


# Sparse Bundle Adjustment

Vortrag von Matej Svejda

*Computer Vision & Visual Tracking for Robotic Applications*

# Was ist Bundle Adjustment?

- Auf deutsch: Bündelblockausgleich 😊
- „Lösung“ eines Henne-Ei-Problems:
- Gegeben:
  - Bilder einer (unbewegten) Szene aus verschiedenen Blickwinkeln (views)
  - Menge von korrespondierenden feature points
- Gesucht:
  - Welche Position hatte die Kamera bei der Aufnahme der einzelnen Bilder? => 9 Parameter pro Bild
  - Was sind die 3D-Koordinaten der einzelnen feature points? => 3 Parameter pro feature point



# Mathematische Formulierung

- $n$  feature points werden in  $m$  views gesehen mit den Koordinaten  $P_{i,j}, i \in \{1, \dots, n\}, j \in \{1, \dots, m\}$
- Ist feature point  $i$  auf view  $j$  zu sehen, dann sei  $v_{i,j} = 1$  sonst  $v_{i,j} = 0$
- Seien  $a_j$  die Kameraparameter von view  $j$  und  $b_i$  die Koordinaten von feature point  $i$
- $q$  sei die Projektionsfunktion und  $d$  die euklidische Distanz
- Bundle adjustment minimiert für  $a$  und  $b$  die Kostenfunktion

$$c(a, b) = \frac{1}{2} \sum_{i=1}^n \sum_{j=1}^m v_{ij} d(q(a_i, b_j), P_{i,j})^2$$

# Wie kommt man zur Lösung?

- Gesucht ist das Minimum Kostenfunktion
- Die Kostenfunktion ist immer positiv und für die exakte Lösung gleich Null
- Exakte Lösung ist aber nicht möglich, da kein LGS
  - Kameraparameter werden mit den feature point Koordinaten bei der Projektion nichtlinear kombiniert
  - Euklidische Distanz quadriert die Koordinatendifferenz
- Ansatz:
  - *Iterative Methoden*

# Iterative Methoden

- Alternative Schreibweise der Kostenfunktion:

$$p = \begin{pmatrix} a \\ b \end{pmatrix}, \quad \varepsilon(p) = q(p) - P \quad \Rightarrow \quad c(p) = \frac{1}{2} \varepsilon(p)^T \varepsilon(p)$$

- Man beginnt mit einer Initialen Schätzung der gesuchten Parameter  $p_0$
- Bei jedem Schritt in der Iteration wird die Schätzung der Parameter aktualisiert  $p_{i+1} = p_i + u$
- Die Parameter werden (im Idealfall) so abgeändert, dass die Kostenfunktion sukzessive gegen Null geht
- Verschiedene iterative Methoden unterscheiden sich darin, wie das Update  $u$  berechnet wird

# Newton Methode

- Die Kostenfunktion wird quadratisch approximiert (Taylor)

$$c(p_i + u) \approx c(p_i) + c_p(p_i)u + u^T c_{pp}(p_i)u$$

- $c_p$  ist der transponierte Gradient,  $c_{pp}$  die Hesse-Matrix
- $u$  soll den Wert annehmen, bei dem  $c(p_i + u)$  minimal wird

$$c(p_i + u) \rightarrow \min \Leftrightarrow c_u(p_i + u) = 0$$

- Also wird die quadratische Approx. nach  $u$  abgeleitet

$$c_{pp}(p_i)u + c_p(p_i) = 0$$

- Aus dieser Gleichung kann  $u$  bestimmt werden

# Abwandlungen der Newton Methode

- Für eine vektorwertige Fkt.  $f$  gilt:  $\partial_x (f(x)^T f(x)) = 2 f_x(x)^T f(x)$

$$c_p(p) = \frac{1}{2} \partial_x (\varepsilon(p)^T \varepsilon(p)) = \varepsilon_p(p)^T \varepsilon(p)$$

$$c_{pp}(p) = \varepsilon_p(p)^T \varepsilon_p(p) + \varepsilon_{pp}(p)^T \varepsilon(p)$$

- **Gauss-Newton:**  $\varepsilon(p)$  wird als linear angenommen

$$\Rightarrow c_{pp}(p) = \varepsilon_p(p)^T \varepsilon_p(p)$$

$$\varepsilon_p(p)^T \varepsilon_p(p) u = -\varepsilon_p(p)^T \varepsilon(p)$$

- **Gradientenabstieg:**  $c_{pp}(p)$  wird mit  $\lambda Id$  approximiert

$$\lambda u = -\varepsilon_p(p)^T \varepsilon(p)$$

# Levenberg-Marquardt

- Kombination von Gauss-Newton und Gradientenabstieg

$$(\lambda Id + \varepsilon_p(p)^T \varepsilon_p(p))u = -\varepsilon_p(p)^T \varepsilon(p)$$


- Der Wert für  $\lambda$  wird so gewählt, dass die Kostenfunktion nach dem Update einen niedrigeren Wert hat
- Dadurch bleibt die Iteration nicht so leicht in lokalen Minima stecken
- Levenberg-Marquardt wechselt also je nach Bedarf zwischen Gradientenabstieg und Gauss-Newton

# Sparse (dünnbesetzte) Matrizen bei LM

- Bei jedem Iterationsschritt muss mehrmals die „normal equation“ gelöst werden:

$$(\lambda Id + J^T J)u = J^T \varepsilon$$

- Dabei ist  $J := \varepsilon_p(p)$  die Jacobi-Matrix
- Bei sparse bundle adjustment wird die blockbasierte, sparse Struktur der Matrix ausgenutzt



## Struktur der sparsen Matrix bei LM (1)

- Die Jacobi-Matrix besteht aus zwei Blöcken  $J = [\varepsilon_a \quad \varepsilon_b] = [A \quad B]$
- Dadurch erhält man für die Iterationsgleichung

$$\begin{aligned}
 (\lambda Id + J^T [A|B]) \begin{pmatrix} u_a \\ u_b \end{pmatrix} &= J^T \varepsilon \Leftrightarrow (\lambda Id + \begin{bmatrix} A^T A & A^T B \\ B^T A & B^T B \end{bmatrix}) \begin{pmatrix} u_a \\ u_b \end{pmatrix} = \begin{pmatrix} A^T \varepsilon \\ B^T \varepsilon \end{pmatrix} \\
 \Leftrightarrow \begin{bmatrix} \tilde{A} & W \\ W^T & \tilde{B} \end{bmatrix} \begin{pmatrix} u_a \\ u_b \end{pmatrix} &= \begin{pmatrix} \varepsilon_A \\ \varepsilon_B \end{pmatrix} \Leftrightarrow M \begin{pmatrix} u_a \\ u_b \end{pmatrix} = \begin{pmatrix} \varepsilon_A \\ \varepsilon_B \end{pmatrix}
 \end{aligned}$$

- Die Tatsache, dass sich die Matrix in dieser Form in Blöcke aufteilen lässt, vereinfacht die Invertierung von M
  - Man muss nur die Matrix  $\tilde{A}$  und das s.g. Schurkomplement  $\tilde{B} - W^T \tilde{A}^{-1} W$  invertieren

## Struktur der sparsen Matrix bei LM (2)

- Zusätzlich zur Blockstruktur von  $M$  wird die Struktur der Jacobi-Matrix  $J$  ausgenutzt
- Diese ergibt sich daher, dass feature-points nur mit den Kameraparametern kombiniert werden, auf denen sie zu sehen sind

$$J = \begin{bmatrix} A & B \end{bmatrix}, \quad A = [A_1 A_2 \dots A_n]^T, \quad B = \text{diag}(B_1, B_2, \dots, B_n)$$

- Durch diese Struktur kann  $\tilde{A}$  und das Schurkomplement effizienter gespeichert werden
- Auch das Invertieren kann effizienter implementiert werden
  - Die Invertierung einer Matrix hat eine Komplexität von  $O(N^3)$
  - Wird die sparse Struktur ausgenutzt kann das auf bis zu  $O(N)$  reduziert werden

# Anwendung von Sparse Bundle Adjustment

- In allen Bereichen, bei denen man die Position von Kamera und feature points bestimmen will
- Dense Multi-View Reconstruction:  
Feature points extrahieren → feature points matchen → Kamerabewegung mit SBA bestimmen → Dense reconstruction  
<http://www.youtube.com/watch?v=vdt66tsPjCM>
- Schleifenerkennung bei SLAM:  
Aufnahmen mit distinktiven feature points speichern (key-frame) → mit SBA Schleifen in den key-frames erkennen  
[http://www.youtube.com/watch?v=\\_p08o\\_oTO4&feature=player\\_detailpage#t=41s](http://www.youtube.com/watch?v=_p08o_oTO4&feature=player_detailpage#t=41s)

Das wars...

Danke für die Aufmerksamkeit 😊