4 Método proposto

Este capítulo tem por objetivo descrever detalhadamente os conceitos e diversos processos aplicados na concepção e modelagem do um novo método de múltipla calibração de câmeras baseado num padrão invariante. A proposta deste método é o tema principal desta tese.

O método apresentado neste trabalho pode ser definido como híbrido, o que significa que é composto por dois tipos de métodos de calibração básicos: um método fotogramétrico e um de auto-calibração, que já foram descritos na seção 2.1.2.

A mistura desses dois tipos de métodos de calibração básicos é feita com os seguintes propósitos:

- O uso de um método fotogramétrico permite calcular uma estimativa inicial confiável dos parâmetros intrínsecos e dos coeficientes de distorção da lente para cada câmera do sistema. Esse tipo de método é muito útil porque permite nos recuperar uma estimativa inicial dos parâmetros intrínsecos e dos coeficientes de distorção da lente de câmeras cujas informações específicas eram desconhecidas. Um outro cenário no qual esta opção também é aplicável é quando temos câmeras que mudam constantemente o tipo de lente para poder cobrir um campo de visão maior ou menor.
- A utilização de um método de auto-calibração permite realizar o cálculo dos parâmetros extrínsecos que relacionam a posição de uma câmera com a de outra. A ideia deste tipo de método num sistema com múltiplas câmeras é realizar a calibração dos parâmetros extrínsecos de todas as possíveis combinações de duas câmeras que podem ser geradas para nosso sistema de n câmeras e, com esses resultados, encontrar a melhor calibração, duas a duas câmeras, que permita relacionar todas as câmeras do sistema, criando uma concatenação entre elas. A ideia de concatenação das calibrações dos diversos sistemas estéreo foi proposta no trabalho de [14], que se

PUC-Rio - Certificação Digital Nº 0510968/CA

mostrou muito útil quando foi precisou calibrar múltiplas câmeras que cobriam uma área de rastreamento muito ampla e bem distribuída.

A combinação do uso desses dois tipos de calibração define a estrutura base de um método híbrido. Esta estrutura permite uma maior flexibilidade e robustez no cálculo de todos os parâmetros de calibração, especialmente quando se tem equipamentos muito variados ou se precisamos cobrir áreas de rastreamento amplas ou pequenas.

Nas seções a seguir, serão descritos os diferentes processos que compõem a estrutura de nosso método.

4.1. Descrição do método

O método proposto neste trabalho surgiu da iniciativa de implementar uma técnica que permita calibrar simultaneamente um sistema formado por múltiplas câmeras. No começo, ao analisar o problema da múltipla calibração e os distintos métodos encontrados na literatura sobre o tema, percebemos que os métodos mais novos adotam uma estrutura híbrida, definida pelo o uso simultâneo de dois tipos de calibração básica: a fotogramétrica e a de auto-calibração. Cada um desses dois tipos de calibração é utilizado para o cálculo de um tipo de parâmetro específico das câmeras. O método fotogramétrico é comumente aplicado para calcular os parâmetros intrínsecos e os coeficientes de distorção de cada câmera, e o de auto-calibração é útil para calcular os parâmetros extrínsecos.

Levando em consideração a flexibilidade e a robustez que uma estrutura híbrida oferece, decidimos modelar o nosso método seguindo esse conceito.

Outro fator que também chamou a nossa atenção foi a evolução do formato dos diferentes padrões de calibração usados em trabalhos referentes ao processo de múltipla calibração, os quais foram especialmente propostos por métodos de auto-calibração (Figura 19). Nós observamos que tanto os padrões unidimensionais como adimensionais descritos nas seções 2.1.3 e 2.1.4 têm sido os mais utilizados na proposta de novos métodos de múltipla calibração [4][7][8][14][22][28][32] e [37], assim como em possíveis evoluções desses métodos que são implementadas em produtos comerciais [1][39][13] e [26]. Percebemos que o motivo principal do uso desse tipo de padrão é sua ampla

PUC-Rio - Certificação Digital Nº 0510968/CA

visibilidade e fácil identificação quando capturado por múltiplas câmeras simultaneamente. Essa característica é importantíssima especialmente quando temos configurações de câmeras cujos campos de visão têm ângulos de interseção que impossibilitariam a captura simultânea de várias vistas válidas do padrão, como acontece, por exemplo, com padrões mais complexos como os clássicos padrões planares.

Figura 19: Evolução dos padrões (a) planar, (b) unidimensional, (c) adimensional.

Nessa evolução, especialmente do padrão unidimensional para o adimensional, algumas informações úteis foram perdidas, como a distância existente entre os diversos marcadores que compõem um padrão unidimensional. A redução no número de marcadores pode gerar um padrão de formato mais simples e fácil de capturar, porém, a diminuição das informações implícitas que o padrão pode fornecer afeta diretamente a última etapa do processo de múltipla calibração, que é a otimização dos parâmetros de calibração. As informações implícitas no formato do padrão ajudam a modelar algumas funções de controle que compõem a função de erro global, definida como um dos componentes básicos do algoritmo de otimização. Quanto mais informações temos em relação às características implícitas do padrão, melhor estará definida a função de erro. Outro problema que surge quando simplificamos o formato do padrão de calibração é a diminuição da robustez no reconhecimento do mesmo como padrão único. Isso é especialmente ressaltado na etapa de aquisição de dados, onde é feita a captura de várias vistas do padrão nas quais teremos que identificá-lo corretamente e correlacionar individualmente os marcadores que o compõem.

Como foi relatado nas seções 2.1.3 e 2.1.4 uma das desvantagens em comum, dos padrões unidimensional e adimensional, é a fácil contaminação da amostra de vistas capturadas com falsos marcadores, devido ao reconhecimento de objetos com formatos semelhantes que podem ser facilmente confundidos com os marcadores. Esse falso reconhecimento pode estar relacionado à falta de uma estrutura robusta que permita identificar o conjunto de marcadores que compõe o

PUC-Rio - Certificação Digital Nº 0510968/CA

padrão como um objeto único. Um exemplo é o caso do padrão planar, cuja estrutura definida pela distribuição dos pontos de referência na sua superfície pode servir como método de reconhecimento robusto, capaz de filtrar e descartar possíveis objetos muito semelhantes ao padrão.

Com base na análise das características e problemática acima descritas em relação à definição e ao reconhecimento de um padrão de calibração simples e robusto, nós propomos como parte de nosso método de múltipla calibração de câmeras, um novo tipo de padrão unidimensional definido como padrão invariante cuja estrutura é formada por um conjunto de quatro marcadores (Figura 20).

Este novo tipo de padrão tenta manter as vantagens dos padrões unidimensional e adimensional em relação à visibilidade e ao fácil reconhecimento e, ao mesmo tempo, procura dar robustez ao processo de reconhecimento do padrão como objeto único. A robustez vem da aplicação de um novo método de reconhecimento criado e testado especialmente para este tipo de padrão nos trabalhos de [16][33][20][21]. A principal contribuição desse novo processo de reconhecimento do padrão é a capacidade de identificar o padrão como um objeto único, o que depois permitirá a identificação individual dos marcadores que o compõem. Outra vantagem é poder usar mais de um desses padrões simultaneamente no mesmo espaço de rastreamento quando realizamos a captura da amostra para calibração. O processo de reconhecimento desse tipo de padrão é implementado apenas com a análise das informações 2D das posições dos marcadores em coordenadas da imagem, processo feito só na etapa inicial de aquisição de dados (Figura 20).

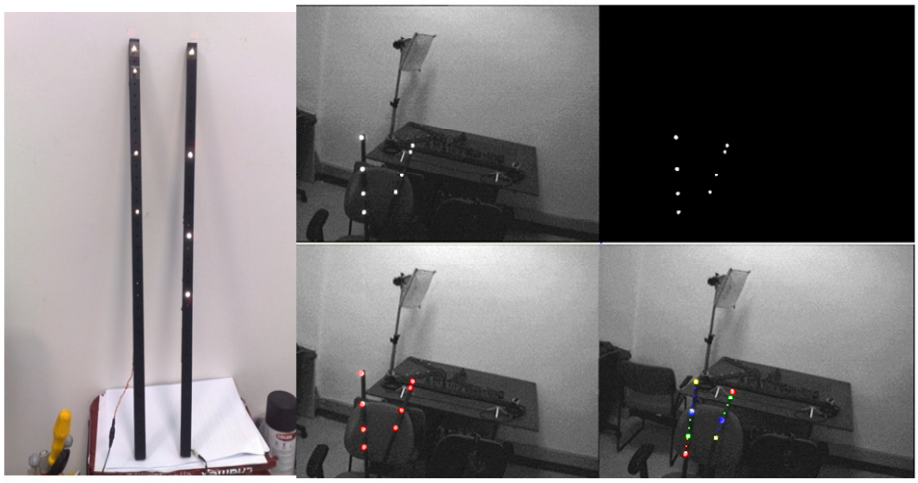

Figura 20: Padrões invariantes e processamento 2D para identificação individual.

PUC-Rio - Certificação Digital Nº 0510968/CA

Finalmente, a proposta desse novo tipo de padrão invariante gera informações implícitas, devido a seu formato, que permitirão usar todas as funções de controle definidas na seção 2.3.1, com as quais podemos modelar uma função de erro global robusta na etapa de otimização. No entanto, além dessas funções, propomos modelar a característica de colinearidade de nosso padrão, como mais duas funções de controle para o processo de otimização. Definimos duas funções de controle porque consideraremos que o teste de colinearidade pode ser efetuado tanto com as posições 2D dos marcadores extraídas da imagem, como também com a colinearidade dos marcadores após serem reconstruídos em 3D no espaço de rastreamento. Isso pode ser feito usando um algoritmo de triangulação, a estimativa dos parâmetros das câmeras e as posições 2D dos pontos correspondentes da amostra de calibração.

Para descrever um resumo dos processos que compreendem o método proposto neste trabalho, nós usaremos como guia o framework conceitual definido na seção 2.3:

- **Aquisição de dados:** sendo um método híbrido, nosso método usa dois tipos de padrão de calibração - um padrão planar, aplicado para realizar a calibração fotogramétrica, e um padrão unidimensional, baseado no padrão invariante proposto utilizado para executar o método de auto-calibração.
- **Calibração inicial:** aplicamos o método descrito na seção 2.2.1.3 para calcular uma estimativa inicial dos parâmetros intrínsecos e dos coeficientes de distorção da lente para cada câmera do sistema. Além disso, usamos o método de auto-calibração descrito na seção 2.2.2.4 para calcular uma estimativa inicial dos parâmetros extrínsecos de cada par de câmeras definidos como produto da combinação das *n* câmeras que formam o sistema de múltiplas câmeras.
- **Otimização da calibração:** devido à informação fornecida pelo padrão invariante, nosso método permite que a função de erro global seja definida usando todas as funções de controle descritas na seção 2.1.3, às quais é possível acrescentar duas funções de controle adicionais propostas com base na colinearidade dos marcadores que compõem o padrão invariante: colinearidade 2D e 3D.

PUC-Rio - Certificação Digital Nº 0510968/CA

Nas seções a seguir, serão descritas mais detalhadamente as etapas do framework conceitual acima.

4.1.1. Aquisição de dados

Nesta primeira etapa do processo de múltipla calibração de câmeras, descreveremos como é feito o processo de captura de cada um dos padrões usados pelo método proposto.

4.1.1.1. Captura do padrão planar

O primeiro processo a ser realizado nesta etapa de calibração é a captura de um número entre 100 e 200 vistas de um padrão planar semelhante ao formato de um tabuleiro de xadrez mostrado da Figura 21.

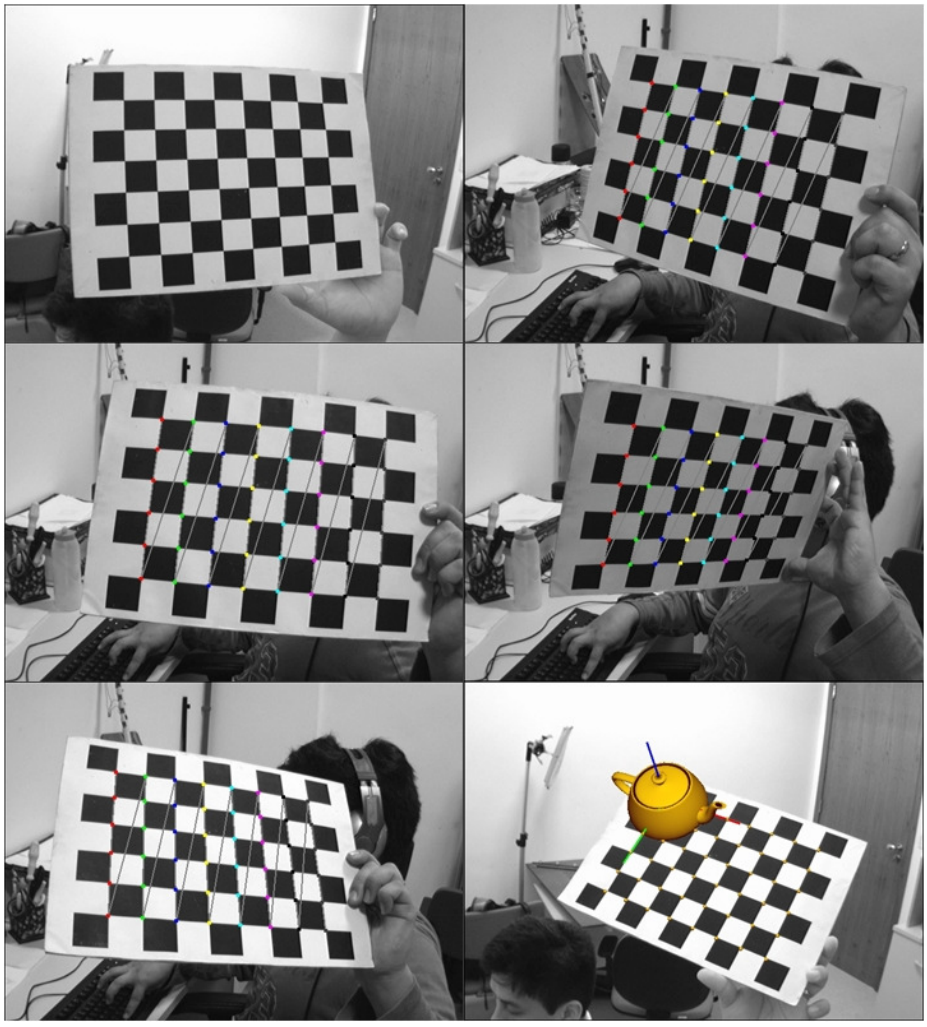

Figura 21: Captura do padrão planar para calibração fotogramétrica.

PUC-Rio - Certificação Digital Nº 0510968/CA

O processo de captura desse padrão planar é realizado individualmente em cada câmera do sistema. Para capturar e reconhecer este tipo de padrão a partir das imagens capturadas, nós usamos a implementação em C++ fornecida pela biblioteca OpenCV[12].

4.1.1.2. Captura do padrão invariante

O segundo passo desta etapa de aquisição de dados é a captura de uma amostra de vistas do novo padrão invariante, que é constituído por quatro marcadores colineares. Esse tipo de padrão foi inicialmente proposto dentro da área de reconhecimento de padrões, como definido nos trabalhos de Meer et al. [20] [21]. Achamos a teoria por trás do reconhecimento desse padrão interessante, e a analisamos e testamos num ambiente onde a tarefa seria modelar e usar esse tipo de padrão como padrões usados na calibração de câmeras. Alguns trabalhos prévios definidos sobre esses testes foram descritos em Loaiza et al.[16][33].

A teoria sobre características projetivas invariantes propõe que a relação definida pelo *cross ratio* calculado a partir de quatro pontos colineares gera um tipo de identificador único que permite diferenciá-lo de outro grupo de quatro pontos colineares cujas distâncias entre os pontos que o compõem sejam totalmente diferentes das distâncias do primeiro conjunto. A relação definida pelo *cross ratio* para um grupo de quatro pontos colineares foi estudada por Meer et al. [20] e, baseado nessa relação, ele propôs uma técnica denominada "P^2-*invariant*" (Apêndice B), que propõe uma forma de gerar um identificador único para este tipo de padrão colinear. O identificador proposto por Meer et al. [20] foi testado por nós em Loaiza et al. [16] e ficou sendo definido não como sendo um valor único, e sim como um intervalo contendo um valor mínimo e um máximo.

O motivo pelo qual o valor do identificador é melhor definido como um intervalo vem de imprecisões geradas no processo de extração das posições 2D dos pontos que formam o padrão colinear na imagem. Leves variações do valor da posição 2D recuperado a partir de uma imagem geram pequenos ruídos no cálculo do valor do *cross ratio* e afetam o processo de geração do valor do identificador "P^2-*invariant*". No entanto, como foi testado em [16], essas variações não são muito distantes e podem ser mensuradas dentro de um intervalo totalmente único em comparação a outro padrão colinear.

PUC-Rio - Certificação Digital Nº 0510968/CA

A característica de poder criar um identificador único (*ProjInvID*) para esse tipo padrão permite que este seja mais robusto se comparado aos padrões unidimensional e adimensional mostrados na Figura 19.

Para poder então calcular o valor do *ProjInvID* de cada padrão invariante, precisa-se realizar uma etapa de treinamento onde calcularemos os valores do intervalo único definido como identificador único para cada padrão.

Portanto, o processo de captura da amostra de vistas para o padrão invariante é dividido em duas fases: treinamento e captura real.

4.1.1.2.1. Treinamento do padrão invariante

O treinamento do padrão invariante consiste na captura de várias vistas do padrão colinear onde será calculado o valor do identificador "P^2-*invariant*" para cada vista analisada. Obtido este resultado, armazenaremos o menor e o maior valor calculado para o identificador "P^2-*invariant*", que será usado como valores mínimo e máximo de um intervalo definido como o identificador único do padrão " *ProjInvID* ".

Nesta primeira parte do treinamento, é importante fazer uma observação adicional: no trabalho inicial de [20] onde foi definido o identificador "P^2-*invariant*" não foram levados em conta os problemas que podem surgir por causa da distorção da lente da câmera, que por exemplo no caso de lentes grande angular podem distorcer significativamente a característica colinear dos pontos. Nos trabalhos [20] e [21], a distorção das lentes era baixa e não deteriorou o processo de treinamento e reconhecimento de nosso padrão colinear. Porém, propomos neste trabalho um caso singular ao usarmos lentes com grande distorção, como por exemplo uma lente grande angular. Nesse caso nossa proposta é executar apenas a etapa de treinamento e a posterior captura do padrão se tivermos a informação necessária para corrigir a distorção da lente. Isso é possível se considerarmos que podemos obter o valor dos coeficientes de distorção da lente com a calibração inicial desses parâmetros feita a partir da amostra de vistas do padrão planar descrita na seção anterior. Com essa consideração continuaremos a relatar como é o processo de treinamento do padrão invariante, que é descrito abaixo e visualmente exemplificado na Figura 22:

PUC-Rio - Certificação Digital Nº 0510968/CA

1. Em cada vista do padrão extrair e calcular as coordenadas 2D de cada marcador que compõe o padrão colinear. Esse processo é semelhante ao definido no final da seção 2.1.1 (Figura 22).
2. Avaliar se há quatro pontos 2D identificados na imagem.
3. Testar se os quatro pontos têm certo grau de colinearidade. Para isso, é usado um algoritmo de aproximação de linha (*fitting line*) e definido como limiar uma distância máxima permitida de três pixels da linha calculada a qualquer marcador do padrão.
4. Calcular o valor do identificador "P^2-*invariant*" para o padrão colinear.
5. Armazenar o menor e o maior valor achado no cálculo do valor em cada vista ($P^2\text{-}invariant_{min}$, $P^2\text{-}invariant_{max}$).
6. Testar todas as vistas, e definir como identificador do padrão colinear o intervalo definido pelos valores mínimo e máximo do identificador "P^2-*invariant*" calculados nas *n* vistas capturadas do padrão ($ProjInvID = [\ P^2\text{-}invariant_{min}$, $P^2\text{-}invariant_{max}\ ]$).

Por fim, repetimos o processo anterior para cada câmera e para cada novo padrão colinear a ser utilizado. O número mínimo de vistas capturadas para o treinamento em nossa implementação foi de 100 vistas para cada padrão analisado. Na Figura 22, mostramos algumas vistas capturadas durante processo de treinamento de um mesmo padrão invariante feito simultaneamente num sistema formado por quatro câmeras.

PUC-Rio - Certificação Digital Nº 0510968/CA

Figura 22: Processo de treinamento feito simultaneamente num sistema de 4 câmeras.

Um último detalhe no processo de treinamento do padrão invariante é definir o reconhecimento individual de cada marcador que o compõe. Para realizar essa identificação, definimos uma heurística simples baseada na proporção da distância entre os dois primeiros e dois últimos marcadores em relação à distância de todo o padrão, tudo em 2D. Como é possível observar na Figura 23, montamos nossos marcadores de tal forma que eles não tenham a mesma distância entre eles. Além disso, também foi feito um distanciamento menor entre os primeiros marcadores (*A,B*) em relação aos dois últimos (*C,D*). Esse distanciamento diferenciado permite definir como primeiro marcador aquele que fica no extremo do padrão que faz parte dos dois marcadores que definem a menor distância. Isso gera como conseqüência uma proporção menor dessa distância em relação à distancia total definida pelos quatro marcadores. Nós escolhemos não trabalhar

PUC-Rio - Certificação Digital Nº 0510968/CA

comparando as distâncias porque, como é bem conhecido nesse tipo de projeção 3D-2D, as distâncias não são preservadas numa projeção em perspectiva, porém quando testadas as proporções geradas pelas distâncias *AB/AD* < *DC/AD* (Figura 24), estas se mostraram como indicadores referenciais muito úteis para definir o primeiro e último marcador do padrão. Então comprovou-se que nossa heurística gera resultados confiáveis quando aplicada depois da identificação grupal acertada do arranjo de marcadores colineares usando o valor do *ProjInvID*. Só depois de os marcadores estarem bem identificados como grupo procede-se a calcular a heurística descrita acima para identificar e etiquetar cada marcador do padrão, tal como é mostrado na Figura 23.

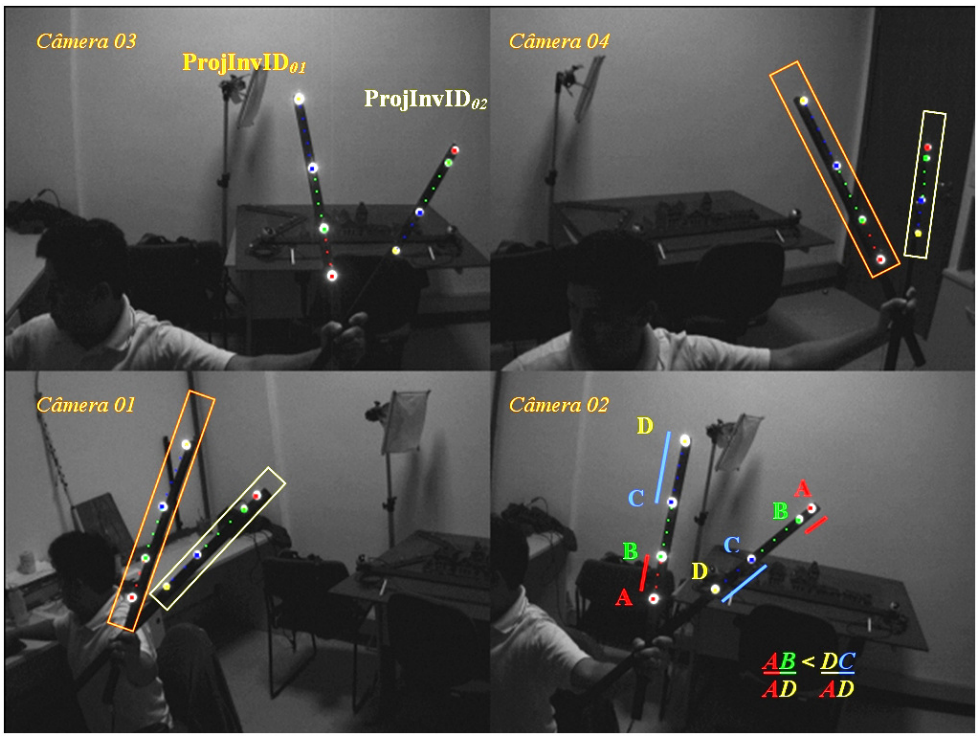

Figura 23: Identificação grupal e etiquetação individual dos marcadores que compõem os padrões invariantes.

Após termos treinado todos os padrões colineares a serem utilizados como padrões de calibração, e termos definido como é feita a identificação individual de cada marcador do padrão, podemos prosseguir para a etapa seguinte, referente à captura da amostra de calibração simultânea em todas as câmeras que nos permita executar o método de auto-calibração.

PUC-Rio - Certificação Digital Nº 0510968/CA

4.1.1.2.2. Captura da amostra do padrão invariante

Diferentemente da etapa de treinamento, a captura da amostra de vistas do padrão ou padrões invariantes é feita de forma simultânea por todas as câmeras. Isso significa que movimentaremos nossos padrões pelo espaço de rastreamento e, à medida que eles são reconhecidos simultaneamente pelas diferentes câmeras, serão preenchidos buffers contendo a informação de pontos correspondentes definidos pelo reconhecimento simultâneo de um mesmo padrão nas diferentes câmeras. O processo de captura é descrito a seguir:

1. Carregar os valores dos identificadores $ProjInvID_i$ (i=1...*número de padrões*) de cada padrão colinear previamente treinado em cada câmera $CameraID_j$ (j =1...*número de câmeras*).
2. Extrair e calcular as coordenadas 2D de cada marcador que compõe um possível padrão colinear, processo é semelhante ao mostrado na Figura 22.
3. Avaliar se temos *número de marcadores 2D* ≥ 4 corretamente identificados na imagem.
4. Gerar combinações de quatro marcadores a partir dos N pontos reconhecidos na imagem C_4^N .
5. Para cada uma das combinações:
    a. Testar se os quatro marcadores 2D da combinação têm certo grau de colinearidade. Para isso, usamos um algoritmo de aproximação de linha (*fitting line*) e definimos como limiar uma distância máxima permitida de três pixels entre a linha calculada pelo algoritmo e qualquer marcador do padrão.
    b. Se o padrão for colinear, calcular o valor do identificador "P^2-*invariant*", se não for, continuar com a próxima combinação.
    c. Calcular e comparar o valor do identificador "P^2-*invariant*" do padrão colinear com cada um dos identificadores $ProjInvID_i$ (i=1...*número de padrões*) dos padrões previamente treinados.
    d. Se o padrão colinear tiver um identificador considerado semelhante a algum identificador treinado, armazenar as

PUC-Rio - Certificação Digital Nº 0510968/CA

posições 2D dos marcadores que o compõem e ativar um indicador $Match_{ij}$ que detalhe que o padrão $ProjInvID_i$ foi identificado na câmera $CameraID_j$. Se o identificador não for semelhante aos $ProjInvID_i$ carregados, continuar com a próxima combinação.

6. Após analisadas todas as vistas capturadas simultaneamente nas m câmeras num mesmo tempo t , realizaremos as correspondências entre padrões corretamente identificados entre todas as câmeras.
    a. Para cada par de câmeras $CameraID_x$ e $CameraID_y$, onde $x \neq y$, verificar se o mesmo indicador $Match_{ix}$ e $Match_{iy}$ para o padrão i está ativo nas duas câmeras.
    b. Se o indicador $Match_{ij}$ estiver ativo nas duas câmeras, x e y , então armazenar os valores das coordenadas 2D dos marcadores do padrão colinear identificado em ambas as câmeras num buffer de pontos correspondentes $CorrespondencePoints_{x,y}$.
7. Após completar um número de n vistas de padrões invariantes colineares devidamente correlacionadas entres as câmeras x e y , terminar o processo de captura da amostra entre esse par de câmeras.
8. Após capturadas as n vistas entre todas as combinações de duas câmeras de nosso sistema, terminar o processo de captura da amostra entre todas as câmeras.

Finalmente, com isso capturamos nossa amostra de calibração para executar o método de auto-calibração entre cada par de câmeras. Cabe ressaltar que em nossa implementação foram utilizados dois tipos de padrões invariantes (Figura 24), com os quais foi capturada essa amostra de calibração. O motivo principal de usar só dois padrões invariantes é o custo computacional gerado quando se usam mais de dois padrões, o que equivale a usar (*número de padrões* × 4 = *N*) marcadores. Se analisarmos especialmente o passo 4 da descrição do processo de captura acima, observaremos que a geração de combinações C_4^N - definida para encontrar os conjuntos de quatro marcadores colineares a partir dos n marcadores detectados na imagem - pode crescer exponencialmente à medida que aumentamos o número de padrões invariantes. Por esse motivo, preferimos limitar o uso de dois padrões invariantes simultâneos para capturar a amostra de

PUC-Rio - Certificação Digital Nº 0510968/CA

calibração. O número de vistas capturadas dos padrões invariantes entre os pares de câmeras variou de 50 até 2500 vistas do padrão.

Figura 24: Captura simultânea dois padrões invariantes num sistema de quatro câmeras.

4.1.2. Calibração inicial

Nesta segunda etapa do processo de múltipla calibração de câmeras, descreveremos quais algoritmos foram usados para realizar os dois tipos de calibração básica escolhidos pelo método proposto. Assim, dividiremos esta etapa em duas partes, correspondentes às descrições dos métodos de calibração fotogramétrica e de auto-calibração.

4.1.2.1. Calibração fotogramétrica

Para implementar o método de calibração fotogramétrica, utilizamos como referência o método de Zhang [40], cuja descrição teórica foi detalhada na seção 2.2.1.3 Para tal usamos a implementação deste método fornecida pela biblioteca em OpenCV[12], e os parâmetros recuperados são:

PUC-Rio - Certificação Digital Nº 0510968/CA

- Parâmetros intrínsecos: (f_x, f_y) e centro da imagem (u_0,v_0) definidos no modelo de câmera descrito no apêndice A.
- Coeficientes de distorção da lente: distorção radial (*k1*,*k2*) e tangencial (*p1*,*p2*) também descritas no apêndice A.

A informação necessária para executar o método de calibração fotogramétrico é fornecida pela amostra de pontos referenciais obtidos a partir da captura e do processamento das vistas do padrão planar (Figura 21). Nós usamos amostras contendo entre 50 e 200 vistas do padrão planar, que foram capturadas entre 30 e 60 cm de distância das câmeras.

4.1.2.2. Auto-calibração

O método de auto-calibração usado neste trabalho é o mesmo descrito por Dorfmüller-Ulhaas em [7][8], e cuja descrição teórica foi feita na seção 2.2.2.4 Este processo pode ser definido como a calibração dos *m* sistemas estéreos definidos pelo número de combinação C_2^n onde *n* é o número de câmeras que formam o sistema. Os parâmetros extrínsecos recuperados são:

- Matriz de rotação R_i , onde $i = 1...m$ e $m = C_2^n$. Esta matriz pode ser modelada pela composição de três ângulos de rotação de Euler definidos como (α, β, γ). Essa simplificação é muito usada especialmente para diminuir o número de parâmetros na etapa de otimização.
- Vetor translação T_i , onde $i = 1...m$.

A informação necessária para a execução do método de auto-calibração é fornecida pela amostra de pontos referenciais obtidos a partir da captura e do processamento das vistas do padrão invariante e da estimativa inicial dos parâmetros intrínsecos e coeficientes de distorção da lente, calculados com o método de calibração fotogramétrica.

Um processo importante dentro no método de auto-calibração é o calculo da matriz fundamental. O algoritmo utilizado para descrever esse cálculo foi o clássico algoritmo dos 8 pontos, considerado como um método linear que produz uma boa solução para o valor da matriz fundamental na presença de 8 pontos correspondentes. Porém, nós temos um sistema de equações sobredimensionado por causa do grande número de pontos correspondentes contidos na amostra

PUC-Rio - Certificação Digital Nº 0510968/CA

capturada com o padrão invariante, por esse motivo, é necessário usar um método mais robusto para o cálculo da matriz fundamental.

Uma estratégia usada para dar robustez ao cálculo da matriz fundamental é usar um algoritmo iterativo em conjunto com um método linear, como o definido pelo algoritmo de 8 pontos. Um exemplo dessa estratégia é mostrada nos trabalhos [34] e [31], onde utiliza-se o algoritmo de RANSAC [9] em conjunto com o algoritmo de 8 pontos. O novo algoritmo aplicado para realizar o cálculo da matriz fundamental mistura o uso do algoritmo dos 8 pontos e o insere na rotina de otimização iterativa definida como parte da execução do algoritmo de RANSAC. Uma vantagem dessa estratégia é que o algoritmo de RANSAC determinará a cada iteração, possíveis pontos erroneamente correspondidos (*outliers*), o que é muito útil. A implementação deste algoritmo pode ser encontrada na biblioteca OpenCV [12] e foi a utilizada em nosso cálculo da matriz fundamental no método proposto neste trabalho.

Uma vez calculada a matriz fundamental, o passo seguinte é a extração da matriz essencial usando os parâmetros intrínsecos calculados na calibração fotogramétrica. É a partir da matriz essencial que recuperaremos a orientação e a posição de uma câmera em relação a seu par correspondente. O processo de auto-calibração é realizado em cada um dos m (= C_2^n) sistemas de câmera em estéreo definidos em nosso sistema. Na implementação, todos os processos referentes à recuperação da posição e da orientação das câmeras foram implementados seguindo os algoritmos e os detalhes descritos em [7][8][10][18] e cuja explicação detalhada foi já descrita na seção 2.2.2.4 desta tese.

Por fim, terminado o cálculo de uma solução inicial para todos os parâmetros das câmeras, procederemos com a próxima etapa do processo de calibração, que é a otimização desses parâmetros, descrita na seção seguinte.

4.1.2.3. Otimização dos parâmetros

Nesta terceira etapa do processo de calibração, descreveremos como o método proposto neste trabalho usa toda a informação implícita relacionada às características do formato do padrão invariante para definir e modelar distintas funções de controle com as quais montaremos uma função de erro global, usada

PUC-Rio - Certificação Digital Nº 0510968/CA

na otimização dos parâmetros das câmeras. Como foi descrito na seção 2.1.3.1, as funções de controle são modeladas com base em:

- Estimativa ou medição de certas características extraídas do formato do padrão, como, por exemplo medição e comparação de distâncias 3D entre marcadores.
- Estimativa ou medição de certas características relacionadas ao processo de calibração e à informação extraída da amostra de calibração, como: reprojeção 3D-2D, reprojeção 2D-2D e reconstrução 3D dos marcadores.

Para realizar a estimativa ou medição das características relacionadas ao padrão, são usadas funções matemáticas que internamente são compostas e dependem dos valores dos parâmetros das câmeras que desejamos otimizar. Quanto mais informações podemos extrair do formato do padrão, melhor será a modelagem matemática das características nele implícitas.

Portanto, as funções de controle então são criadas para quantificar e controlar o valor correto dessas características quando são testadas novas soluções para os parâmetros das câmeras geradas durante a execução do algoritmo de otimização.

PUC-Rio - Certificação Digital Nº 0510968/CA

4.1.2.3.1. Definição da função de erro global

A maioria dos algoritmos de otimização precisa de uma função de erro global para guiar e salvar as melhores mudanças nos valores dos parâmetros que estão sendo otimizados. Os trabalhos apresentados no capítulo 3 definem suas funções de erro baseados nas funções de controle expostas na seção 2.1.3.1. Nem todas as funções de controle são usadas simultaneamente em alguns desses trabalhos, isso porque, em alguns casos, o padrão de calibração não permite modelar todas elas. Por exemplo, no caso do padrão adimensional usado por Svoboda et al. [32], não é possível usar a função objetivo relacionada à extração de medidas, uma vez que só temos um único marcador como referência. Já no caso do padrão unidimensional usado por Borghese [4], por ser constituído por dois marcadores, podemos extrair a distância entre os marcadores e portanto modelar a função objetivo de recuperação de medidas.

Em nosso método, as características do padrão invariante permitem que todas as funções de controle da seção 2.1.3.1 sejam modeladas: re-projeção 3D-2D, extração de medidas reais 3D entre marcadores do padrão e re-projeção 2D-2D. Essas três funções objetivo costumam ser as mais utilizadas para montar a função de erro global no algoritmo de otimização. No entanto, como foi definido pelo método proposto, nós usamos um tipo de padrão de calibração que, além das características necessárias para modelar as funções objetivo comumente usadas, contém mais uma informação adicional entre os marcadores que o compõem: a colinearidade dos marcadores.

Esse tipo de padrão fez uma primeira contribuição na etapa de captura, rastreamento e identificação grupal e individual dos marcadores que o compõem, e nesta etapa de otimização dos parâmetros, o padrão fornecerá mais uma contribuição: a modelagem da medida de colinearidade que seus marcadores devem manter como mais duas funções de controle que poderão ser inseridas para compor a função de erro global. Essa característica de colinearidade pode ser medida tanto no espaço 2D (na imagem) como no 3D (reconstruído no espaço de rastreamento). As duas funções objetivo para medir a colinearidade serão descritas a seguir.

4.1.2.3.2. Colinearidade 2D e 3D

Para medir a colinearidade 3D e 2D dos marcadores de nosso padrão, nós modelamos este cálculo como um problema de aproximação de linha. No caso da colinearidade 3D calculamos a melhor linha 3D que passe pelos marcadores reconstruídos em 3D que compõem nosso padrão e depois medimos a distância desses pontos à linha. No caso da colinearidade 2D, o processo é o mesmo descrito acima, só mudando os dados de entrada, que, nesse caso, são representados pelas coordenadas 2D dos marcadores que aparecem sobre a imagem.

Nossa estimativa é que a função de colinearidade 3D contribua para guiar a otimização dos parâmetros intrínsecos e extrínsecos, pois esses parâmetros são usados para a reconstrução 3D dos marcadores. Já a colinearidade 2D contribuirá para a otimização dos coeficientes de distorção das lentes, porque estes são os

PUC-Rio - Certificação Digital Nº 0510968/CA

responsáveis pela correção da posição das coordenadas 2D dos marcadores na imagem.

Para a implementação da função de colinearidade 3D e 2D, foi utilizado o método denominado "*Ortoghonal distance regression*" [3], que permite achar a melhor solução para o problema de minimização de *n* distâncias ortogonais a uma linha definida por um conjunto de pontos.

Em nosso caso, os quatro marcadores que formam nosso padrão invariante definiram duas aproximações de linhas: uma linha $\boldsymbol{L}_{3D}$, calculada usando os marcadores reconstruídos em 3D ($P_{(X_w \quad Y_w \quad Z_w)}^{i=1\ldots 4}$), e uma segunda linha $\boldsymbol{L}_{2D}$, que pode ser calculadas usando as coordenadas 2D na imagem dos mesmos marcadores ($P_{(u \quad v)}^{i=1\ldots 4}$).

As funções para colinearidade 3D e 2D são definidas como:

$$\varepsilon_{\,Colinearidade\ 3D} = \sum_{i=1\ldots 4}^{n} dist\ \left(L_{3D}, P_{(X_w \quad Y_w \quad Z_w)}^{i}\right) \tag{48}$$

$$\varepsilon_{\,Colinearidade\ 2D} = \sum_{i=1\ldots 4}^{n} dist\ \left(L_{2D}, P_{(u \quad v)}^{i}\right) \tag{49}$$

Concluímos assim nossa função de erro global que será composta pelas seguintes funções de controle:

$$\varepsilon_{Global} = \left(\begin{array}{l} \varepsilon_{\mathrm{Re}\ proj.\ \ 3D-2D} + \varepsilon_{\mathrm{Re}\ proj.\ \ 2D-2D} + \varepsilon_{dist.\ \ 3D} + \\ \varepsilon_{Colinearid\quad ade\ -3D} + \varepsilon_{Colinearid\quad ade\ -2D} \end{array} \right) \tag{50}$$

Na implementação do método proposto neste trabalho, usamos os algoritmos de otimização Levenberg Marquardt [27][6] e Downhill simplex [24][27] para minimizar o erro estabelecido pela equação 50, na qual otimizaremos todos os parâmetros intrínsecos, extrínsecos e coeficientes de distorção das lentes. Para a implementação do algoritmo de otimização de Levenberg Marquardt, foi usada uma biblioteca em C++ chamada CMinpack[6].

4.2. Sumarizando o método

A seguir será mostrado um fluxograma que ilustra todos os processos que compõem o método de múltipla calibração de câmeras proposto neste trabalho. Também será apresentado um fluxograma mais detalhado para cada processo.

PUC-Rio - Certificação Digital Nº 0510968/CA

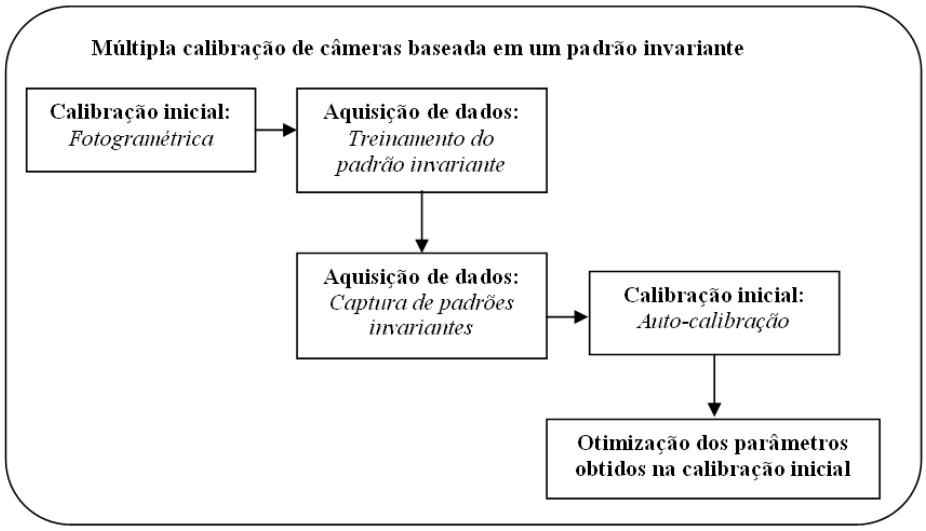

Figura 25: Fluxograma geral do método de múltipla calibração de câmeras proposto nesta tese.

O fluxograma apresentado na Figura 25 descreve, de uma forma global, os processos chave que compõem a base do método de múltipla calibração de câmeras proposto neste trabalho.

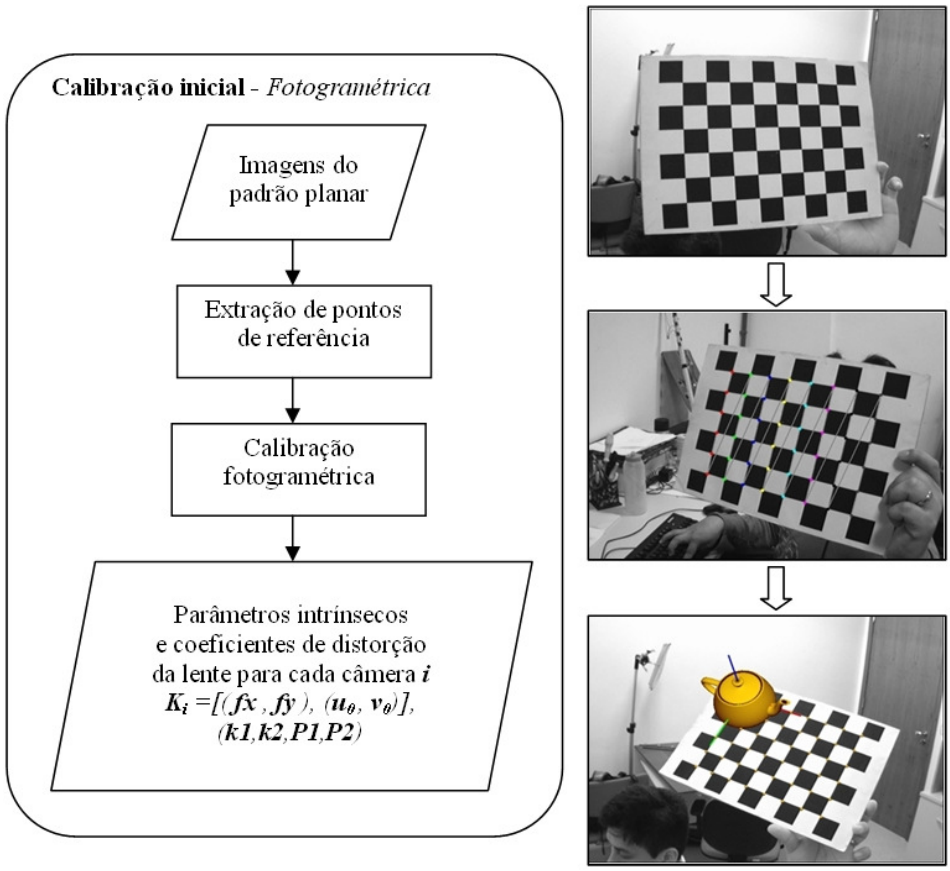

Figura 26: Fluxograma do processo de calibração fotogramétrica.

O primeiro passo na aplicação de nosso método é a calibração inicial, realizada em cada câmera do sistema com o método fotogramétrica (Figura 26).

PUC-Rio - Certificação Digital Nº 0510968/CA

O segundo passo consiste no treinamento dos padrões invariantes que serão usados no processo de múltipla calibração (Figura 27). Ressaltamos a importância de a calibração inicial fotogramétrica permitir calcular uma estimativa dos coeficientes de distorção da lente, para fazer a devida correção no momento da extração das posições 2D dos marcadores.

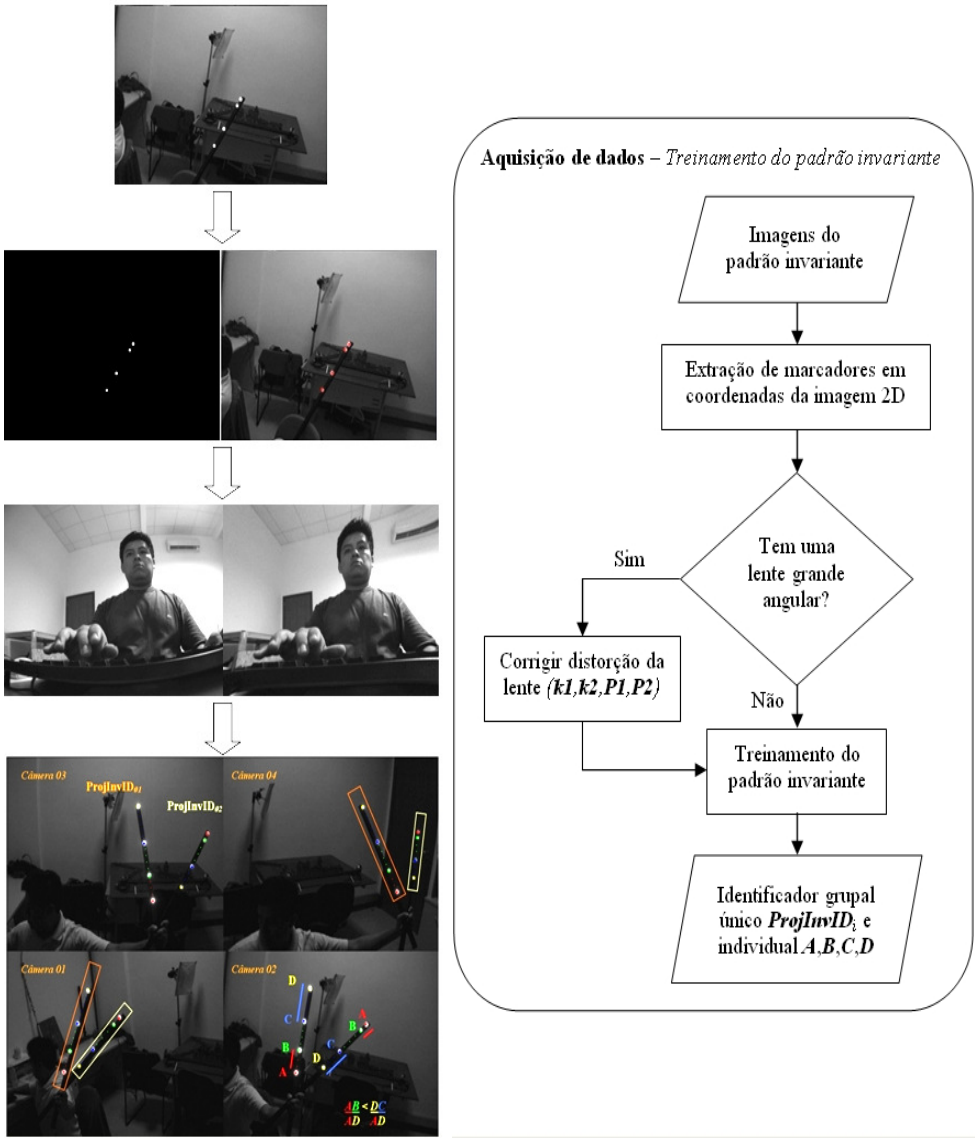

Figura 27: Fluxograma do processo de treinamento dos padrões invariantes.

PUC-Rio - Certificação Digital Nº 0510968/CA

O terceiro passo consiste na captura simultânea por todas as câmeras de vistas dos padrões invariantes previamente treinados (Figura 28). A partir dessas vistas, será gerada uma amostra de pontos correspondentes entre as imagens de cada par de câmeras. Essa amostra será usada na cálculo dos parâmetros extrínsecos para o qual o método de auto - calibração será aplicado.

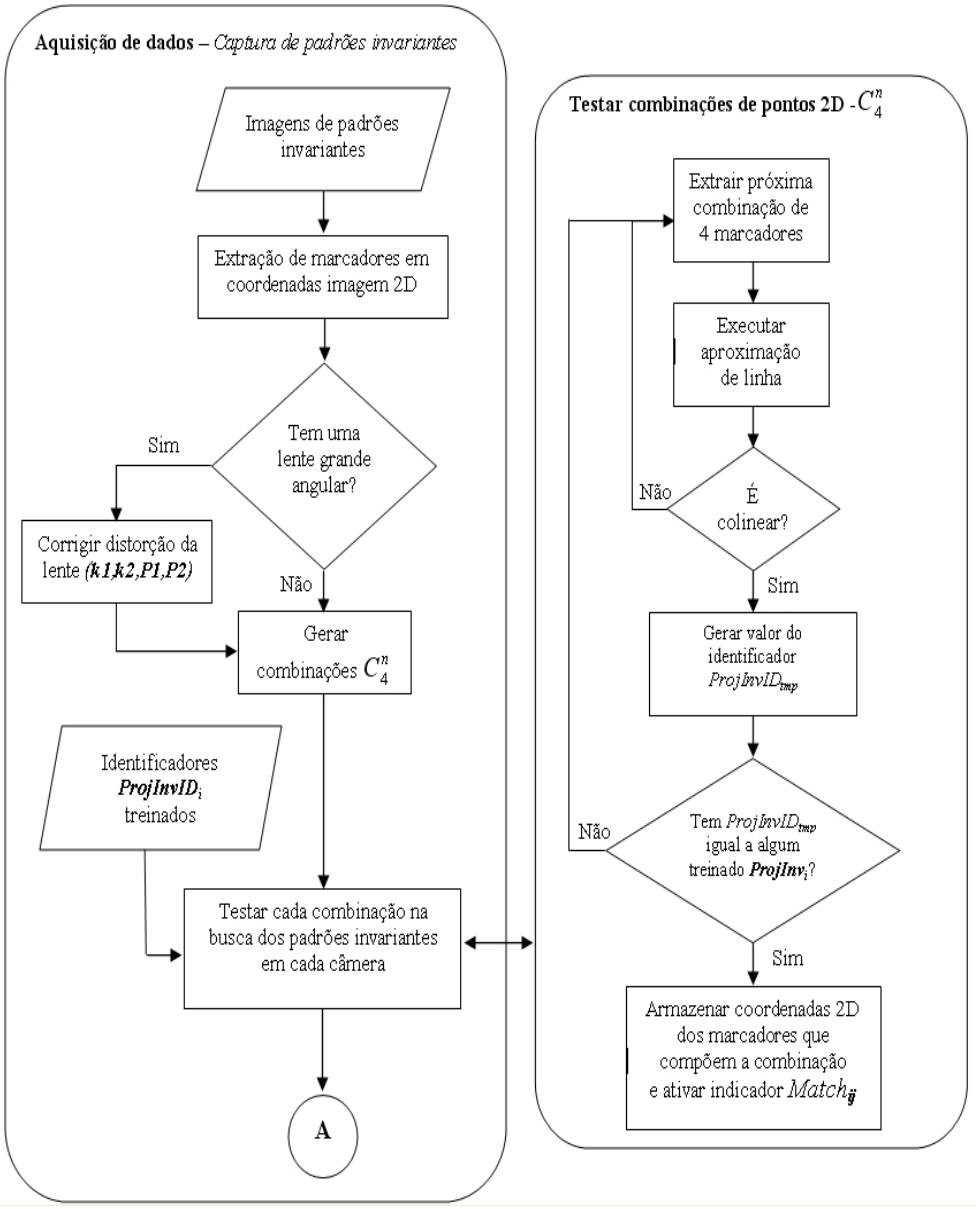

Figura 28: Fluxograma do processo de captura dos padrões invariantes previamente treinados.

PUC-Rio - Certificação Digital Nº 0510968/CA

Como resultado deste terceiro passo, nós teremos um conjunto de buffers $CorrespondencePoints_{i,j}$ para cada par de câmeras *(i,j)* contendo pontos corretamente correspondidos entre elas (Figura 29). Esses pontos são definidos a partir das posições 2D dos marcadores que compõem nossos padrões invariantes e que foram extraídos a partir das vistas capturadas como amostra de calibração.

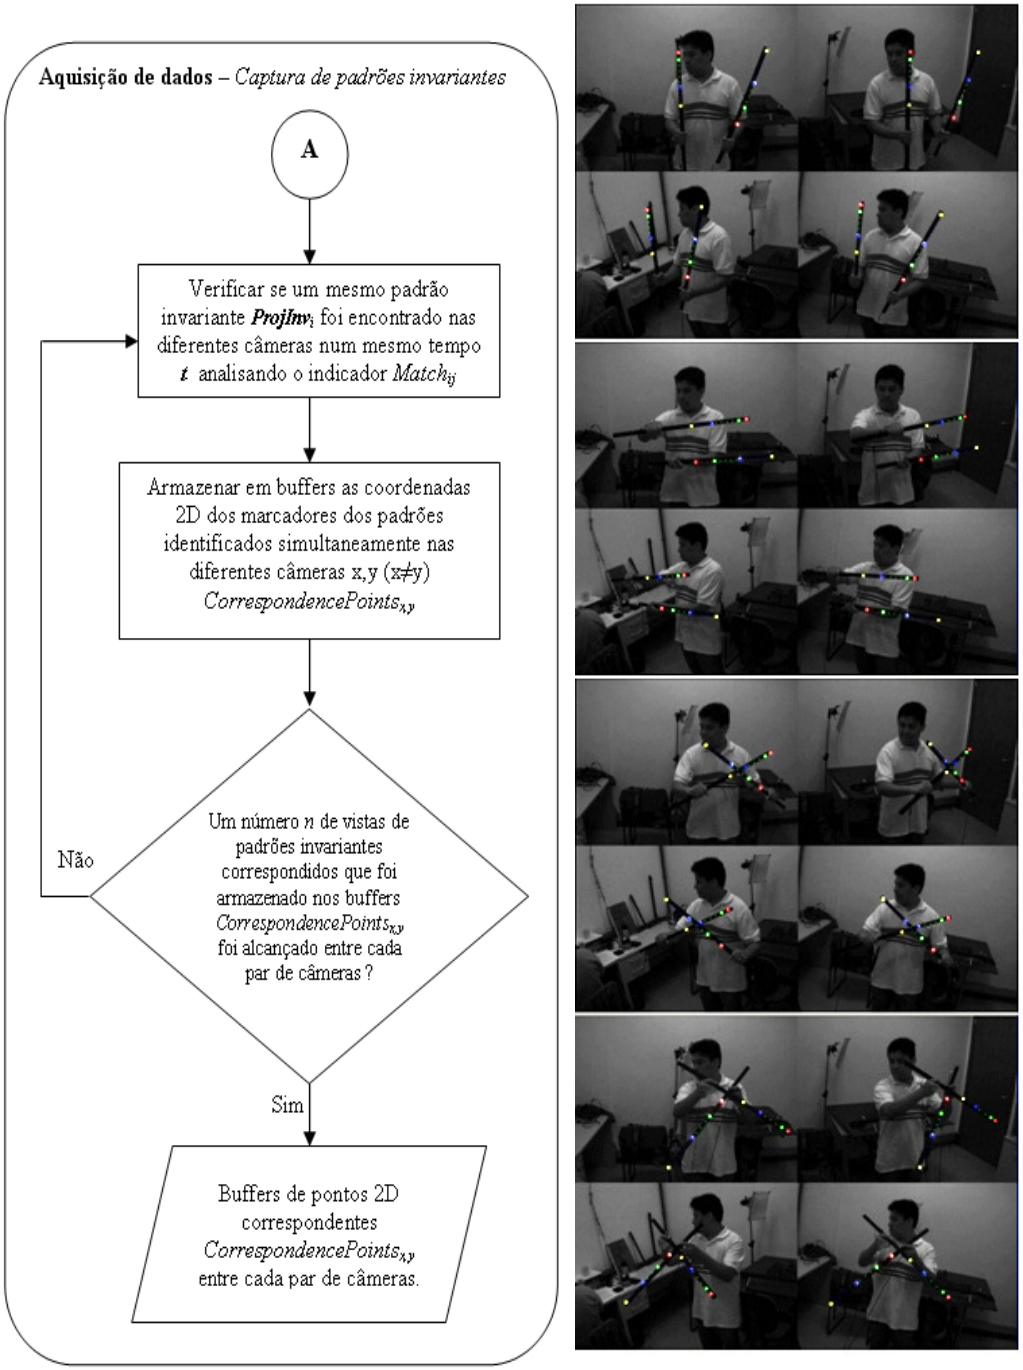

Figura 29: Fluxograma do processo de captura dos padrões invariantes previamente treinados (Continuação).

PUC-Rio - Certificação Digital Nº 0510968/CA

O quarto passo no processo de múltipla calibração consiste na aplicação do método de auto – calibração entre cada par de câmeras que formam nosso sistema (Figura 30). Como resultado recuperaremos os parâmetros extrínsecos que definem o posicionamento relativo entre cada par de câmeras. O último passo consiste na otimização de todos os parâmetros das câmeras previamente estimados pelos dois métodos de calibração inicial: fotogramétrico e auto–calibração, o resultado é a calibração final entre cada par de câmeras (Figura 31).

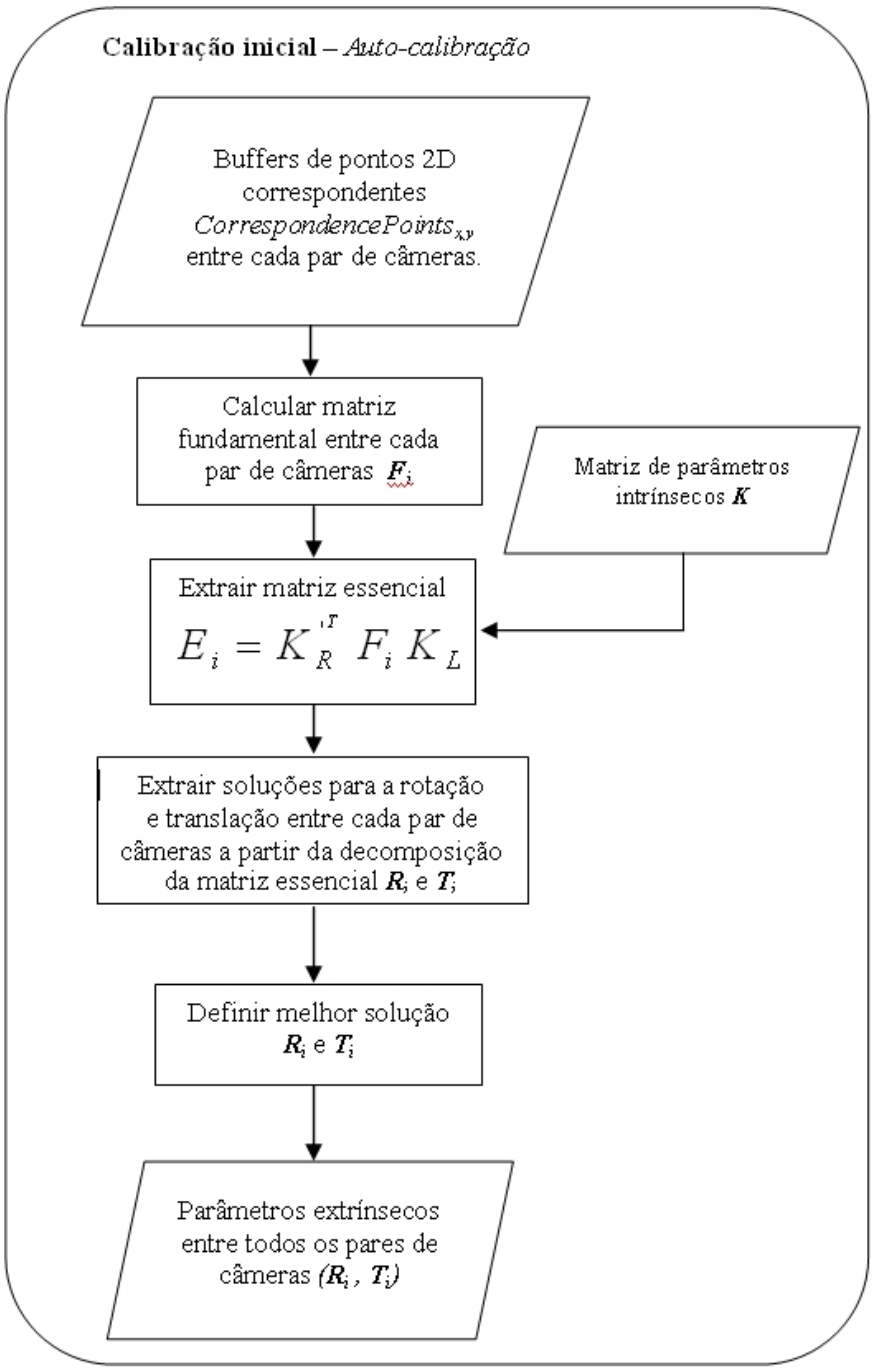

Figura 30: Fluxograma do processo de auto - calibração.

PUC-Rio - Certificação Digital Nº 0510968/CA

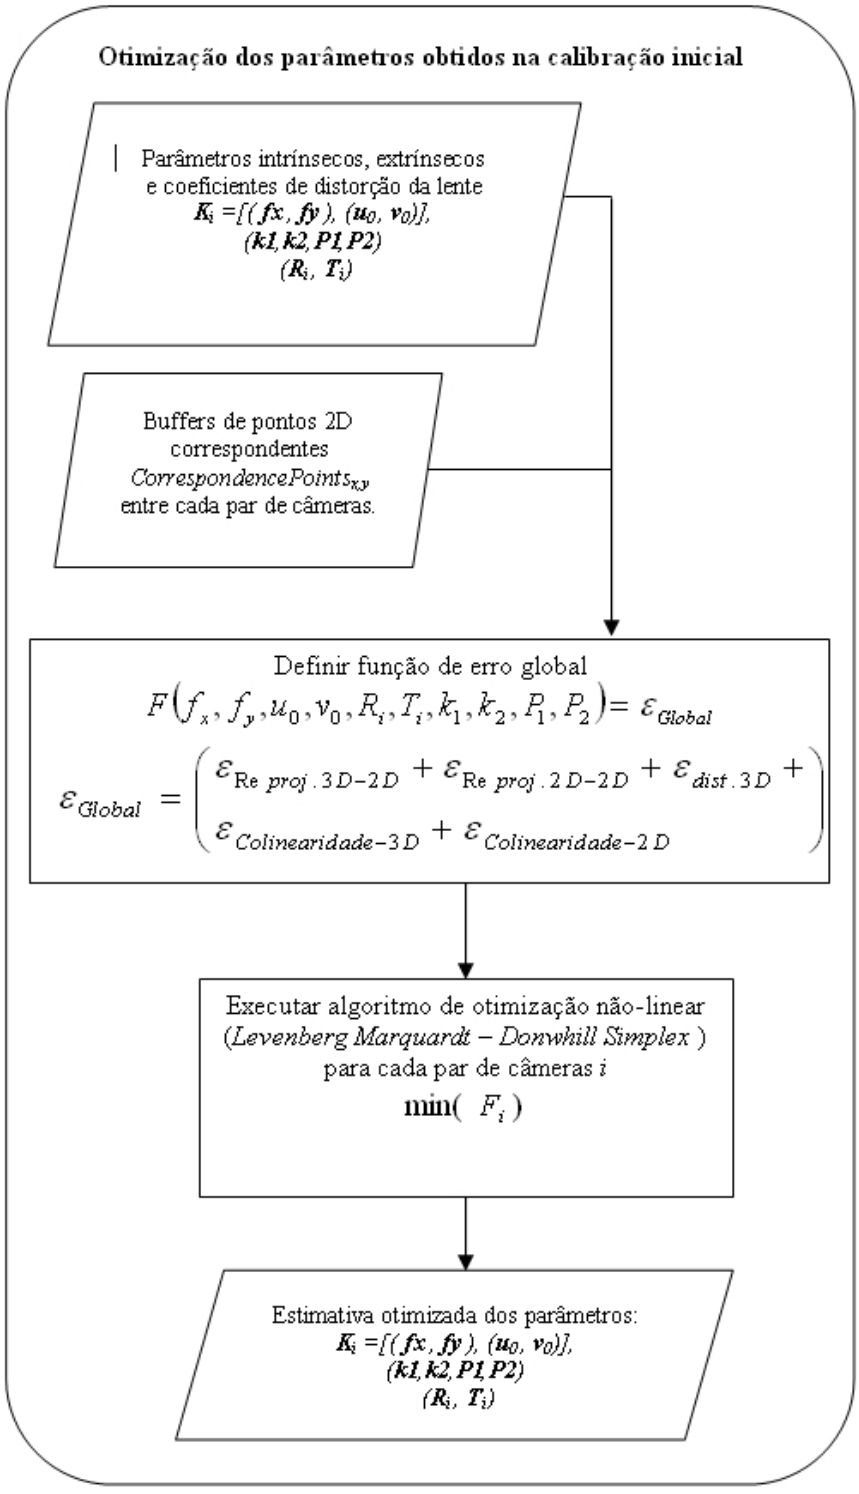

Figura 31: Fluxograma do processo de otimização final dos parâmetros das câmeras estimados na calibração inicial.

Com a exposição dos fluxogramas acima, descrevemos de uma forma resumida todo o processo de múltipla calibração de câmeras definido pelo método proposto neste trabalho. No capítulo seguinte, mostraremos alguns resultados da precisão alcançada na aplicação do nosso método na tarefa de calibração de um sistema de quatro câmeras montado por nós para testes.

PUC-Rio - Certificação Digital Nº 0510968/CA