
Registrierung von 3D Punktwolken via 2D Korrespondenz für ein kombiniertes Messsystem

Mathias BURGER, Songül POLAT, Burkhard TIETZ, Frank BOOCHS

Abstract

Ein Messsystem, bestehend aus einem 3D-Sensor (z.B. TOF) und einem höher auflösenden 2D-Sensor (RGB- oder Monochromkamera) kombiniert die Echtzeiterfassung von 3D-Geometrien mit der hohen Informationsdichte der Oberflächentextur. Dabei stehen beide Sensoren in einer festen relativen Beziehung zueinander, die sich über Standardmethoden der Photogrammetrie bestimmen lässt. Sie bildet die Grundlage für die rechnerische Übertragung von 2D-Tracking und Merkmalsextraktion auf die 3D-Geometrie. Ziel ist, in Echtzeit, bei sequenzieller 3D-Aufnahme, ein homogenes und rauschreduziertes dreidimensionales Gesamtmodell zu generieren.

Hohes Rauschen, nicht modellierte Systematiken und frequente Messausfälle verhindern das Funktionieren etablierter Registrierungsverfahren. Diese, nur auf 3D-Daten basierende Verfahren, berechnen eine Grobregistrierung über homologe 3D-Merkmalpunkte und eine Feinregistrierung über ICP. Im Rahmen der hier vorgestellten Lösung wurden Maßnahmen zur Rauschkompensation und Steigerung der Robustheit konzipiert und entwickelt. Die Registrierung wird aus 2D-Korrespondenzen geschätzt. Dazu werden über Merkmalsoperatoren bestimmte homologe Bildpunkte durch die relative Orientierung mit repräsentativen 3D-Punkten in Verbindung gebracht. Aus den repräsentativen 3D-Punkten wird eine räumliche Transformation geschätzt. Da mit einer Vielzahl von korrespondierenden Punkten geschätzt wird, sind Rauschen und Punktausfälle weniger problematisch. Die Gesamtregistrierung wird zur Steigerung der Robustheit und Genauigkeit über korrespondierende Ebenen vorgenommen. Dazu werden Ebenen im 3D mit einem eigens entwickelten Segmentierungsalgorithmus ermittelt und die Korrespondenz über Ebenen- und Punkthaufenähnlichkeit hergestellt. Die Ebenenregistrierung ist ein flächenbasierter Ansatz, dessen Zuverlässigkeit grundsätzlich gegenüber punktbasierten Ansätzen nicht von Punktvarianz beeinträchtigt wird.

1 Einleitung

Die Erzeugung von 3D-Datensätzen, sei es in Form von einfachen 3D-Punktwolken, Maschenmodellen oder texturierten Maschenmodellen, erfordert oft das Zusammenführen von Partialdatensätzen zu einem Gesamtdatensatz. Hauptfehlerquelle ist hierbei, dass die einzelne Datenaufnahme eines jeden Sensors in den seltensten Fällen vollständig ist. Durch die zentralperspektivische oder polare Aufnahme entstehen bei photogrammetrischen oder laserbasierten Aufnahmesystemen (Streifenlichtprojektion und terrestrisches Laserscanning) Abschattungen. Bei komplexen Oberflächengeometrien kann es darüber hinaus zu Selbstverdeckung kommen. Aus diesen Gründen sind mehrere Aufnahmen von unterschiedlichen Standpunkten aus notwendig. Jede dieser Aufnahmen erzeugt ohne vor- oder

nachbearbeitende Schritte Daten mit einem eigenen räumlichen Kontext. Um ein Objekt vollständig zu beschreiben, müssen diese Aufnahmen in einen Gesamtkontext überführt werden. Bei 3D-Daten, insbesondere Punktwolken, heißt dieses Verfahren Registrierung. Grundsätzlich lassen sich drei Ansätze für die Lösung des Registrierproblems skizzieren:

- Manuelle oder semiautomatische Registrierung über spezielle Signalisierungen (z.B. Kugeln)
- Tracking des Messsystems
- Registrierung über die Daten selbst

Der in diesem Artikel vorgestellte Algorithmus ist dem letzten Ansatz zu zuordnen.

Die Erzeugung eines Gesamt-3D-Datensatzes aus Partialdatensätzen ist nicht nur für den Bereich terrestrisches Laserscanning von Interesse, sondern auch bei der Prozesssteuerung in der Industrie (z.B. Bin Picking (IKEUCHI 1984)) und in der Robot Vision (z.B. Structure From Motion (WU 2011)). Der hier dargelegte Algorithmus zielt auf die Anwendung im Bereich der Prozesssteuerung ab, ist aber auf andere Anwendungsbereiche übertragbar.

Die Lösung des Registrierproblems über die Daten selbst stellt eine gewisse Anforderung an den Informationsgehalt. Diese beinhaltet, dass zwischen konsekutiven Aufnahmen in den Daten genug eindeutig identifizierbare homologe Merkmale auffindbar sind. Je nachdem, welche Art von Objekten aufgenommen wurde, ist der Informationsgehalt mehr oder weniger günstig.

Im 3D-Bereich finden sich Merkmale an Schnittpunkten von Oberflächen (FILIFE 2013). Daher ist eine Aufnahme von gleichförmigen, unstrukturierten Oberflächen arm an Merkmalen. In 2D-Bildaufnahmen finden sich Merkmalspunkte an kontrastreichen Stellen; Grauwertübergänge, die ihre Ursache in Lichtschatteneffekten oder Oberflächentextur haben. Aus diesem Grund finden sich in den 2D-Bildaufnahmen oft mehr Merkmale als in den 3D Aufnahmen des gleichen Objektes. Außerdem sind die Auflösungen gängiger 3D-Sensoren geringer, als bei gängigen 2D-Sensoren, was das Gleichgewicht des Informationsgehaltes zu Gunsten der 2D-Bilddaten verschiebt.

In dem hier vorgestellten Ansatz des kombinierten 2D/3D-Messsystems werden 3D-Daten durch informationsreichere 2D-Bilddaten ergänzt.

Darüber hinaus wird der Aspekt der Simultankalibrierung des Messsystems angesprochen. Die Simultankalibrierung ist Voraussetzung für den thematischen Schwerpunkt der Registrierung. Die Registrierung wird in zwei Stufen gegliedert. Die erste Stufe ist die Sequenzregistrierung, die den eigentlichen Diskussionsgegenstand darstellt. Die zweite, die Gesamtregistrierung, bietet eine beispielhafte Lösung zum Problem der verketteten Registrierung vieler Aufnahmen.

2 Lösungen zur Registrierung von Punktwolken

Zum Stand der Forschung werden zunächst etablierte Systeme zur dreidimensionalen Erfassung von Objektgeometrien aus den Bereichen der Computer Vision und dem industriellen Bereich betrachtet. Anschließend erfolgt ein Blick auf Lösungen aus der aktuellen Forschung in Bezug auf die Verwendung von Registrierverfahren.

1.1 Etablierte Systeme

Die dreidimensionale Erfassung von Objektgeometrien findet insbesondere im industriellen Kontext ein breites Spektrum an Einsatzmöglichkeiten. Systeme aus dem Hause Scape Technologies etwa leisten mit photogrammetrischen Komplettlösungen einen Beitrag zur Behebung der „Bin Picking“-Problematik. Im Bereich der flächenhaften 3D-Geometrieerfassung hat sich das Streifenlichtscanning in der Industrie zur stichprobenartigen Qualitätsprüfung etabliert (LUHMANN 2003). Darunter fällt beispielsweise das optische 3D-Messsystem IOS Kolibri. Die Systeme haben jedoch das Defizit, schwach strukturierte Objektgeometrien nicht verarbeiten zu können.

Ein weiterer Lösungsansatz zur Erfassung der Objektgeometrie ist das Structure from Motion Verfahren. Es findet seinen Ursprung in der Computer Vision, welche sich eingehend mit der automatischen Orientierung und Modellgenerierung von Bildern beschäftigt. Nachteil dieses Verfahrens ist die zum Teil sehr hohe Rechenzeit und die fehlende Zuverlässigkeit hinsichtlich der erzielbaren Resultate (KERSTEN ET AL. 2012). Das Programm VisualSFM ist eine Anwendung, welche auf Grundlage des genannten Verfahrens zur Rekonstruktion von 3D-Objekten eingesetzt wird (WU 2011). Die SFM Lösung ist als Offline/Post-Processing Lösung gedacht und kommt wegen der hohen Rechenzeit nicht für die Prozesssteuerung in Frage.

1.2 Etablierte Registrierverfahren

Zur Registrierung von 3D-Aufnahmen aus mittels Laserscanner generierten Punktwolken gibt es spezielle Ansätze. Einen solchen Ansatz stellt das Least Squares 3D Surface Matching (LS3D) von GRÜN & AKCA dar. Dabei erfolgt die Bestimmung der Parameter der 3D-Helmertransformations durch die Minimierung der euklidischen Distanz zwischen vermaschten Ausschnitten der zu registrierenden Punktwolken (GRÜN & AKCA 2012). Ferner besteht ein weiterer Ansatz zur Registrierung von 3D-Aufnahmen in der Erweiterung des von LOWE (2004) entwickelten SIFT Operators. SCOVANNER ET AL. (2007) stellen einen auf den dreidimensionalen Raum ausgeweiteten SIFT Merkmalsoperator zur Detektion von 3D-Features vor (FLITTON ET AL. 2010). Ein allgemeiner von RUSINKIEWICZ & LEVOY (2001) entwickelter Ansatz zum Zusammenführen von 3D-Daten ist ICP (Iterative Closest Point). Die Vorgehensweise zur Schätzung einer räumlichen Transformation aus einer zufälligen Stichprobe einer Untermenge der Punktwolken erfolgt dabei iterativ. Die Registrierung von 2D-Aufnahmen kommt unter anderem im Bereich der autonomen Roboternavigation zum Einsatz. Der SLAM Algorithmus (Simultaneous Localization and Mapping) nutzt beispielsweise Bildsequenzen zur Berechnung räumlicher Modelle, welche die Grundlage für die Navigation der Roboter bilden (KLEIN & MURRAY 2007).

Diese etablierten Registrierverfahren orientieren sich eher an dichten und rauscharmen 3D-Punktwolken, die ggf. auch noch vermascht sein sollten. ICP basierte Ansätze setzen eine gute Startsituation (Partialdatensätze in einem bereits genäherten gemeinsamen Kontext) voraus. Die akkurate Rekonstruktion der Objektgeometrie steht bei SLAM hinter der weniger präzisen Navigation an. Auch wenn die etablierten Ansätze der Lösungsdomäne nicht gerecht werden, so lassen sich dennoch Teilansätze als Startkonzepte für die eigene Entwicklung entnehmen.

3 Registrierung via 2D Korrespondenz

3.1 Kalibrierung des Stereosystems

Die Kalibrierung des Stereosystems ist für die Verwendung der Messwerte aus TOF- und Monochromkamera unabdingbar. Die gemeinsame Kalibrierung (Simultankalibrierung) der beiden Kameras erfordert die Identifizierung identischer Information für jedes Bildpaar der 3D- und Monochromkamera.

Geht man vom allgemeinen photogrammetrischen Abbildungsmodell aus, kann der Zusammenhang für beide Aufnahmesysteme, welche den gleichen Punkt $P=X$ sichten wie folgt formuliert werden:

$$\begin{aligned} X &= X_{0_1} + \lambda_1 R_1 \bar{x}_1 \\ X &= X_{0_2} + \lambda_2 R_2 \bar{x}_2 \end{aligned} \quad (1)$$

Die Gleichungen (1), welche die Strahlen beider Kameras zum selben Objektpunkt beschreiben, sind in diesem Fall voneinander unabhängig. Eine Abhängigkeit und somit Stützung der Geometrie des Gesamtsystem erhält man mit der Einführung einer gegenseitigen Orientierung der Systeme. Die gegenseitige Beziehung zwischen den Projektionszentren O_1 und O_2 zweier Kameras kann allgemein mit der Vektoraddition verdeutlicht werden. Dabei lässt sich der Vektor zum zweiten Projektionszentrum über den Vektor zum ersten und den dazwischenliegenden Basisvektor mit dessen Richtungsinformation R_1 darstellen:

$$X_{0_2} = X_{0_1} + R_1 B \quad (2)$$

Die Orientierung R_2 des zweiten Projektionszentrums O_2 kann wiederum durch die des ersten R_1 mit der relativen Orientierung R_{rel} ausgedrückt werden:

$$R_2 = R_1 R_{rel} \quad (3)$$

Durch Substituierung erhält man:

$$X = X_{0_1} + R_1 (B + \lambda_2 R_{rel} \bar{x}_2) \quad (4)$$

Damit ist eine direkte Abhängigkeit zweier Strahlgänge (von TOF- und Monochromkamera) zum gleichen Objektpunkt über die relative Orientierung gegeben. Diese wird im Rahmen einer Bündelausgleichung geschätzt.

Die starre Basis zwischen den Aufnahmesystemen stützt die Gesamtgeometrie und wirkt sich zudem positiv auf die Genauigkeit der Bestimmung der inneren Orientierung der 3D-Kamera aus.

3.2 Sequenzregistrierung

Die Sequenzregistrierung ist eine Verknüpfung konsekutiver Aufnahmen ohne Grob-/Vorregistrierung, bei der Aufnahmepaare aufeinander verortet werden. Für eine Registrierung sind homologe 3D-Punkte notwendig, um eine räumliche Transformation ermitteln zu können.

Als erstes findet die Bestimmung homologer Punkte statt. Eingangs werden in den beiden Bildern der Monochromkamera Merkmalspunkte anhand von Features detektiert.

Es wurden die gängigen Feature-Operatoren auf Maßstabs- und Rotationsinvarianz und Empfindlichkeit auf Beleuchtungsunterschiede untersucht. Verglichen wurden SIFT (LOWE 1999), SURF (BAY ET AL. 2008), MSER (MATAS 2004) und ORB (RUBLEE 2011). Der SURF-Operator, der eine verbesserte Version des grundlegenden SIFT-Operators ist, kristallisierte sich als Favorit heraus, da er das Optimum von Laufzeitverhalten und Robustheit in sich vereint.

Nach dem die Feature-Punkte in beiden Bildern der Sequenz detektiert wurden, schließt sich die Korrespondenzsuche homologer Features an. Für die Suche wird eine einfache Nearest-Neighbour-Distance-Ratio (MIKOLAJCZYK 2005) Suche im Merkmalsraum benutzt. Dieser Algorithmus betrachtet den nächst- und zweitnächstgelegenen Nachbarn und berechnet das Verhältnis zueinander. Damit ist das Verfahren eindeutiger und zuverlässiger, als eine einfache Nearest-Neighbour Betrachtung. Daraus resultieren innerhalb eines Sequenzpaares im Merkmalsraum korrespondierende 2D Features. Diese können noch Fehlzuordnungen enthalten. Eine zusätzliche Filterung wird mit Hilfe der Fundamentalmatrixschätzung durchgeführt (HARTLEY 2003). Durch diese Schätzung werden Fehlzuordnungen weitestgehend eliminiert.

Die Zuverlässigkeit wurde überprüft, in dem das Korrespondenzverhalten über eine größere Sequenz analysiert wurde (vgl. Tabelle 1).

Tabelle 1: Matching korrespondierender Features in Bildpaaren mit wachsendem Sequenzabstand

Bildkombination	Matches	Outlier	Inlier	Outlier (%)	Inlier (%)
1 und 2	861	607	254	70,5	29,5
1 und 3	705	605	100	85,8	14,2
1 und 4	561	471	90	84,0	16,0
1 und 5	531	449	82	84,6	15,4
1 und 6	561	499	62	88,9	11,1

Wie zu erwarten sinkt die Anzahl der Punktkorrespondenzen mit wachsendem Sequenzabstand, dennoch finden sich ausreichend Punkte zur Bestimmung der räumlichen Transformation.

Nun folgt der Prozess der Bestimmung homologer 3D Punkte. Genutzt wird hierfür die 2D-3D-Korrespondenz. Dazu werden zunächst die zeitgleich zu den Bildern aufgenommenen Punktwolken der TOF-Kamera über die relative Orientierung in das System der 2D-Kamera transformiert. Mit der aus der Simultankalibrierung bestimmten inneren Orientierung werden nun die 3D-Punkte ins Bild projiziert.

Die in die 2D-Kamera projizierten Punkte behalten ihre 3D-Information bei. Über eine einfache Nearest-Neighbour-Suche mit Grenzwert wird zu jedem homologen Feature-Punkt ein projizierter 3D-Punkt gesucht. Somit erhält man korrespondierende 3D-Punkte (Pass-

punkte) in etwa der Genauigkeit der Punktwolkenauflösung. Diese wiederum gelten als Beobachtungen für die darauffolgende Helmerttransformation im 3D.

$$\mathbf{X}_i = \mathbf{X}_0 + \lambda \mathbf{R} \mathbf{x}_i \quad (5)$$

Die Überbestimmung der Beobachtungen in beiden Punktwolken führt zu einem nichtlinearen Ausgleichsproblem, bei dem die Koordinaten im Start-, sowie im Zielsystem als Beobachtungen eingehen.

$$\begin{bmatrix} X_i + v_{x_i} \\ Y_i + v_{y_i} \\ Z_i + v_{z_i} \end{bmatrix} = \begin{bmatrix} X_0 \\ Y_0 \\ Z_0 \end{bmatrix} + \lambda \begin{bmatrix} r_{11} & r_{12} & r_{13} \\ r_{21} & r_{22} & r_{23} \\ r_{31} & r_{32} & r_{33} \end{bmatrix} \begin{bmatrix} x_i + v_{x_i} \\ y_i + v_{y_i} \\ z_i + v_{z_i} \end{bmatrix} \quad (6)$$

Die Schätzung der Transformationsparameter erfolgt hierbei im nichtlinearen verallgemeinerten Gauß-Helmert-Modell (GHM) (NEITZEL 2009). Die so geschätzte Transformation registriert die Punktwolken im Bereich der Punktwolkengrundgenauigkeit aufeinander.

3.3 Gesamtregistrierung

Der Gesamtregistrierschritt dient zur gemeinsamen Ausgleichung einer Sequenz von Aufnahmen, welche zuvor die Sequenzregistrierung durchlaufen haben. Ziel dabei ist es, die Punktwolken in ein gemeinsames übergeordnetes Koordinatensystem zu transformieren. Zudem wird die Fehlerfortpflanzung der Sequenz durch dieses Vorgehen weitestgehend kompensiert. Anders als bei Registrierungen, welche Punktidentitäten nutzen, werden korrespondierende Ebenen zur Transformationsschätzung herangezogen. Die Ebene hat gegenüber anderen geometrischen Primitiven den entscheidenden Vorteil, dass sie von einer Perspektive aus vollständig zu erfassen ist. Bedingt durch den geringeren Einfluss des Rauschens der Punktwolke auf die Ebenenschätzung und somit auch auf die Bestimmung der Transformationsparameter, wird zudem eine bessere Genauigkeit als bei der Verwendung von Punktkorrespondenzen erreicht (GIELSDORF 2009).

Zur automatisierten Detektion und Zuordnung der Ebenen wurden verschiedene Algorithmen miteinander verknüpft. So erfolgte die Segmentierung der Punktwolken in einzelne Ebenen durch die Kombination verschiedener Clusteralgorithmen. Dabei wurde in einem ersten Schritt eine k-means Clusteranalyse anhand der Punktnormalen durchgeführt (HARTIGAN & WONG 1979).

Als Resultat dieser Clusteranalyse erhält man Cluster mit ähnlichen Punktnormalen. Zur Ermittlung der einzelnen Ebenen innerhalb der im Vorfeld bestimmten Cluster erfolgt in einem weiteren Schritt eine von ESTER ET AL. (1996) entwickelte dichte-basierte Clusteranalyse (DBSCAN). Somit werden die durch Punktnormalen zusammengefassten, jedoch räumlich voneinander unabhängigen Ebenen detektiert.

Die anschließende Zuordnung erfolgt über die euklidische Distanz zwischen den einzelnen Ebenenschwerpunkten in den bereits durch die Sequenzregistrierung übereinander gebrachten Punktwolken. Pro Standpunkt (für jede Punktwolke) wird eine räumliche Orientierung über eine Bündelausgleichung bestimmt.

4 Test-Ergebnisse

Zum Testen des Algorithmus wurde als Szenario die Depalettierung von Kisten (min. 10x10x10cm) gewählt. Dafür wurde das Messsystem auf das Messvolumen abgestimmt und die Simultankalibrierung durchgeführt.

Tabelle 2: Ergebnisse aus der Simultankalibrierung

Standardabweichung der Gewichtseinheit		$\sigma_0 = 0.05$ $S_0 = 0.02$
Bildmessgenauigkeit	Monochrom Kamera	$rms_{x,y} = 0.117\mu\text{m} \approx \frac{1}{50} \text{Pixel}$
	ToF Kamera	$rms_{x,y} = 2.500\mu\text{m} \approx \frac{1}{16} \text{Pixel}$
RMS der Objektpunkte		$rms_X = 2,4\mu\text{m}$ $rms_Y = 2,4\mu\text{m}$ $rms_Z = 3,7\mu\text{m}$
RMS der Basis		$rms_{B_x} = 37\mu\text{m}$ $rms_{B_y} = 35\mu\text{m}$ $rms_{B_z} = 126\mu\text{m}$

Die Ergebnisse der Kalibrierung finden sich in der Tabelle 2 wieder und liegen im Bereich der zu erwartenden Genauigkeit. Die Abweichungen im 3D sind weit unter der Genauigkeit der 3D-Aufnahmen (ca. 7,5 mm).

Für den eigentlichen Test wurde per Hand eine Sequenz von 3D- und Bilddaten aufgenommen. Zuerst wurde die Registriergenauigkeit untersucht. Anschließend wurde betrachtet, wie sich der Algorithmus verhält, wenn sich der zeitliche und räumliche Abstand zur Nullmessung vergrößert. Dazu wurde der mittlere Abstand einer Stichprobe zufälliger Punkte vor und nach der Registrierung verglichen. Zusätzlich wurde das quadratische Mittel der Residuen an den für die Transformation benutzen 3D-Punkten betrachtet.

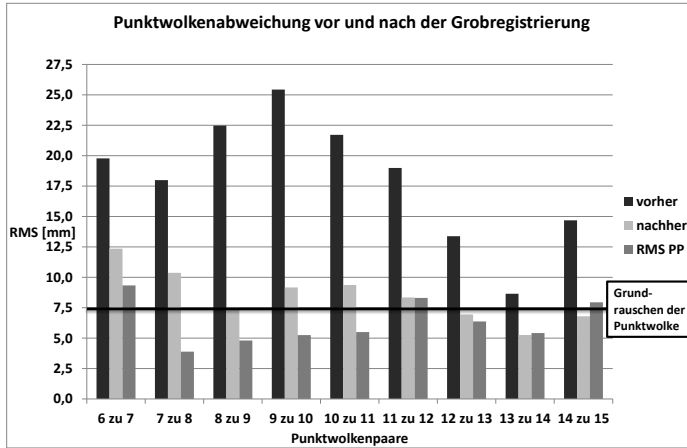


Abb. 1: Genauigkeit Sequenzregistrierung mit mittlerer Abweichung der Passpunkte (PP)

Wie aus Abbildung 1 ersichtlich, erreicht die Sequenzregistrierung ein Zusammenführen der Punktwolken mit der Genauigkeit des Grundrauschens.

Für die Betrachtung der Registrierung mit wachsendem Sequenzabstand wurde statt zufälliger Punkte ein markanter Punkt manuell herausgesucht. Dieses Vorgehen wurde gewählt, da es bei größeren Sequenzabständen zu Fehlern bei der Berechnung des quadratischen Mittels der Distanz aus einer Stichprobe zufälliger Punkte kommt. Die Ursache liegt in der steigenden Wahrscheinlichkeit, dass bei der Stichprobenkorrespondenz Fehlzusammenordnungen stattfinden. Wie aus der Abbildung 2 zu entnehmen ist, wirkt sich ein größerer Sequenzabstand nicht negativ auf die Qualität der Registrierung aus.

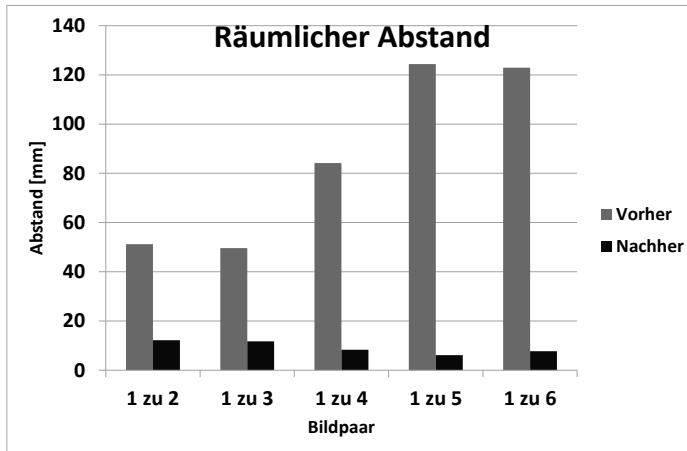


Abb. 2: Abstand eines gewählten Objektpunktes vor und nach der Sequenzregistrierung mit wachsendem Sequenzabstand

Zusätzlich wurde ein Vergleichstest mit ICP basierten Werkzeugen durchgeführt: (CloudCompare & Geomagic Studio). Dabei zeigte sich, dass die auf ICP basierenden Ansätze bei großen Sequenzabständen oder Ebenengeometrien auf falsche Ergebnisse kommen.

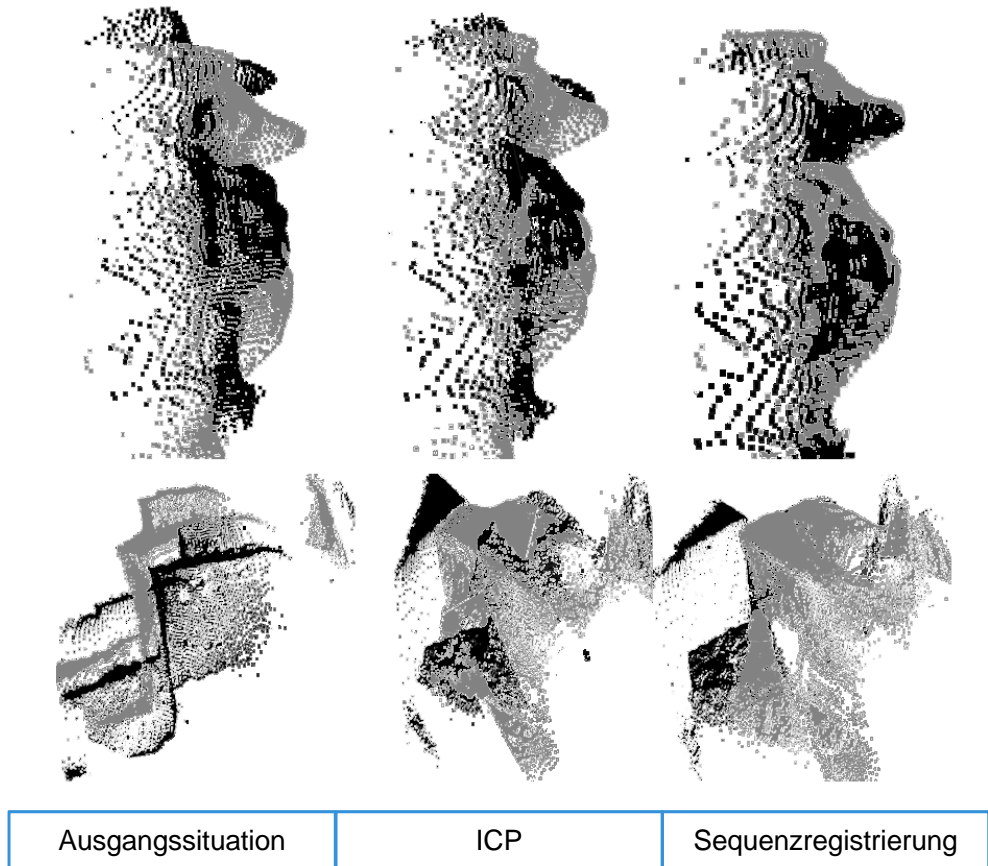


Abb. 3: Vergleich Sequenzregistrierung versus ICP

Dass der ICP unter bestimmten Voraussetzungen zu einem falschen Registrierergebnis kommt, lässt sich mit folgendem Sachverhalt erklären. Die Registrierung via ICP erfolgt durch eine iterative Schätzung aus einer zufälligen Stichprobe von Punkten in der Quellpunktwolke. Über eine Nearest-Neighbor Betrachtung der Stichprobe werden in der Zielpunktwolke korrespondierende Punkte gesucht. Diese Korrespondenzen werden zur Schätzung einer Transformation herangezogen. Überdecken sich die Punktwolken an einer nicht-homologen Stelle, werden falsche Korrespondenzen und damit eine falsche Transformation geschätzt. Daraus resultiert, dass ICP auf ein lokales Minimum konvergiert.

Ein wesentlicher Vorteil der Sequenzregistrierung liegt in der Tatsache, dass Merkmale mit einem größeren Informationsgehalt einen Punkt beschreiben, als es der räumliche Abstand zu vollbringen vermag.

5 Fazit

Die Tests zeigen, dass der entwickelte Algorithmus über die 2D-Korrespondenz 3D-Datensätze vereinen kann, ohne dass eine manuelle Grobregistrierung durchgeführt werden muss oder dass geringe Punktdichte verbunden mit hohem Rauschen Probleme bereitet. Das Ziel, ein robustes Registrierungsverfahren zu entwickeln, wurde erreicht.

Eine Weiterentwicklung in Richtung Laufzeitverhalten mit dem Ziel einer Echtzeitanwendung ist denkbar. Auch empfiehlt es sich, zusätzliche Strategien bei der Sequenzregistrierung zu implementieren, die bei denkbar ungünstigen Bildaufnahmebedingungen den Algorithmus unterstützen. Weiterhin sind andere Ansätze für die Gesamtregistrierung denkbar. Ein Ansatz, der auf gekrümmten Oberflächen in Form von Superquadriken funktioniert, würde die Einsatzmöglichkeiten erweitern.

Durch die Weiterentwicklung der 3D-Sensoren in Sachen Qualität, Kompaktheit, Schnelligkeit und niedrigerer Anschaffungskosten, lässt sich der Algorithmus auf andere Anwendungen zukünftig übertragen. Auch ist damit ein skalierbares Messvolumen und höhere Grundgenauigkeit realisierbar.

6 Danksagung

Diese Arbeit wurde von der Stiftung Rheinland-Pfalz für Innovation unter dem Förderkennzeichen (FKZ) 152202-386261/558 gefördert, was von den Autoren geschätzt wird. Für die gute Zusammenarbeit möchten wir uns bei unseren Kooperationspartnern aus Mainz, der Metronom Automation GmbH und Hirata Engineering Europe GmbH, bedanken.

Literatur

- Gielsdorf, F. (2009): *Ebenendetektion, Matching und verkettete Transformation von Laserscans*. Allgemeine Vermessungs-Nachrichten, 11-12/2009, S. 391-395.
- Neitzel, F. & Johannes, L. (2009): *Anwendung des tachymetrischen Laserscannings in der Überwachung eines historischen Bauwerkes*. Photogrammetrie - Laserscanning - Optische 3D-Messtechnik, C. Müller, Ed. Heidelberg: Herbert Wichmann Verlag, S. 127-136.
- Luhmann, T. (2003): *Nahbereichsphotogrammetrie*, Wichmann Verlag 2. Auflage 2003, ISBN 3-87907-398-8
- Kersten, T. P., Lindstaedt, M., Mechelke, K., Zobel, K. (2012): *Automatische 3D-Objektrekonstruktion aus unstrukturierten digitalen Bilddaten für Anwendungen in Architektur, Denkmalpflege und Archäologie*. Publikationen der Deutschen Gesellschaft für Photogrammetrie, Fernerkundung und Geoinformation e.V., Band 21, Hrsg. E. Seyfert, 32., S. 137-148, ISSN 0942-2870
- Wu, C. (2011): *VisualSFM: A Visual Structure from Motion System*. <http://ccwu.me/vsfm/>
- Gruen, A. & Akca, D. (2012): *Least Squares 3D Surface Matching*. International Archives of the Photogrammetry, remote Sensing and Spatial Information Sciences (Bd. XXXIV).
- Westfeld, P. (2012): *Geometrische und stochastische Modelle zur Verarbeitung von 3D-Kameradaten am Beispiel menschlicher Bewegungsanalysen*. Verlag der Bayerischen Akademie der Wissenschaften in Kommission beim Verlag C. H. Beck, ISBN 978-3-7696-5099-0
- Rusinkiewicz, S. & Levoy, M. (2001): *Efficient Variants of the ICP Algorithm*. Third International Conference on 3D-Digital Imaging and Modeling (3DIM)
- Klein, G. & Murray, D. (2007): *Parallel Tracking and Mapping for Small AR Workspace*. International Symposium on Mixed and Augmented Reality (ISMAR)
- Bay, H., Ess, A., Tuytelaars, T., Van Gool, L. (2008): *SURF: Speeded Up Robust Features*. Computer Vision and Image Understanding (CVIU), Vol. 110
- Scovanner, P., Saad, A., Mubarak, S. (2007): *A 3-dimensional sift descriptor and its application to action recognition*. Proceedings of the 15th International Conference on Multimedia 2007 September 24-29, Augsburg, Germany, S. 357-360, ISBN 978-1-59593-702-5
- Lowe, D.G. (2004): *Distinctive image features from scale-invariant keypoints*. International Journal of Computer Vision, 60, 2 (2004), S. 91-110.
- Lowe, D. G. (1999): *Object Recognition from Local Scale-Invariant Features*. Proceedings of the International Conference on Computer Vision, S. 1150-1157, Corfu, Greece.

- Mikolajczyk, K. & Schmid, C. (2005): *A Performance Evaluation of Local Descriptors*. Journal IEEE Transactions on Pattern Analysis and Machine Intelligence, Vol. 27, Issue 10, Oktober 2005, S. 1615–1630.
- Flitton, G., Breckon, T., Megherbi Bouallagu, N. (2010): *Object Recognition using 3D SIFT in Complex CT Volumes*. Proceedings of the British Machine Vision Conference, S. 11.1-11.12, BMVA Press
- Filipe, S. & Alexandre, L. A. (2013): *A Comparative Evaluation of 3D Keypoint Detectors*. Confele 2013, S. 145-148, Castelo Branco, Portugal.
- Hartigan, J. A. & Wong, M. A. (1979): *A K-Means Clustering Algorithm*. Journal of the Royal Statistical Society, Series C (Applied Statistics), 28, S. 100–108.
- Ester, M., Kriegel, H., Sander, J., Xu, X. (1996): *A density-based algorithm for discovering clusters in large spatial databases with noise*. Proceedings of the Second International Conference on Knowledge Discovery and Data Mining (KDD-96). AAAI Press, ISBN 1-57735-004-9, S. 226–231.
- Ikeuchi, K., Horn, B., Nagata, S., Callahan, T., Feingold O. (1984) *Picking up an object from a pile of objects*. Robotics Research: The First International Symposium. MIT Press, 1984.
- Matas, J., Chum, O., Urban, M., Pajdla, T. (2004): *Robust Wide-Baseline Stereo from Maximally Stable Extremal Regions*. Image and Vision Computing, 22(10), S. 761-767.
- Rublee, E., Rabaud, V., Konolige, K., Bradski, G. (2011): *ORB: an efficient alternative to SIFT or SURF*. Proceedings of the IEEE International Conference on Computer Vision, Barcelona, Spain.
- Hartley, R., Zisserman, A. (2003): *Multiple View Geometry in Computer Vision*. Cambridge University Press.