura é interessante, principalmente para realizar registro de superfícies simétricas, como um vaso, por exemplo.
- Variantes do algoritmo ICP: A implementação de outras variantes do algoritmo ICP pode implicar melhores resultados na qualidade do registro das superfícies.
- Alinhamento global com reconstrução: Neste trabalho, o registro é realizado localmente para cada par de pontos, sem nenhum teste de coerência global. A reconstrução pode ser utilizada como uma boa referência para realizar o alinhamento das malhas de maneira global.

Referências

- [1] P. J. Besl and N. D. Mckay. A method for registration of 3D shapes. Pattern Analysis and Machine Intelligence, 14(2):239-256, Feb. 1992.
- [2] B. Curless and M. Levoy. A volumetric method for building complex models from range images. In Siggraph, volume 30, pages 303-312. ACM, 1996.
- [3] B. Horn. Closed-form solution of absolute orientation using unit quaternions. Optical Society of America, 4:629-642, 1987.
- [4] A. Johnson. Spin-Images: A Representation for 3D Surface Matching. PhD thesis, Carnegie Mellon University, Pittsburgh, Aug. 1997. Advised by Martial Hebert.
- [5] M. Kazhdan, M. Bolitho, and H. Hoppe. Poisson surface reconstruction. In Symposium on Geometry Processing, pages 61-70. ACM/Eurographics, 2006.
- [6] M. Levoy, K. Pulli, B. Curless, S. Rusinkiewicz, D. Koller, L. Pereira, M. Ginzton, S. Anderson, J. Davis, J. Ginsberg, J. Shade, and D. Fulk. The digital Michelangelo project: 3D scanning of large statues. In Siggraph, pages 131-144, New York, 2000. ACM.
- [7] P. Neugebauer. Geometrical cloning of 3D objects via simultaneous registration of multiple range images. In Shape Modeling and Applications, page 130, Washington, 1997.

- [8] Y. Ohtake, A. Belyaev, M. Alexa, G. Turk, and H.-P. Seidel. Multi-level partition of unity implicits. In Siggraph, volume 22, pages 463-470, New York, 2003. ACM.
- [9] D. Simon. Fast and Accurate Shape-Based Registration. PhD thesis, Carnegie Mellon University, Pittsburgh, Dec. 1996.



(b) Reconstrução.

Figura 11. Modelo do bunny.



(a) Malhas alinhadas.



(b) Reconstrução.

Figura 12. Modelo de uma mão.



(a) Malhas alinhadas.



(b) Reconstrução.

Figura 13. Modelo de um cavalo.



(a) Malhas alinhadas.



(b) Reconstrução.

Figura 15. Modelo de uma boneca.



(a) Malhas alinhadas.

(b) Reconstrução.

Figura 14. Modelo de uma cabeça.