CAPÍTULO II

2 FUNDAMENTAÇÃO TEÓRICA

Este capítulo tem como objetivo básico apresentar uma revisão bibliográfica do conjunto de técnicas utilizadas no processo de automação da resseção espacial de imagens, bem como os métodos de estimação de parâmetros de orientação exterior da câmara, empregados neste trabalho.

A seção 2.1 apresenta a teoria da correlação relacional, que aborda os conceitos sobre relação, tipos de relação, estrutura de árvore e as medidas de função custo, consagradas na Visão Computacional.

A seção 2.2 apresenta uma seqüência de etapas para extração automática de feições retas (suavização, detecção de bordas, limiarização, afinamento de bordas, vetorização e ajustamento de segmentos retos), onde a partir das retas extraídas é realizado o processo de descrição relacional entre feições retas no espaço-imagem e no espaço-objeto.

A seção 2.3 trata dos modelos fotogramétricos, e enfoca basicamente os modelos de colinearidade e dos planos equivalentes, utilizados para relacionar as feições nos espaços imagem e objeto. A seção 2.4 apresenta o método de estimação recursivo, e a seção 2.5 as técnicas de controle de qualidade e identificação de erros grosseiros, e finalmente a seção 2.6 apresenta o sistema de varredura Laser.

2.1 TEORIA DA CORRELAÇÃO ESTRUTURAL

Para a apresentação da teoria da correlação estrutural é necessário esclarecer que o objeto de interesse deste trabalho são hipóteses de rodovia definidas por um conjunto de quatro feições retas cada uma.

Para DAL POZ (1996, p. 54), uma descrição relacional possui como unidade básica a relação. Seja *E*, *M*, *U*, *V*, *S*, *J* (Fig. 1a), um conjunto *P* hipóteses de rodovia descritas no espaço-imagem, por exemplo. Define-se uma relação **N-ária R** sobre *P* como sendo um subconjunto do produto cartesiano $P^N = Px...xP$ (N vezes).

A Figura 1b mostra uma representação em grafo de um conjunto de pares distintos de nós que se conectam por meio de arcos e que descreve uma relação binária $R^2 \subseteq P_1 x P_1 = \{(E,M); (E,U); (U,V); (S,J); (E,V); (S,M)... (E,J)\}$. Essa relação binária pode ser de paralelismo, perpendicularismo e/ou conexão entre os nós. Ou seja, uma descrição relacional é uma seqüência de relações $DR_p = \{R1,...,Rl\}$, onde para cada i=1,...,*I* existe um inteiro positivo *ni*, tal que $Ri \subseteq P^{ni}$, para algum conjunto **P**. **R**_i indica as várias relações entre os planos.

FIGURA 1 - (A) HIPÓTESES DE RODOVIA NO ESPAÇO-IMAGEM. (B) GRAFO DE NÓS REPRESENTANDO AS HIPÓTESES DE RODOVIA NO ESPAÇO-IMAGEM.



Um grafo é um conjunto não vazio de vértices (nós) e um conjunto de pares ordenados ou não-ordenados de vértices distintos. Os arcos do grafo (Fig. 1b), descrevem as relações binárias entre as hipóteses de rodovia ou nós.

2.1.1 Descrição relacional com atributos

A descrição relacional definida anteriormente descreve relações entre as hipóteses de rodovia, mas não entre as propriedades das feições ou propriedades das relações. Desta forma, é necessário estender estas relações para que seja admitido atributos que relacionam as hipóteses de rodovia.

Seja *P* um conjunto de hipóteses de rodovia no espaço-imagem e *M* um conjunto de propriedades, de forma que *M* é assumido como sendo um conjunto de números reais. Uma relação com atributos é um subconjunto de $P^{Q}xM^{O}$, para *Q* e *O* inteiros não-negativos.

Uma descrição relacional com atributos DR_p é uma seqüência de relações com atributos, $DR_p = \{R1,...,Rl\}$, onde para cada i=1,...,*l* existe um inteiro não-negativo *Qi* e um inteiro não-negativo *Oi* (*Qi* + *Oi* > 0), e um conjunto de propriedades *M*, tal que $Ri \subseteq P^{Qi} x M^{Oi}$.

Estruturas em grafos e árvores são geralmente utilizadas para estabelecer correlações entre as primitivas. Essas estruturas são bastante úteis no problema de redução do espaço de busca.

2.1.2 Estrutura em grafo e árvore

Alguns problemas em Inteligência Artificial, Robótica e Análise de Imagens, Visão Computacional e Fotogrametria, possuem um espaço de busca que pode ser representado em grafos e árvores. O espaço de busca do problema de correlação estrutural, também é representado por uma estrutura em grafos ou árvores.

No domínio da Inteligência Artificial e Visão Computacional foram desenvolvidas várias estruturas para redução do espaço de busca (BARR e FEIGENBAUM, 1981; NILSSON, 1982). A Figura 2 apresenta duas estruturas utilizadas no problema de correlação.



FIGURA 2 – (A) ESTRUTURA SIMPLES DE ÁRVORE. (B) ESTRUTURA EM

Na Figura 2b por exemplo, uma estrela cuja raiz é o nodo E, compreende o próprio nó, todas as componentes das relações dele para outros nós e os nós que possuem relação com o nó raiz, também denominada nó vizinho. Portanto, uma relação como a definida anteriormente pode ser decomposta em n estrelas, onde n é o número de primitivas na relação (DAL POZ, 1996, p. 57).

Por exemplo, o símbolo E é nó raiz da estrutura que faz relação com seus nós vizinhos (U, V, S, J, M, Fig. 2b). Posteriormente, cada nó vizinho tornar-se-á um nó raiz, compondo as relações entre eles e seus sucessores. Todos os métodos de estrutura em árvore iniciam seu processo na raiz ("nó raiz"), e se estende ao longo de suas folhas ("nós folha", U, S, V, J, M - Fig. 2), até que seja encontrada uma solução (PEARL, 1984).

Como descrito anteriormente, os arcos que conectam os nós representam as relações que podem ser direcionais ou não, dependendo das propriedades das relações (PARK et al., 2000).

As estruturas em grafos e árvores são utilizadas na redução do espaço de busca para a solução do problema de correlação estrutural e baseada em área. O método de interesse neste trabalho é o problema de correlação estrutural.

A correlação estrutural compara a descrição relacional entre as primitivas. Uma descrição relacional, descreve atributos determinados nas relações entre as primitivas contidas no espaço-imagem e espaço-objeto, sendo o último transformado para um espaço compatível com o espaço-imagem, que será denominado de espaço-referência.

No contexto deste trabalho será utilizado como entidade ou primitiva básica para o processo de estabelecimento de relações binárias, hipóteses de rodovia definidas por um conjunto de 4 feições retas. As relações binárias entre as hipóteses de rodovia podem ser estabelecidas através de atributos que descrevem as relações existentes entre os mesmos. Neste contexto será dado um tratamento matemático às relações binárias adotadas que são do tipo:

$$R_p = \{R1, \dots, Rn\} \tag{1}$$

onde, *R1,...,Rn* são as componentes de uma relação específica. Em particular, uma determinada componente *Ri* de *R* tem a forma:

$$R_{i} = \left\{ \pi E1, \pi E2, ap^{1}, ap^{2} \right\}$$
(2)

Sendo, $\pi E1$ e $\pi E2$ as hipóteses de rodovia pertencentes ao conjunto das primitivas ou entidades $P = ap^1$, ap^2 os atributos da relação, como por exemplo, ângulo entre as duas hipóteses e a bissetriz do ângulo. Esses atributos possuem a função de caracterizar a componente Ri de R. Sendo **M** o conjunto dos atributos, a relação **R** é um subconjunto de P^2xM^2 , ou seja, $R \subseteq P^2xM^2$. A partir do desenvolvimento descrito acima será desenvolvida a métrica utilizada para o problema de correlação (ver capítulo 3).

Considerando o caso em que a correlação é realizada entre hipóteses de rodovia contidas no espaço-imagem e no espaço-referência, e adotando-se os índices *I* para o espaço-imagem e *r* para o espaço-referência, pode-se reescrever as Equações (1) e (2) para o espaço-imagem e para o espaço-referência como segue:

$$R_{I} = \{R_{1}^{I}, ..., R_{n1}^{I}\}$$

$$R_{i}^{I} = \{\pi E_{1}^{I}, \pi E_{2}^{I}, a p_{1}^{I}, a p_{2}^{I}\}$$
(3)

$$R_{r} = \left\{ R_{1}^{r}, ..., R_{n2}^{r} \right\}$$

$$R_{i}^{r} = \left\{ \pi E_{1}^{r}, \pi E_{2}^{r}, a p_{1}^{r}, a p_{2}^{r} \right\}$$
(4)

Desta forma, a descrição relacional **DR**_{*I*} para o espaço-imagem e **DR**_{*r*} para o espaço-referência pode ser escrita como segue:

$$DR_{I} = \{R_{I}^{1}, ..., R_{I}^{n}\}$$

$$DR_{r} = \{R_{r}^{1}, ..., R_{r}^{n}\}, n = 1, ..., N\pi$$
(5)

onde, $N\pi$ número de hipóteses de rodovia que se relacionaram em ambos os espaços.

2.1.3 Definições de Correlação estrutural

Para entender o conceito de correlação estrutural é necessário definir os conceitos de mapeamento e de composição.

Segundo DAL POZ (1996, p. 67), define-se um mapeamento *h* como sendo uma função que mapeia elementos do conjunto **P** em elementos do conjunto **P'**, sendo **P'** o conjunto de hipóteses de rodovia extraídas no espaço-referência, sendo usualmente denotado por *h*:**P** \rightarrow **P'**.

Seja agora $R \subseteq P^N$ uma relação N-ária sobre o conjunto das partes **P** e seja $S \subseteq P^N$ uma segunda relação N-ária sobre o conjunto das partes **P'**. Define-se uma composição $R \circ h$, de R com h, como segue:

$$R \circ h = \{ (p_1, ..., p_n) \in S \mid \exists (p_1, ..., p_n) \in R \}, \text{ com } h(p_i) = p_i, \text{ i=1,...,N}$$
(6)

Ou seja, a função *h* deve preservar em *S* todas as inter-relações originais existentes em *R*, descrevendo um homomorfismo relacional de $R \subseteq P^N$ para $S \subseteq P^N$. No caso em que *h* seja um-a-um tem-se um monomorfismo relacional de $R \subseteq P^N$ para $S \subseteq P^N$, indicando uma correlação mais restritiva que o homomorfismo relacional.

De acordo com SHAPIRO e HARALICK (1987), o tipo mais forte de correlação estrutural é o isomorfismo, no qual a função *h* satisfaz a condição $S = R \circ h$.

Neste contexto, pode-se classificar a correlação estrutural de forma que, sejam dois grafos G(v, e) e G'(v', e'), os quais correspondem às descrições relacionais entre P e P'. Os nós v e v' correspondem às primitivas básicas (hipóteses de rodovia) utilizadas no processo e os arcos e e e' são as inter-relações entre v e v'. Para DAL POZ (1996, p. 70) *apud* BALLARD e BROWN (1982), encontrar o isomorfismo relacional consiste em encontrar um mapeamento h, um-a-um, tal que para cada $v_1 \in v$, temos apenas um $v_2 \in v'$, tal que $h(v_1) = v_2$ e para cada arco de e, definidos pelo nó raiz v_1 e seu vizinho v_1' ambos $\in v$, existe um arco de e', definida pelos nós raiz v_2 e seu vizinho v_2' ambos $\in v'$.

Para comparar as descrições relacionais entre os dois grafos, deve-se utilizar alguma função. A função custo é a função utilizada em aplicações clássicas de estrutura em grafo, onde os ganhos obtidos entre as relações devem ser maximizados. O ganho representa a quantidade de veracidade na relação entre os grafos, por exemplo, se existe correlação entre os nós raízes dos grafos o ganho varia dentro de um intervalo entre 80 à 100%.

2.1.4 Medidas de função custo

Podem ser citadas duas funções custo consagradas na Visão Computacional, utilizadas como medida de similaridade no problema de correlação estrutural, ou seja, a medida de distância introduzida por SANFELIU e FU (1983) e a medida desenvolvida por SHAPIRO e HARALICK (1985).

A medida proposta por SHAPIRO e HARALICK (1985), define o erro estrutural $E_e(h)$ de uma função de mapeamento *h* entre **P** e **P'** em relação ao iésimo par de relações homólogas R_i e S_i, pertencentes a **D***R*_P e **D***R*_{p'}, como segue:

$$E_{e}(h) = |R \circ h - S| + |S \circ h^{-1} - R|$$
(7)

De acordo com VOSSELMAN (1992, p. 67), o primeiro termo do membro da direita da Equação (7) indica quantas ênuplas em R não foram mapeadas por *h* para ênuplas em S. Já o segundo termo da Equação (7) indica quantas ênuplas em S não foram mapeadas por h^{-1} para ênuplas em R. Se $E_e(h)=0$, as relações R e S são isomorfas. O erro total da função de mapeamento *h* em relação a DR_P e $DR_{p'}$ é dado por:

$$E(h) = \sum_{n=1}^{k} E_{e}(h)$$
(8)

Onde,

- *E* : erro total da função de mapeamento;
- E_e^k : erro estrutural da função de mapeamento; e
- k: número de pares.

Desta forma, a distância relacional ou a medida de similaridade entre DR_P e $DR_{p'}$ é dada por:

$$D(DR_{P}, DR_{n'}) = \min E(h)$$
(9)

A Equação (10) fornece a melhor correlação entre $DR_P \in DR_{p'}$.

2.2 PRIMITIVAS UTILIZADAS PARA O PROCESSO DE CORRELAÇÃO ESTRUTURAL

Várias técnicas foram propostas para solucionar o problema de correlação estrutural, dentre elas são destacadas, as técnicas de correlações baseadas em grafos e árvores (BALLARD e BROWN, 1982; SHAPIRO e HARALICK, 1985; DAL POZ et al., 1996; WILSON et al., 1998; DAL POZ e TOMMASELLI, 1999; JURIE, 1999; PEARCE e CAELLI, 1999), as técnicas de rotulação por relaxação (HUMMEL e ZUCKER, 1983; LI, 1992; EVANS, 1999; WERSING e HITTER, 1999; BUDDHIRAJU, 2001; GAUTAMA e BORGHGRAEF, 2003) e as técnicas de análise

de autovetores (SHAPIRO e BRADY, 1992; PILU, 1997; entre outros). Estas técnicas diferem tanto pelo método como pelos algoritmos utilizados.

VOSSELMAN (1992), desenvolveu uma função custo eficiente baseada na teoria da informação que, combinada com um padrão de estrutura em árvore avalia o método de correlação estrutural. A função permite a combinação de atributos numéricos e simbólicos dentro de uma mesma medida, determinando as similaridades através da transição de probabilidade e não pela diferença dos valores dos atributos.

DAL POZ (1996), utilizou estrutura de estrela para o estabelecimento de correlações. As relações entre as feições retas extraídas nos espaços objeto e imagem são realizadas feição-a-feição. A função custo utilizada na metodologia de correlação foi apresentada por SHAPIRO e HARALICK (1985).

WILSON et al. (1998), desenvolveram uma metodologia para a solução do problema de correlação estrutural, na qual adota uma representação de triangulações ativas baseadas no método de triangulação de *Delaunay*. Esta metodologia é iterativamente reconfigurada para aumentar o grau de congruência topológica com o modelo relacional no processo de correlação.

Já, GOLDOF et al. (1992), SCLAROFF e PENTLAND (1995), PARK et al. (2000), PARK et al. (2003), propuseram um método baseado na análise de autovetores como medida de similaridade (função custo), com uso de estrutura em árvore no processo de correlação estrutural. O método transforma as feições retas dentro de um hiper-espaço de eixos de simetria generalizada, de forma que as feições possam ser verdadeiramente analisadas. A aplicação direta do método pode causar sérios problemas no processo de correlação, como por exemplo, o estabelecimento de falsas correlações. Por isso, o método é exeqüível apenas quando a quantidade de feições retas no espaço-objeto é a mesma do espaço-imagem.

SHEN e PALMER (2000), apresentaram um algoritmo para correlação estrutural da seguinte forma: uma propagação de covarâncias na etapa de extração de feições é aplicada para determinar as precisões na etapa de correlação. As correlações são realizadas com base no processo de extração de feições combinada com a informação dos atributos para determinar a similaridade entre os mesmos.

GALO (2003), desenvolveu um método que inclui a injunção epipolar na solução do problema de correlação. Neste método a condição de coplanaridade entre os CP's e os candidatos à correlação é injuncionada e a orientação relativa e a correlação são determinados simultaneamente.

PUTJARUPONG et al. (2003), exploraram uma técnica de correlação que utiliza cinco pontos coplanares para registro de imagens. A técnica introduzida é um método não iterativo baseado em atributos geométricos e propriedades invariantes. O registro da imagem é realizado por meio de um processo de correlação entre os objetos.

Uma das complexidades no problema de correlação estrutural, em relação às feições pontuais é que, a descrição é estabelecida a partir de formas geométricas mais complexas e de acordo com GALO (2003, p. 19), a projeção de uma feição reta, por exemplo, pode degenerar a feição em um ponto, devido principalmente às diferenças de altitude dos pontos que definem uma reta no espaço. Entretanto, o problema é bastante atrativo e exige maior cuidado na estruturação de agrupamentos de feições retas para o estabelecimento de suas correlações.

Neste trabalho, as hipóteses de rodovia serão as primitivas básicas utilizadas para o processo de correlação estrutural e por isso é necessário apresentar um fluxo de extração de feições retas para reconstruir a primitiva de interesse.

2.2.1 Fluxo de extração de feições retas

PARKER (1996), apresentou segmentadores de bordas que agrupam as etapas de extração de feições, como por exemplo, o operador Canny que considera as etapas de suavização, detecção e afinamento de bordas, como uma única etapa de detecção de bordas. CANNY (1986), desenvolveu um fluxo de segmentação de bordas, a partir de critérios de detecção e localização, utilizando um filtro ótimo no processo de resposta do valor de magnitude para cada pixel de borda detectada.

FORSTNER (1994), LAGUNOVSKY e ABLAMEYKO (1996), ARTERO (1999), HABIB et al. (2000), ARTERO e TOMMASELLI (2002), sugeriram um fluxo de extração de feições retas bastante semelhante, onde o diferencial é determinado

42

por pequenas modificações desenvolvidas pelos autores citados, como por exemplo, a extensão de máscaras para a determinação de direção e magnitude de bordas, entre outras.

O método de programação dinâmica baseada em contornos ativos, também é um tipo de algoritmo para extração de feições lineares. O algoritmo é muito utilizado em problemas de extração de rodovias em imagens digitais (MERLET e ZERUBIA (1996); GRUEN e LI, 1997; WIEDERMANN e HINZ, 1999; BAUMGARTNER et al., 1999; DAL POZ e AGOURIS, 2000; HINZ e BAUMGARTNER, 2001; DAL POZ e SILVA, 2002b; VALE e DAL POZ 2003, entre outros). O algoritmo de programação dinâmica, geralmente utiliza *splines* (definidas como linhas de traçado curvo) para definir o contorno dos objetos.

Neste trabalho optou-se pelo uso do algoritmo de extração de feições retas baseado nos processos descritos por PAINE e LODWICK (1989). Os processos tradicionais de extração de feições retas seguem uma seqüência composta por cinco etapas: suavização; detecção de bordas; limiarização; afinamento de bordas; e conexão.

2.2.1.1 Suavização

No processo de extração de feições retas a suavização de bordas é uma etapa considerada opcional. No entanto, esta etapa tem por finalidade atenuar ruídos e excesso de detalhes presentes em imagens digitais.

Dependendo da natureza do filtro de suavização, este pode produzir o efeito de borramento das bordas na imagem. Em algumas situações o filtro é considerado como filtragem, pois além de suavizar os efeitos de ruídos, preserva ao máximo as informações de bordas. Os principais filtros utilizados na etapa de suavização, são os que seguem:

- ✓ Média;
- ✓ Mediana; e
- ✓ Suavização com preservação de bordas e cantos.

As informações mais importantes para o processo de extração de feições retas são as bordas dos objetos. Com o ensejo de preservar ao máximo as

informações de borda, o filtro da mediana foi implementado, uma vez que possui a característica de atenuar os ruídos presentes na imagem e preservar as informações de borda. Neste tipo de filtro, o pixel central da máscara de suavização é substituído pela mediana dos seus pixels vizinhos.

2.2.1.2 Segmentação

2.2.1.2.1 Detecção de bordas

A borda é uma descontinuidade abrupta dos valores de brilho em uma imagem em tons de cinza, que define o contorno das feições presentes na imagem. A borda de uma feição possui dois atributos, ou seja, sua magnitude e direção, no qual os mesmos podem ser descritos pelo gradiente do pixel nas direções x e y (Gx, Gy). A magnitude e direção da borda do pixel podem ser determinadas por meio das Equações (10) e (11), representadas na Figura 3 (SONKA et al., 1998).

FIGURA 3 – DETERMINAÇÃO DA MAGNITUDE E DIREÇÃO DOS GRADIENTES.



$$\vec{R} = magnitude_{GxGy} = \sqrt{Gx^2 + Gy^2}$$
(10)

$$\alpha = \arctan\left(\frac{Gy}{Gx}\right) \tag{11}$$

Os principais operadores de bordas são obtidos a partir de aproximações de derivadas parciais, tais como, o operador de Roberts, Prewitt, Sobel e

Nevatia&Babu. Neste trabalho será utilizado o operador de Nevatia&Babu, que aplica 12 máscaras com inclinações variando de 30⁰ em 30⁰ (Fig. 4).

FIGURA 4 – MÁSCARAS UTILIZADAS PELO OPERADOR NEVATIA E BABU (FONTE: PRATT, 1991)



Observa-se que as máscaras utilizadas na detecção com direção α e (α + π) são similares. A única diferença definida é a troca dos sinais.

2.2.1.3 Limiarização

A limiarização consiste em separar pixels de borda com pequena magnitude, dos pixels de borda de grande magnitude. Existe uma grande variedade de técnicas para a obtenção de um valor limiar, tais como, método P-Tile, Pun, Otsu, triângulo entre outros. Cada um deles utiliza algum critério que considera importante para obter o valor de melhor limiar (SAHOO, 1998). Uma técnica bastante utilizada baseada na análise discriminante e utilizada no fluxo implementado neste trabalho, é o método de Otsu. O valor do limiar é obtido supondo que os pixels da imagem podem ser classificados em duas classes (C₀ e C₁) que são o objeto e o fundo, respectivamente.

2.2.1.4 Afinamento de bordas

O afinamento consiste na eliminação de pixels de borda redundantes que formam uma borda espessa. A eliminação dos pixels de borda de menor importância é dada por meio de uma análise em função da direção da borda que está sendo pesquisada. O método utilizado neste trabalho é o método de supressão não-máxima. Com a separação dos pixels de fundo do objeto de interesse é aplicado a etapa de afinamento de bordas. O método de supressão não-máxima foi implementado para compor o fluxo de extração.

Este método utiliza uma quantização de ângulos dos pixels de borda em 8 ou 12 direções. Entretanto, na detecção de bordas pode ser obtido um conjunto discreto de ângulos, mas com outras quantidades de variações angulares. Por isso, antes da execução do operador de supressão não-máxima é necessário quantizar estes ângulos em direções pré-definidas pelo operador de supressão.

Por este método, a eliminação dos pixels é feita perpendicularmente à direção da borda. A discretização dos ângulos e o afinamento podem ser realizados através da comparação entre os pixels, mantendo apenas aqueles com maior magnitude.

2.2.1.5 Vetorização

A conexão é necessária para agrupar pixels de borda pertencentes à mesma borda e formar segmentos de retas. Para isto, é necessário que se disponha dos atributos dos pixels de borda. Existem vários métodos que realizam o agrupamento dos pixels, tais como, a Transformada de *Hough*, *Scan&Label*, dentre outros.

BALLARD e BROWN (1982), apresentaram o processo de rotulação por um método de inundação, onde todos os pixels vizinhos e de características semelhantes, ao pixel semente, recebem o mesmo rótulo.

O método *Scan&Label*, apresentado por ZHOU et al. (1989), VENKATESWAR e CHELLAPA (1992) e ARTERO (1999), varre a imagem da esquerda para a direita, de cima para baixo e para cada pixel (de acordo com sua direção), são verificados seus vizinhos. Os pixels de borda são analisados pelo algoritmo e são atribuídos a eles rótulos, de acordo com sua condição de análise. Ao primeiro pixel analisado é atribuído o rótulo de valor igual à 1, denominado de pixel rótulo. O pixel atual é aquele que está em processo de pesquisa, para que seja atribuído um rótulo. Caso seja encontrado algum vizinho, já rotulado do pixel atual, o último recebe o mesmo rótulo do primeiro. Ao final do processo obtém-se um conjunto de segmentos rotulados e atribuídos à eles suas respectivas magnitudes e direções.

2.2.1.6 Ajustamento de segmentos retos

O ajustamento de segmentos retos determina a equação da reta que melhor se ajusta aos pixels de borda pertencentes ao segmento de reta formado.

ARTERO (1999), apresenta um caso particular do ajustamento pelo Método dos Mínimos Quadrados, conhecido como regressão linear. Este método é utilizado em casos que os pixels pertencentes aos segmentos, são sempre ajustados por linhas retas. De acordo com ARTERO (1999, p. 46), esta particularização permite a construção de um modelo mais simples de ser visualizado e ainda dispensa o uso de matrizes e vetores. Este modelo adota o conjunto de pixels definido por $S_{ij} = \{(x_1, y_1), ..., (x_n, y_n)\}$ e a função g, escolhida como a função que mais se aproxima da função desconhecida que gerou a seqüência S_{ij} . A solução é dada por:

$$a = \frac{\sum_{i=1}^{n} x_{i} y_{i} - \frac{\sum_{i=1}^{n} x_{i} y_{i}}{N}}{\sum_{i=1}^{n} x_{i}^{2} - \frac{\left(\sum_{i=1}^{n} x_{i}\right)^{2}}{N}}$$
(12)

$$b = \frac{\sum_{i=1}^{n} y_i}{N} - a \frac{\sum_{i=1}^{n} x_i}{N}$$
(13)

Onde N é o número de pixels do segmento de reta, *a* é o parâmetro angular da reta, *b* é o parâmetro linear da reta, x_i e y_i coordenadas do pixel, no sistema do

centro da imagem, que definem os pontos extremos de cada feição reta extraída. As variâncias dos parâmetros determinados pelas equações (12) e (13), podem ser obtidos por meio das seguintes equações (TOMMASELLI, 1993):

$$\sigma_a^2 = \frac{2(a^2 + 1)}{(x_2 - x_1)^2} \sigma_{xy}^2$$

$$\sigma_b^2 = \frac{x_2 + x_1}{(x_2 - x_1)} (a^2 + 1) \sigma_{xy}^2$$
(14)

Onde σ_a^2, σ_b^2 variância dos coeficientes angular e linear da reta, σ_{xy}^2 variância das coordenadas dos pixels.

Entretanto, a escolha do algoritmo de extração de feições retas não causa grande impacto nos resultados obtidos, mas fornece informações sobre a qualidade das bordas extraídas. A eficiência destes algoritmos depende principalmente das condições de aquisição da imagem a ser segmentada e da resolução geométrica da mesma, além da sofisticação dos algoritmos envolvidos no processo.

A partir da extração das feições retas pode-se construir figuras planas com o uso de 4 feições retas que definem um plano. A partir do pressuposto, a busca em árvore ou grafo inicia-se no nó raiz, que é expandido por meio da geração de seus nós sucessores ou folhas. Um determinado nó é aceito se o critério de isomorfismo relacional for aceito. A partir deste nó uma nova expansão é realizada, obtendo-se novamente os nós sucessores, de forma que o procedimento é repetido até que seja encontrada a solução.

Com as correlações homólogas estabelecidas é necessário utilizar um modelo matemático que relacione funcionalmente as feições utilizadas no processo de correlação, com a finalidade de estimar os parâmetros de orientação exterior da câmara.

2.3 MODELOS MATEMÁTICOS FOTOGRAMÉTRICOS

Os modelos matemáticos utilizados na Fotogrametria são considerados modelos projetivos que melhor se aproximam da realidade dos fenômenos físicos

que interagem o espaço-imagem e o espaço-objeto, seja por meio de feições pontuais, feições retas e/ou feições *free-forms*. Dentre os modelos utilizados, o mais consagrado é o modelo de colinearidade na sua forma direta e inversa. Com o transcorrer do tempo outros modelos matemáticos foram desenvolvidos pela comunidade fotogramétrica.

2.3.1 Modelo de colinearidade

Este modelo estabelece uma condição de colinearidade entre os pontos no espaço-imagem, seus pontos correspondentes no espaço-objeto e o Centro Perspectivo da câmara (LUGNANI, 1987). A Figura 5 apresenta a condição de colinearidade.



FIGURA 5 - CONDIÇÃO DE COLINEARIDADE.

Onde,

- *CP*: Centro Perspectivo da câmara, que é uma abstração pontual do sistema de lentes;
- CPxyz: é o sistema tridimensional de coordenadas fotogramétricas positivo;
- *pp*: ponto principal, pertencente ao plano fotográfico e é definido pela projeção ortogonal do CP sobre o plano fotográfico, que neste caso é o positivo fotográfico;
- ppx'y': sistema plano de coordenadas fotográfico positivo (sistema fiducial), obtido a partir do sistema CPxyz, fazendo-se a consideração de que a origem é o pp e que os eixos x' e y' são paralelos e de mesmo sentido, respectivamente, aos eixos x e y;
- f: distância focal;
- ωφκ: ângulos de rotação, respectivamente, em torno dos eixos x, y, z e referidos ao sistema OXYZ;
- OXYZ: sistema tridimensional de coordenadas do terreno;
- *P*: ponto da superfície física da Terra, cujas coordenadas no sistema OXYZ são X_p, Y_p, Z_p; e
- p: imagem de P no positivo fotográfico, cujas coordenadas no sistema ppx'y' são x' e y'.

As equações de colinearidade são deduzidas com base no princípio de colinearidade e são dadas como segue:

$$x = -f \frac{r_{11}(X_p - X_0) + r_{12}(Y_p - Y_0) + r_{13}(Z_p - Z_0)}{r_{31}(X_p - X_0) + r_{32}(Y_p - Y_0) + r_{33}(Z_p - Z_0)}$$

$$y = -f \frac{r_{21}(X_p - X_0) + r_{22}(Y_p - Y_0) + r_{23}(Z_p - Z_0)}{r_{31}(X_p - X_0) + r_{32}(Y_p - Y_0) + r_{33}(Z_p - Z_0)}$$
(15)

$$r = \begin{bmatrix} \cos\varphi\cos\kappa & \cos\omega \sin\kappa + \sin\omega\sin\varphi\cos\kappa & \sin\omega\sin\kappa - \cos\omega\sin\varphi\cos\kappa \\ -\cos\varphi\sin\kappa & \cos\omega\cos\kappa - \sin\omega\sin\varphi\sin\kappa & \sin\omega\cos\kappa + \cos\omega\sin\varphi\sin\kappa \\ \sin\varphi & -\sin\omega\cos\varphi & \cos\omega\cos\varphi \end{bmatrix}$$

Onde,

r_{ij} : elementos da matriz (r) de rotação em função dos ângulos de rotação da câmara.

Deve-se admitir que neste caso a Equação 15 está isenta de erros sistemáticos. Na seção 2.3.2 será apresentado o modelo matemático que relaciona funcionalmente feições retas no espaço-imagem e espaço-objeto.

2.3.2 Modelo dos planos equivalentes

LUGNANI (1981), TOMMASELLI e LUGNANI (1988), KLINEC (2004) e HABIB (1998), desenvolveram modelos matemáticos que relacionam feições retas no espaço-imagem e no espaço-objeto.

TOMMASELLI (1993), desenvolveu um modelo matemático que, relaciona funcionalmente uma reta no espaço-objeto com sua homóloga no espaço-imagem, denominado modelo dos planos equivalentes. A Figura 6 apresenta o esquema visual das feições retas que se relacionam em ambos os espaços.



FIGURA 6 – GEOMETRIA DOS PLANOS EQUIVALENTES.

Onde,

- S : feição reta no espaço-objeto;
- s : feição reta no espaço-imagem homóloga de S;
- $\vec{P} = \begin{bmatrix} X_1 \\ Y_1 \\ Z_1 \end{bmatrix}$: coordenadas tridimensionais de um ponto P qualquer da

reta S;

- \vec{V} : cosseno diretor da reta S;
- \vec{N}_0 : vetor normal ao plano de interpretação no espaço-objeto;
- \vec{N}_i : vetor normal ao plano de interpretação no espaço-imagem.

A equação da reta pode ser escrita na sua forma paramétrica e na sua forma normal. Na forma paramétrica os parâmetros *a* e *b* representam os coeficientes angular e linear da reta, dados por:

$$y = ax + b \tag{16}$$

Onde $a = tg \alpha$.

se:

A equação da reta na forma normal é dada por:

$$\cos\theta x + \sin\theta y - \rho = 0 \tag{17}$$

Rearranjando a Equação (17) e comparando-a com a Equação (16), obtêm-

$$a = -\cot g\theta = tg\alpha$$

$$b = \frac{\rho}{sen\theta}$$
(18)

A Equação (16) não é definida quando **s** for aproximadamente vertical ($\theta \cong 0$). Este problema pode ser resolvido arranjando uma nova parametrização para a equação da reta, dada por:

$$x = a^* y + b^* \tag{19}$$

Desta forma, os coeficientes a^{*} e b^{*} podem ser derivados:

$$a^* = -tg\theta$$

$$b^* = \frac{\rho}{\cos\theta}$$
(20)

As feições retas **S** no espaço-objeto e **s** no espaço-imagem e o CP definem o plano de interpretação (Fig. 6). O plano de interpretação é definido no espaço-imagem pela feição reta **s** e pelo CP, cuja equação é dada por:

$$-f\cos\theta x - f\sin\theta y + \rho z = 0 \tag{21}$$

Portanto o vetor normal ao plano de interpretação no espaço-imagem é dado por:

$$\vec{N}_{i} = -\begin{bmatrix} f \cos \theta \\ f \sin \theta \\ -\rho \end{bmatrix}$$
(22)

O plano de interpretação também pode ser definido no espaço-objeto. O vetor normal ao plano de interpretação no espaço-objeto é dado por:

$$\vec{N}_{o} = \begin{bmatrix} nx \\ ny \\ nz \end{bmatrix} = \begin{bmatrix} -n(Y_{0} - Y) + m(Z_{0} - Z) \\ n(X_{0} - X) - l(Z_{0} - Z) \\ -m(X_{0} - X) + l(Y_{0} - Y) \end{bmatrix}$$
(23)

Multiplicando o vetor \vec{N}_o pela matriz de rotação elimina-se a diferença angular entre os sistemas de referência imagem e objeto e resulta em um vetor normal ao plano de interpretação no espaço-objeto que possui a mesma direção que o vetor \vec{N}_i , normal ao plano de interpretação no espaço-imagem, mas com magnitude diferente (TOMMASELLI, 1993, p. 53).

$$\vec{N}_i = \lambda R \vec{N}_0 \tag{24}$$

Onde λ é o fator de escala e *R* é a matriz de rotação definida pela seqüência κ , ϕ , ω . A Equação (24) pode ser reescrita como:

$$\begin{cases} f \cos \theta \\ f \sin \theta \\ -\rho \end{cases} = \lambda \begin{bmatrix} r_{11}nx + r_{12}ny + r_{13}nz \\ r_{21}nx + r_{22}ny + r_{23}nz \\ r_{31}nx + r_{32}ny + r_{33}nz \end{bmatrix}$$
(25)

Com r_{ij} sendo os elementos da matriz de rotação. O elemento λ pode ser algebricamente eliminado. Para TOMMASELLI (1993, p. 53), a Equação (25) é dividia em dois conjuntos de equações, de acordo com o valor do parâmetro θ para que sejam evitadas divisões por zero. Para intervalos de retas horizontais ($45^{0} < \theta < 135^{0}$ ou $225^{0} < \theta < 315^{0}$) tem-se:

$$\cot \theta = \frac{r_{11}.nx + r_{12}.ny + r_{13}.nz}{r_{21}.nx + r_{22}.ny + r_{23}.nz}$$

$$\frac{-\rho}{f.\sin \theta} = \frac{r_{31}.nx + r_{32}.ny + r_{33}.nz}{r_{21}.nx + r_{22}.ny + r_{23}.nz}$$
(26)

Os elementos da equação paramétrica são:

$$a = \cot\theta$$

$$b = \frac{-\rho}{f \sin\theta}$$
(27)

A Equação (27) pode ser reescrita como:

$$a = -\frac{r_{11}.nx + r_{12}.ny + r_{13}.nz}{r_{21}.nx + r_{22}.ny + r_{23}.nz}$$

$$b = -f \frac{r_{31}.nx + r_{32}.ny + r_{33}.nz}{r_{21}.nx + r_{22}.ny + r_{23}.nz}$$
(28)

Para intervalos de retas verticais ($0^{0} < \theta < 45^{0}$ ou $135^{0} < \theta < 225^{0}$ ou $315^{0} < \theta < 360^{0}$), tem-se:

$$\tan \theta = \frac{r_{21}.nx + r_{22}.ny + r_{23}.nz}{r_{11}.nx + r_{12}.ny + r_{13}.nz}$$

$$\frac{-\rho}{f.\cos\theta} = \frac{r_{31}.nx + r_{32}.ny + r_{33}.nz}{r_{11}.nx + r_{12}.ny + r_{13}.nz}$$
(29)

Neste caso uma nova parametrização para retas deve ser introduzida:

$$a^* = \tan \theta$$

$$b^* = \frac{-\rho}{f \cos \theta}$$
(30)

A Equação (30) pode ser reescrita como:

$$a^{*} = -\frac{r_{21}.nx + r_{22}.ny + r_{23}.nz}{r_{11}.nx + r_{12}.ny + r_{13}.nz}$$

$$b^{*} = -f \frac{r_{31}.nx + r_{32}.ny + r_{33}.nz}{r_{11}.nx + r_{12}.ny + r_{13}.nz}$$
(31)

Como descrito anteriormente, o modelo dos planos equivalentes utiliza um ponto qualquer da feição reta no espaço-objeto e um vetor de cassinos diretores da reta. Devido a esta peculiaridade do modelo, não é necessário estabelecer correlações ponto-a-ponto sobre cada feição reta.

O modelo matemático desenvolvido considera que os dois vetores normais ao plano no espaço-imagem e ao plano no espaço-objeto, respectivamente, são paralelos. Este modelo matemático será utilizado neste trabalho e dentalhes sobre a formulação matemática apresentada, podem ser encontrados em TOMMASELLI (1993) e/ou TOMMASELLI e TOZZI (1996).

A Figura 7 apresenta os intervalos de linhas retas horizontais e verticais, de acordo com a parametrização sugerida pelas Equações (28) e (31) (TOMMASELLI, 1993).



FIGURA 7 – PARAMETRIZAÇÃO DAS RETAS.

Onde, Lin, Col: eixos do sistema digital.

TOMMASELLI e TOZZI (1999), aplicaram o modelo dos planos equivalentes na calibração de câmaras em aplicações recursivas de Visão de Máquina. Os resultados obtidos mostraram a aplicabilidade do modelo desenvolvido não apenas em Visão de Máquina mas também na Fotogrametria.

DAL POZ (1996), DAL POZ e TOMMASELLI (1998, 1999), propuseram uma metodologia para a determinação automática dos parâmetros de orientação exterior da câmara, utilizando o modelo dos planos equivalentes para relacionar funcionalmente as observações no espaço-imagem e no espaço-objeto. A eficiência do método depende da qualidade das feições retas extraídas.

TELLES e TOMMASELLI (2002), estenderam o modelo dos planos equivalentes, adicionando os parâmetros de orientação interior da câmara, tais como as coordenadas do ponto principal na imagem e os erros sistemáticos.

De acordo com os autores, os resultados obtidos mostraram que o método de calibração por linhas retas é compatível ao método de calibração convencional por pontos. Um problema do modelo matemático dos planos equivalentes é a condição de paralelismo entre os vetores normais aos planos no espaço-imagem e no espaço-objeto. Com isto, as feições retas extraídas devem de alta qualidade, caso contrário ocorre distúrbios na condição de paralelismo afetando efetivamente os resultados obtidos. SANTOS e DALMOLIN (2004), buscaram solucionar o problema de desestabilização do modelo matemático dos planos equivalentes com auxílio de feições retas grandes, devidamente selecionadas sobre rodovias em imagens digitais. Os resultados obtidos com dados simulados mostraram que, a metodologia empregada pode ser uma solução ao problema de desestabilização causada pelo uso de linhas retas de pequeno porte (feições pouco retas).

O modelo dos planos equivalentes é um modelo explícito não linear, ou seja, as observações ajustadas estão em função dos parâmetros ajustados. Pelo fato do modelo matemático descrito relacionar funcionalmente feições retas no espaçoimagem e no espaço-objeto, é possível estimar os parâmetros de orientação exterior da câmara. Na seção 2.4 serão descritos os métodos de estimação mais importantes para a solução do problema apresentado neste trabalho.

2.4 MÉTODOS DE ESTIMAÇÃO DE PARÂMETROS

De acordo com TOMMASELLI (1993, p. 28), existem vários métodos de estimação de parâmetros a partir de observações, desde o Método dos Mínimos quadrados (MMQ), concebido por Gauss e Legendre, até a filtragem Kalman, introduzida por Kalman na década de 60.

O método de estimação por Mínimos Quadrados tem como objetivo minimizar a soma dos quadrados dos resíduos e encontrar solução única para o problema, e supõe que os parâmetros não possuam variação temporal, ou seja, que o sistema é estático. Além do que, este método envolve operações com matrizes, as quais são dimensionadas em função do número de observações a serem inseridas e o número de parâmetros a serem estimados.

No entanto, a necessidade de inversão da matriz das equações normais torna o processo computacionalmente lento e indesejável e muitas vezes requer o uso de injunções para quebrar a deficiência de posto da matriz das equações normais.

A filtragem Kalman é um método de estimação Bayeseano, não tendencioso e assume variância mínima. Além de ser adequado para alimentar sistema dinâmico, pois considera a variação temporal dos parâmetros. Este método de estimação é o utilizado na determinação dos parâmetros de orientação exterior das imagens e será desenvolvido na sub-seção 2.4.1.1

2.4.1 Método de estimação recursivo

A estimação recursiva de parâmetros possibilita atualizar a solução com inserção de novas observações sem a necessidade de armazenar as observações da época anterior, ou seja, ocorre uma atualização do vetor de estado a cada conjunto de novas observações coletadas pelo sistema. Porém, o método carece de uma estimativa inicial aproximada (vetor de estado), bem como de sua MVC, também aproximada.

Os métodos de estimação recursivos são divididos em sistemas dinâmicos e sistemas estáticos. Os sistemas dinâmicos são utilizados em sistemas que possuem movimentos (localização de objetos em esteiras, deslocamento de robôs,movimento de corpos rígidos etc). Os casos de sistemas estáticos coincidem com o MMQ, no qual trata simultaneamente todas as observações disponíveis no instante t_k, ou seja, as observações são manipuladas individualmente, de modo que os parâmetros sofram uma variação temporal. Em ambos os casos, os dados são filtrados e uma solução ótima é determinada.

O filtro de Kalman é considerado "ótimo" por fornecer a mesma estimativa independente do critério de otimização utilizado. É também considerado um filtro de erro mínimo, pois a incerteza no final do processamento é a menor entre todas as outras geradas por outras aproximações.

De acordo com GELB (1974, p. 105), a escolha da filtragem depende do modelo matemático empregado na solução. Em caso de modelos matemáticos não lineares, a versão do filtro utilizada na estimação dos parâmetros é o denominado Filtro de Kalman Iterativo Estendido (IEKF – *Iterated Extended Kalman Filtering*).

2.4.1.1 Filtro de Kalman iterativo estendido

A necessidade de linearização do modelo matemático exige processos iterativos para que o modelo tenha a melhor aproximação de sua forma linear. A

versão do IEKF, que será utilizada neste trabalho, possui as seguintes características:

- Sistema estático; e
- Equação de observação não linear e discreta.

A equação de observação pode ser colocada na forma (GELB, 1974):

$$lb_n = f(x_n) + r_n, n = 1, 2, 3, ...$$
 (32)

Onde,

- *lb_n* : vetor das n observações ou medidas;
- *r*_n: vetor dos resíduos das observações, com média zero (variâncias não são correlacionadas), e Matriz de Variância-Covariância Σ^{*lb*} (MVC de *lb_n*);
- *x_n* : vetor dos parâmetros ou vetor de estado; e
- *f*: modelo matemático não linear, que vincula o vetor dos parâmetros ao vetor das observações.

Para a estimação do vetor dos parâmetros (x_n), empregando-se as medidas disponíveis (Ib_n), utiliza-se a seguinte equação (GELB, 1974):

$$\eta_{i+1} = x_{n-1} + K_{n;\eta_i} \left[lb_n - f(\eta_i) - A_{n;\eta_i} (x_{n-1} - \eta_i) \right]$$
(33)

Onde,

- η_i: i-ésima iteração, sendo uma estimativa de x_n, onde na 1^ª iteração η₁=x_{n-1};
- x_{n-1}: estimativa obtida com a observação anterior (*Ib_{n-1}*), isto é, vetor estimado com a (n-1) observação;
- $K_{n;\eta i} = (\Sigma_{n-1}^p A_{n;\eta_i})^T \left[A_{n;\eta_i} \Sigma_{n-1}^p A_{n;\eta_i}^T + \Sigma_n^{lb} \right]^{-1}$: ganho de Kalman;

- Σ^p_{n-1}: matriz variância-covariância de x_{n-1}. Ou seja, é a MVC dos parâmetros; e
- $A_{n;\eta_i} = \frac{\partial f(x_n)}{\partial x_n}\Big|_{x_n = \eta_i}$: matriz de derivadas parciais de $f(x_n)$ em

relação ao vetor dos parâmetros, calculada no ponto η_i .

O objetivo do processo de estimação é atualizar o vetor de parâmetros (x_n) e sua respectiva MVC (Σ^P). A Figura 8 apresenta o esquema de um processo de estimação pelo IEKF.

FIGURA 8 – PROCESSO DE ESTIMAÇÃO DO IEKF.



De acordo com a Figura 8, no início do processo (*n*=1), é imprescindível o uso de um vetor de parâmetros com valores aproximados (x_0) e sua matriz variância-covariância (Σ^{p}_{0}).

O primeiro conjunto de observações lb_1 e sua Σ^{lb}_1 são introduzidos e os cálculos de cada iteração são efetuados de acordo com a seguinte seqüência:

- cálculo do ganho de kalman (K);
- cálculo da iteração; e
- teste de convergência, através de algum critério pré-definido.

Após a convergência da solução, faz-se:

$$x_n = \eta_{i+1} \tag{34}$$

$$\Sigma_{n}^{p} = (I - K_{n;x_{n}} A_{n;x_{n}}) \Sigma_{n-1}^{p} (I - K_{n;x_{n}} A_{n;x_{n}})^{T} + I - K_{n;x_{n}} \Sigma_{n}^{lb} K^{T}_{n;x_{n}}$$
(35)

O filtro de Kalman foi utilizado em problemas de automação das etapas fotogramétricas. TOMMASELLI (1993), aplicou-o para realimentar o processo de extração de feições retas, pela redução gradativa da janela de busca da feição na imagem. O método exige o uso de estimativas preditas iniciais de boa qualidade, pois o modelo matemático envolvido no processo é do tipo não linear e uma estimativa grosseira definiria uma janela de busca muito grande eliminando as vantagens introduzidas pela realimentação introduzida pela filtragem.

TOMMASELLI e TOZZI (1996), aplicaram a filtragem Kalman para solucionar o problema de resseção espacial de imagens. A propriedade recursiva do filtro foi utilizada no processo de estimação dos parâmetros da câmara como resposta gradativa para a definição do tamanho da janela de busca de feições retas.

DAL POZ (1999), aplicou-o na estimação automática de parâmetros de orientação exterior da câmara, com a heurística de injunção de rigidez e correlação estrutural. Devido à condição ótima do filtro, o mesmo superestima a MVC dos parâmetros e a janela de pesquisa reduz drasticamente sua dimensão

impossibilitando o uso de algumas feições para o processo de estabelecimento automático.

VOSSELMAN e KNECHT (1999), combinaram resultados advindos de correlação por Mínimos Quadrados com filtragem Kalman para determinar a posição e descrever a forma de rodovias. Os ruídos da imagem são os fatores indesejados no processo, uma vez que perturbam as variâncias determinadas entre as feições previamente definidas pelo operador e as feições detectadas automaticamente.

KINN (2002), combinou informações de GPS e Sistema de Navegação Inercial com filtro de Kalman para permitir a determinação acurada da posição e atitude da câmara no momento de exposição da fotografia. O filtro de Kalman é utilizado para integrar os erros advindos dos dois sistemas e determinar a magnitude dos mesmos. O vetor de estado inclui a estimativa dos erros associados com a posição e atitude da câmara.

LI et al. (2004), apresentaram uma nova metodologia para restauração de imagens TM LANDSAT, por meio da implementação do filtro de Kalman como um filtro atmosférico. Os resultados obtidos mostraram que o filtro de Kalman age como um filtro atmosférico mais eficiente que o filtro de *Wiener* convencional, uma vez que apresenta melhores resultados de detalhes e contraste das imagens.

Como a realidade física é demasiadamente complexa é impossível desenvolver um modelo matemático que a represente de forma fidedigna. Ao assumir que o modelo matemático é adequado a um suposto problema, como no caso das relações existentes entre feições retas no espaço-imagem e no espaço-objeto, deve-se verificar quanto as observações estão consistentes com o modelo matemático e indicar a presença de erros grosseiros, para que seja possível adaptar a situação.

Por isso, os resíduos das observações ajustadas no processo de estimação devem ser analisados estatisticamente e o processo mais adequado é o uso de alguma técnica de controle de qualidade das observações, como por exemplo o teste *data-snooping*.

2.5 CONTROLE DE QUALIDADE

Se o modelo matemático adotado no processo de estimação dos parâmetros de orientação exterior da câmara é adequado, o controle de qualidade se resume na verificação da consistência entre as observações e o modelo matemático, bem como identificar a presença de erros grosseiros não modelados para que os mesmos sejam eliminados (TEUNISSEN, 1998).

O controle de qualidade está perpetuado à execução de testes estatísticos, onde uma determinada condição, denominada hipótese nula (H_0), é estabelecida para os parâmetros a serem examinados. Os testes estatísticos são baseados em testes de hipóteses.

2.5.1 Teste hipótese

O teste de hipótese pode ser entendido como uma regra de decisão para se aceitar ou rejeitar uma suposição, que pode ser verdadeira ou falsa, quanto ao valor de um parâmetro populacional para uma dada probabilidade. Devido à dificuldade de se examinar a população inteira, utiliza-se uma amostra aleatória. Com isto, formulase a denominada hipótese nula (H_0) para os parâmetros a serem testados.

A rejeição de H₀ significa a aceitação de uma hipótese alternativa (H_a), que advém da insuficiência de evidências para rejeitar H₀. Sendo assim, ao se acatar o resultado de um teste de hipóteses, cometem-se dois tipos de erros: o erro α e o erro β , no qual o erro do tipo α , também denominado de nível de significância, é a probabilidade de se rejeitar uma hipótese que na realidade é verdadeira. O erro do tipo β , é a probabilidade de se aceitar uma hipótese que na realidade é falsa (TIBERIUS, 1998).

Geralmente a etapa de detecção de erros é a etapa mais importante no controle de qualidade. Nesta etapa testa-se a hipótese H_0 contra H_a , com a finalidade de verificar a inconsistência entre o modelo matemático e as observações.

O processo de estimação proporciona resíduos das observações que possuem uma mistura de todos os tipos de erros. Os erros sistemáticos são passíveis de modelagem, enquanto os erros aleatórios são de natureza desconhecida e os erros grosseiros, geralmente, requerem o uso de técnicas de

64

detecção e eliminação aplicada aos resíduos provenientes do processo de estimação.

2.5.2 Detecção de erros grosseiros

Num processo de medida envolvendo *n* observações e *u* incógnitas pode-se formular as seguintes hipóteses:

- *H*₀: hipótese básica preconizando que a observação analisada não contém erro de magnitude ∇ (escalar desconhecido); e
- *H_a*: hipótese alternativa preconizando que a observação analisada contém erro de magnitude ∇.

O teste para detecção pode ser realizado a partir de uma análise dos resíduos preditos, que por estarem em função das observações, possibilitam que o teste seja executado paralelamente ao filtro de Kalman. A estatística a ser utilizada para testar H_0 contra H_a é dado por (BAARDA, 1968):

$$S = \frac{r_n}{\sigma_{r_n}} \tag{36}$$

Onde,

- *r_n* : resíduo predito das observações;
- σ_{r_n}: desvio-padrão dos resíduos preditos;
- *S* : estatística denominada correção normalizada.

As estatísticas apresentadas possuem distribuição normal padrão, isto é, $S \sim N_{\alpha/2}(0,1)$, e trata localmente as observações. Se a primeira hipótese é verdadeira, não existem erros nas observações. Então, as observações não contêm erros quando a estatística *S*, a um nível de significância α , estiverem situadas no intervalo (DAL POZ, 1999):

$$-N_{\alpha/2} < S < N_{\alpha/2} \tag{37}$$

Onde, $N_{\alpha/2}$ é extraída da curva normal padrão.

Nos casos em que a estatística S exceder a distribuição normal a um determinado nível de significância, o erro é identificado. Caso algum erro seja detectado e identificado, as observações são descartadas do processo e o vetor de estado não é atualizado.

2.6 SISTEMA DE VARREDURA LASER

O sistema de varredura Laser aerotransportado efetua uma varredura perpendicular à direção da linha de vôo, medindo o tempo de emissão e recepção do pulso gerado pelo sistema Laser. A distância entre a plataforma aérea e o terreno é calculada em pós-processamento, em função da velocidade da luz, altura de vôo, ângulo de varredura, frequência de varredura e taxa de amostragem. O sistema determina coordenadas tridimensionais de cada ponto perfilado no terreno, com o uso de basicamente 3 componentes:

- Receptor GPS: registra a posição da aeronave em intervalos de tempo fixos, enquanto outro receptor de base (no terreno), possibilita correção diferencial do posicionamento do sensor (pós-processamento);
- Sistema de medida inercial: registra os ângulos de atitude (κ,φ,ω) do sensor durante o vôo. Posteriormente, são utilizados no pós-processamento para determinação precisa das coordenadas dos pontos tridimensionais no terreno. O conjunto de dados (GPS/inercial) é medido e armazenado simultânea e paralelamente à medição do tempo de emissão e recepção de cada pulso Laser; e
- Laser: armazena o tempo de emissão e recepção de cada pulso, bem como o valor de intensidade de reflectância de cada objeto varrido.

Na concepção do sistema, os raios Laser são utilizados devido sua baixa divergência, tornando seu percurso similar a uma linha reta, mesmo quando o diâmetro de seu cone visual (*footprint*) esteja entre 30 cm e 1,5 m. Como consequência, múltiplas reflexões são permitidas quando, por exemplo, o raio atinge a borda do telhado de uma edificação, sendo que uma parte do raio é refletida pela borda da edificação e outra parte relfetida pelo terreno.

O aspecto mencionado apresenta vantagens e desvantagens, uma vez que múltiplas reflexões constituem uma poderosa ferramenta para vários tipos de análise de dados. Por outro lado, apresenta falsas informações para alguns tipos de objetos, como por exemplo, o tamanho real da edificação não é representado de forma fidedigna.

Por isso, para que um MDT gerado pelo sistema de varredura Laser represente perfeitamente a morfologia do terreno é necessário que seja utilizado um algoritmo de filtragem de dados brutos eficiente. Isto não é uma tarefa trivial e muitas soluções foram apresentadas por KRAUS e PFEIFER (1998), VOSSELMAN (2000), MASAHARU e OHTSUBO (2002), ALHARTHY e BETHEL (2002), entre outros.

O sistema de varredura Laser fornece como produto final um conjunto de pontos distribuídos irregularmente, constituindo um MDT e um MNE (Modelo Numérico de Elevações) da região perfilada. A densidade dos pontos obtidos atinge vários pontos por m², dependendo da altura de vôo e a frequência de perfilamento. A frequência do Laser se situa na faixa de 500 a 1500 nm, com valores de 1040 a 1060 nm, sendo as mesmas refletidas pelos objetos contidos no terreno. Os pontos coletados podem ser utilizados diretamente ou podem ser filtrados e interpolados de forma a gerar uma grade regular de pontos.

A grande potencialidade do sistema está na geração de MDT's e MNE's de forma precisa, rápida e completa. Com o sistema em uso pode-se gerar o MDT em regiões homogêneas (áreas de vegetação) e hetereogêneas, uma vez que a geração de MDT por meio de correlação de imagens (Fotogrametria), não permite a determinação de pontos com altitude em áreas homogêneas e principalmente das elevações (por exemplo, edificações e árvores) contidas no terreno (SANTOS, 2002).

Existem alguns tipos de sistemas de varredura Laser e neste trabalho foram utilizados dados provenientes do sistema OPETCH *ALTM* (*Airborne Laser Terrain*

Mapper) 2050 System. O Quadro 1, apresenta alguns parâmetros do sistema utilizado.

QUADRO 1: CARACTERÍSTICAS DE SISTEMAS OPETCH ALTM (Airborne Laser Terrain Mapper) 2050.

| Características/Sistemas | ALTM 2050 |
|--------------------------|-----------------------|
| Ano do modelo | 2003 |
| Taxa de amostragem | Até 50 KHz |
| Frequência de varredura | Até 35 Hz |
| Ângulo de varredura | 0 ± 20^{0} |
| Altura de operação | 210-2000 m |
| Modo (pulso) | Primeiro e/ou segundo |
| Intensidade | Sim |
| Câmara digital | 4k x 4k pixels |

Segundo WEHR e LOHR (1999, p. 79), conta-se com sistemas com precisão melhor que 10 cm em posição e melhor que 0.02° em atitude. Mais detalhes, sobre o funcionamento do sistema podem ser encontrados em DALMOLIN e SANTOS (2004).

2.6.1 Imagem de intensidade Laser

Outra peculiaridade do sistema de varredura Laser é a aquisição dos valores de intensidade de reflectância dos objetos perfilados no terreno. A Figura 9 apresenta a imagem de intensidade de uma porção aérea da região de interesse. O vôo foi realizado pela empresa de Aerofotogrametria Engefoto e a imagem de intensidade foi gentilmente cedida pelo LACTEC (Instituto de tecnologia e desenvolvimento).



FIGURA 9 – IMAGEM DE INTENSIDADE (FONTE: LACTEC).

A imagem de intensidade é obtida a partir da interpolação dos valores de intensidade de cada ponto varrido pelo sistema, gerando uma imagem bidimensional de valores de intensidade. Para cada ponto é atribuído um valor de intensidade, no qual é agregado aos mesmos suas coordenadas tridimensionais compostas num arquivo de um ponto por linha de texto (arquivo bruto). Os dados são interpolados de acordo com a resolução ao qual foram perfilados os pontos no terreno.

Recentemente a fusão de imagens provenientes do sistema de varredura Laser e imagens adquiridas com câmaras não métricas, tem sido de grande interesse na comunidade científica, como exemplo, HABIB et al. (2004a, 2004b e 2004c) integraram dados do sistema de varredura Laser e imagens digitais para aplicações de Fotogrametria.

DELARA et al. (2004), integrou imagens provenientes de câmaras não métricas e do sistema de varredura Laser para a aerotriangulação de um bloco de imagens digitais. A integração das imagens forneceu melhor rigidez para o processo de aerotriangulação e os resultados obtidos mostraram a viabilidade da integração dos dados tomados por câmaras não métricas e pelo sistema de varredura Laser, além de apresentar resultados compatíveis com o método convencional de aerotriangulação.