Markerlose Kalibrierung einer einer Linienkamera zur Erzeugung hyperspektral annotierter 3D-Punktwolken mit einem terrestrischen Laserscanner

Thomas Wiemann, Felix Igelbrink, Joachim Hertzberg

1 Einleitung

In diesem Beitrag beschreiben wir ein Verfahren zur markerlosen Co-Kalibrierung einer hyperspektralen Linienkamera mit einem terrestrischen Laserscanner. Ähnlich der Kalibrierung gegen eine konventionelle RGB-Kamera sollen die 3D-Messpunkte das Laserscanners mit den gemessenen Spektren der Hyperspektralkamera assoziiert werden. Hyperspektralkameras teilen das Spektrum des einfallenden Lichts in diskrete Wellenlängenbereiche auf, in denen die Intensität des einfallenden Lichts pro Bereich detektiert wird. Dies erlaubt es, die charakteristische Intensitätsverteilung des von den in der Umgebung vorhandenen Materialien reflektierten Lichts über die verfügbaren Spektralbereiche zu erfassen. Technisch wird dazu das einfallende Licht mittels eines Prismas aufgeteilt und auf einen CCD-Chip geleitet, der die Intensität für jeden Pixel misst. Dabei spiegelt eine Dimension der Pixelmatrix die räumliche Verteilung wieder, die andere die spektrale Verteilung. Dementsprechend verhält sich so eine Kamera wie eine Zeilenkamera mit vielen hyperspektralen Kanälen.

Einen ersten Ansatz zur Kalibrierung eines solchen Systems haben wir in Wiemann et al. (2018) vorgestellt. Hier geschah die Kalibrierung mittels eines Referenzmusters in OpenCV im Lochkameramodell. Obwohl sich mit diesem Ansatz bereits passable Ergebnisse erreichen ließen, hatte es zwei entscheidende Nachteile. Zum einen musste des Referenzmuster sowohl in den Hyperspektraldaten als auch in den Laserdaten gefunden werden. Aufgrund der geringen räumlichen Auflösung der Kamera, war es in vielen Situationen schwierig, das Referenzmuster sicher zu erkennen. Zum anderen zeigte sich, dass mit dem Lochkameramodell nicht alle Verzerrungen korrekt ausgeglichen werden konnten.

In diesem Papier zeigen wir einen weiterführenden Ansatz, der diese Probleme löst. Die extrinsische Kalibrierung der Hyperspektralkamera gegen den Laserscanner erfolgt nun markerlos, so dass eine Neukalibrierung des Systems direkt im Einsatz ohne die Einbringung von künstlichen Markern möglich ist. Dazu werden die einzelnen Bilder der Kamera zunächst zu einem konsistenten

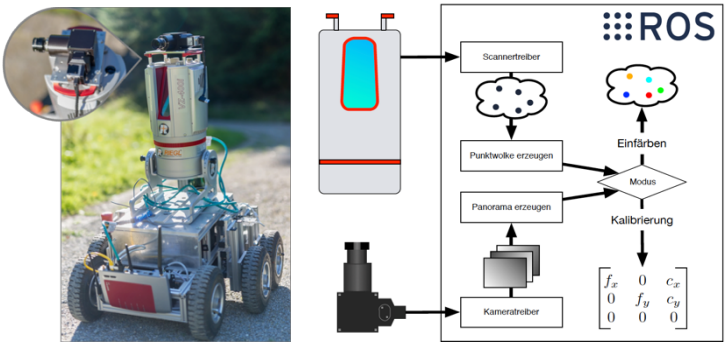

Abbildung. 1: Aufbau und Sensorik der Roboterplattform Pluto (links) sowie eine schematische Übersicht der implementierten Softwarekomponenten und des Ablaufs der Kalibrierung (rechts).

„Hyperspektralpanorama“ zusammengesetzt. Mit Hilfe eines Panoramamodells werden dann die Daten aus beiden Sensoren mittels eines Mutual-Information-Ansatzes zur Deckung gebracht. Im Folgenden beschreiben wir den Aufbau unseres Referenzsystems, den Ansatz zur Kalibrierung der beiden Sensoren und zeigen erste Ergebnisse von durchgeführten Messungen.

2 Aufbau des Messsystems

Das hier vorgestellt Messsystem besteht aus einem Riegl VZ 400i Laserscanner sowie einer Resonon PikaL-Hyperspektralkamera mit 150 diskreten Spektralkanälen im Bereich von 400 bis 1000 Nanometer und einer räumlichen (vertikalen) Auflösung von 900 Pixeln pro Linie. Der Aufbau des Systems ist in Abbildung 1 dargestellt.

Der Laserscanner ist hier auf einer mobilen Roboterplattform installiert, die mit dem Robot Operating System (ROS) betrieben wird. ROS stellt Mechanismen zu Synchronisation von Sensordaten aus verschiedenen Quellen zur Verfügung. Hier verwenden wir eigene Treiber für Scanner und Kamera. Der Kameratreiber setzt die Linien der Hyperspektralkamera während der Drehbewegung des Laserscanners zu einem konsistenten Panoramabild zusammen. Die Daten von beiden Sensoren werden dann je nach gewählten Betriebsmodus entweder zur Kalibrierung oder zur Einfärbung der Punktwolken verwendet.

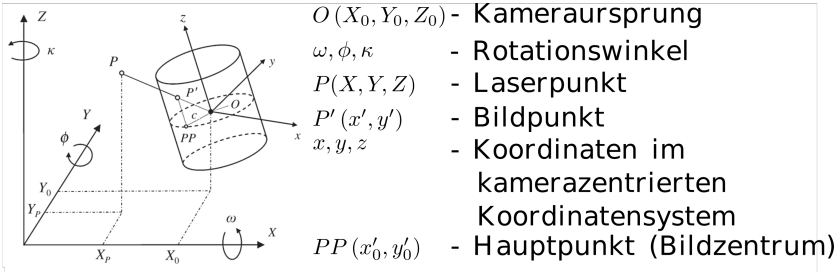

Abbildung 2: Zylindrisches Kameramodell nach Schneider und Maas (2006), das zur Projektion der 3D-Punkte verwendet wird.

3 Automatische Kalibrierung

3.1 Erzeugung von Referenzbildern zur Kalibrierung

Für die extrinsische Kalibrierung müssen die Daten des Laserscanners mit denen der Kamera verglichen werden können. Dazu werden die 3D-Punkte p_i des Scanners mit einem passenden Panoramamodell nach Schneider und Maas (2006) auf eine Zylinderoberfläche projiziert, die den Parametern der verwendeten Kamera entspricht. Ein Skizze dieses Modells ist in Abbildung 2 dargestellt. Daraus ergeben sich die folgenden Projektionsgleichungen für die Koordinaten x_i'und y' auf der Zylinderoberfläche:

$$p_i = \boldsymbol{R}^{-1}(P_i - O),\ R(\omega,\ \phi, \kappa),\ O(X_0, Y_0, Z_0)$$
$$x_i{}' = x_0' - \tan^{-1}\left(\frac{-y_i}{x_i}\right)$$
$$y_i{}' = y_0' - \frac{z_i}{\sqrt{x_i^2 + y_i^2}}$$

Diese Zylinderkoordinaten werden anschließend in die Pixelkoordinaten eines Bildes umgewandelt:

$$x_i^{image} = \frac{x_i' + \min_j x_j'}{I_x},\ \mathrm{y_i^{image}} = \frac{R_y}{2} - \frac{y_i'}{I_y}$$
$$I_x = \frac{\max_i x_i' - \min_i x_i'}{R_x},\ I_y = \frac{\max_i y_i' - \min_i y_i'}{R_y}$$

R_x und R_y spezifizieren dabei die Auflösung des generierten Bildes in Pixeln.

Abbildung 3: Beispiel für ein Pseudo RGB-Panorama, das aus den Liniendaten der Hyperspektralkamera zusammengesetzt wurde.

Das resultierende synthetische Bild des Laserscanners wird dann mit dem Panoramabild der Hyperspektralkamera verglichen. Dazu wird aus den Hyperspektraldaten ein RGB- bzw. Graustufenbild abgeleitet. Dieses kann gewonnen werden, indem die Intensitäten entsprechender Spektralbereiche (z.B. rot: 570 nm, grün: 540 nm, blau: 440 nm) als RGB-Werte interpretiert werden. Ein Beispiel für ein so erzeugtes Pseudo-RGB-Bild ist in Abbildung 3 gezeigt.

Die Idee hinter diesem Ansatz ist, dass sich trotz unterschiedlicher Bilddomänen gemeinsame Strukturen in beiden Bildern finden lassen. Dazu projizieren wir den normalisierten Reflektanzwert jedes 3D-Punktes des Laserscanners im Sichtbereich der Kamera in die Pixelkoordinaten der angenommenen zylindrischen Panoramakamera. Ausgehend von einer passenden Initialschätzung der Ausrichtung der Kamera, werden anschließend die Modellparameter optimiert, bis Kamera- und Laserscannerbild optimal zueinander passen. Ein Beispiel für ein solches Bildpaar zeigt Abbildung 4. Die Optimierung der Modellparameter erfolgt dabei mit einem Mutual-Information-Ansatz, dessen Implementierung im Folgenden vorgestellt wird.

Abbildung 4: Projektion der Intensitätswerte der 3D-Punkte in das synthetische Panoramabild (links) und das mit der Kamera aufgenommene Referenzbild (rechts). Die schwarzen Anteile im linken Bild entstehen durch die Unterschiedlichen Blickwinkel der Sensoren.

3.2 Extrinsische Kalibrierung mittels Mutual Information

Der Vergleich der Bilder zur Optimierung der Modellparameter basiert auf der sogenannten Normalized Mutual Information (NMI). Diese beschreibt die statistische Abhängigkeit zwischen zwei Zufallsvariablen M, N basierend auf der Shannon Entropie (Shannon 2001). Hier betrachten wir die Histogramme der Grauwertverteilung in beiden Bilddomänen als Approximation der Zufallsverteilungen. Die NMI wird wie folgt berechnet:

$$H(M) = -\sum_{m \in M} p_M(m) \log \frac{1}{p_M(m)}$$
$$H(N) = -\sum_{n \in N} p_N(n) \log \frac{1}{p_N(n)}$$
$$H(M,N) = -\sum_{m \in M} \sum_{n \in N} p_{M,N}(m,n) \log \frac{1}{p_{M,N}(m,n)}$$
$$NMI(M,N) = \frac{H(N) + H(M)}{H(M,N)}$$

Die Eigentliche Kalibrierung ist hier ein Optimierungsproblem, bei demein die NMI maximierender Parametersatz des Kameramodells gesucht wird:

$$\widehat{\boldsymbol{\Theta}} = \arg\max_{\boldsymbol{\Theta}} \mathrm{NMI}(M, N, \boldsymbol{\Theta})$$
$$\boldsymbol{\Theta} = \{X_0, Y_0, Z_0, \omega, \phi, \kappa, x_0', y_0'\}$$

Durch die Diskretisierung der verwendeten Histogramme und den dadurch entstehenden Fehler in der Approximation der Zufallsverteilung weist die Zielfunktion viele lokale Maxima auf, was das Auffinden der global optimalen Lösung erschwert. Um die Auswirkung dieser lokalen Maxima zu verringern, werden die Eingangsbilder vor der Histogrammerstellung mit einem Gaußfilter gefaltet. Zusätzlich wird die Bin-Anzahl der Histogramme signifikant verkleinert, um den Einfluss von Rauschen auf die Approximation der Zufallsverteilung zu verringern

Die resultierenden Zielfunktionen für einen Modellparameter sind in Abbildung 5 gezeigt. Die gefaltete Zielfunktion weist offensichtlich nur ein einzelnes Maximum auf, dessen Position mit dem Maximum der nicht-gefalteten Zielfunktion übereinstimmt. Dies stellt sicher, dass das verwendete Optimierungsverfahren mit hoher Wahrscheinlichkeit im globalen Maximum konvergiert. Um die Datenbasis zu erweitern, findet die Kalibrierung nicht nur mit einem Bildpaar, sondern mit den gemeinsamen Verteilungen mehrerer Bildpaare statt. Dadurch erhöht sich zwar der Rechenaufwand, die Robustheit der Kalibrierung wird aber signifikant erhöht.

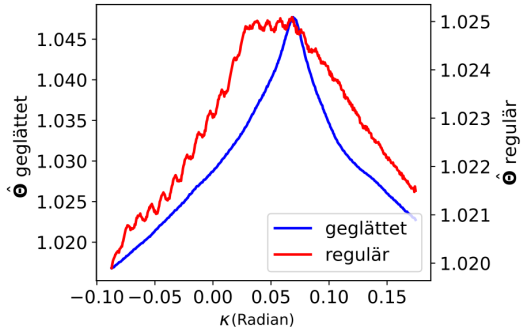

Abbildung 5: Verlauf der Zielfunktion vor- und nach der Faltung der Eingabehistogramme mit einem Gaußfilter.

Die eigentliche Optimierung erfolgt mit einem Standard-Optimierungsverfahren. Wir haben hier Partikelschwarmoptimierung (PSO) und das Verfahren nach Nelder-Mead (Olson und Nelson 1976) evaluiert, die beide keine Gradienteninformationen benötigen und daher auch für nicht-stetige Zielfunktionen, wie im vorliegenden Fall, geeignet sind. Da ein Optimierungsschritt durch die Projektion der 3D-Punkte und die Berechnung der Histogramme für hohe Bildauflösungen sehr rechenaufwändig ist, haben wir diese Schritte in CUDA zur Berechnung auf GPUs implementiert. Dadurch ist es möglich, das Optimierungsproblem in wenigen Sekunden zu lösen. Die Rechenzeiten der verschiedenen Verfahren für einen und 10 Scans sind in Tabelle 1 aufgeführt. Zur Bewertung der Qualität der Kalibrierung, haben wir jeweils manuell 10 korrespondierende Punkte nach der Optimierung in den Bildern bestimmt und den Abstand zueinander ermittelt. Die so berechneten mittleren Abstandswerte zeigt die letzte Spalte der Tabelle. Insgesamt zeigt sich, die die Reduzierung der Bins zu deutlich robusteren Ergebnissen führt. Dies ist auf die signifikante Reduzierung des Einflusses lokaler Maxima auf die Zielfunktion zurückzuführen.

Tabelle 1: Laufzeiten und durchschnittlicher Pixelfehler der getesteten Implementierungen

Methode	1 Scan	10 Scans	Pixelfehler
PSO (CPU)	6,30 h	> 40 h	1,37
PSO (GPU)	323,23 s	2379,28 s	1,37
Nelder-Mead (GPU, 256 Bins)	5,62 s	60,51 s	794,77
Nelder-Mead (GPU, 16 Bins)	9,03 s	84,88 s	1,90

4 Anwendungsbeispiele

Im Folgenden präsentieren wir zwei beispielhafte Einfärbungen von hyperspektral annotierten Punktwolken. Im ersten Beispiel (Abbildung 6) wurde der Anteil des roten und nahen Infrarotbereichs der Daten durch Falschfarben hervorgehoben (rot: 850 nm, grün: 660 nm, blau: 540 nm). In diesem Bild bildet der Rotkanal den nahen Infrarotbereich ab, der Grünkanal den roten Spektralbereich und der Blaukanal den grünen Anteil ab. Dadurch werden Materialien, die im nahen Infrarotbereich abstrahlen, besonders hervorgehoben. Dies ist insbesondere für das Chlorophyll der Pflanzen der Fall, weshalb diese besonders hervorkommen. Diese Aktivität kann durch die sogenannten NDVI-Wert (Normalized Difference Vegitation Index) noch weiter hervorgehoben werden, wie in Abbildung 7 dargestellt ist.

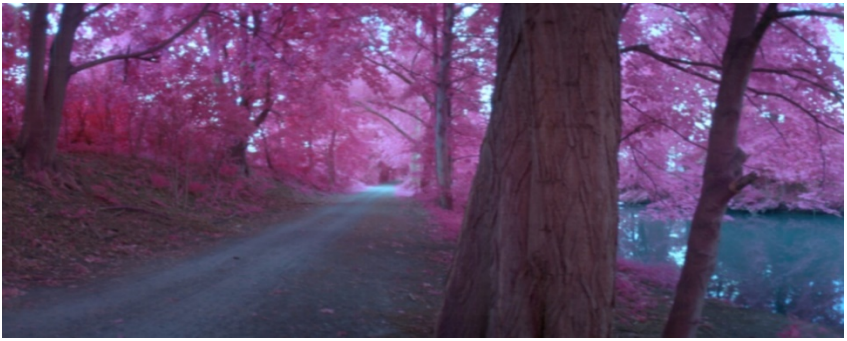

Abbildung 6: Hervorhebung der Farbanteile im roten und nahen infraroten Spektralbereich

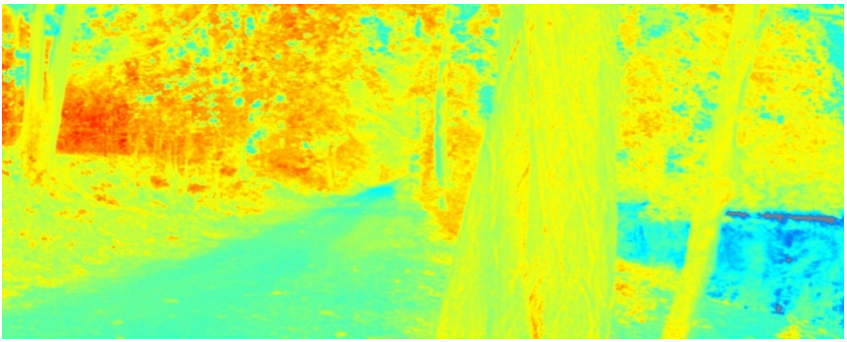

Abbildung 7: Darstellung der NDVI-Werte der einzelnen Punkte, die aus den Hyperspektraldaten ermittelt wurden

Literatur

Wiemann, T.; Heiden, C.; Diederichsen, R.; Pütz, S.; Hertzberg, J. Erzeugung hyperspektraler Punktwolken auf einem mobilen Roboter. In: Luhmann/Müller (eds.): Photogrammetrie, Laserscanning, Optische 3D-Messtechnik. Beiträge der Oldenburger 3D-Tage 2018, Wichmann Verlag, 2017

Schneider D.; Maas, H. A geometric model for linear-array-based terrestrial panoramic cameras. The Photogrammetric Record , 21(115):198-210, 2006.

Shannon, C. A mathematical theory of communication. ACM SIGMOBILE Mobile Computing and Communications Review , 5(1), 3-55, 2001.

Olsson, D. M.; Nelson, L. S. (1975). The Nelder-Mead simplex procedure for function minimization. Technometrics, *17*(1), 45-51, 1975

Kontakt

Dr. Thomas Wiemann
Universität Osnabrück, Institut für Informatik
Wachsbleiche 27
49090 Osnabrück
twiemann@uni-osnabrueck.de