

Kamera-Kalibrierung für optische Messaufgaben mit erweiterter Berechnung und Bewertung

Steffen Reichel*, Jan Burke**, Alexey Pak**

*Hochschule Pforzheim, Tiefenbronner Str. 65, D-75175 Pforzheim

**Fraunhofer-IOSB, Fraunhoferstraße 1, D-76131 Karlsruhe

<mailto:steffen.reichel@hs-pforzheim.de>

Digitalkameras für Messaufgaben benötigen eine gute Kamerakalibrierung. Wir präsentieren einen neuen Vorschlag zur objektiven Kamerakalibrierung basierend auf machine learning Ansätzen. Dazu wird zusätzlich neben dem re-projection error (Standard) ein neues Gütemaß, der forward projection error eingeführt. Erste Ergebnisse zeigen die Nützlichkeit dieses neuen Ansatzes.

1 Einführung

Digitale Kameras sind in der berührungslosen Oberflächenmessung und -prüfung nicht mehr wegzudenken. Dem Lochkamera-Modell werden nach Wunsch Parameter für Verkippung, Verzeichnungen und Verzerrungen hinzugefügt. Aus einer Serie von Bildern eines Referenzmusters werden dann eine Kameramatrix und die Verzerrungsparameter berechnet.

In der hierfür häufig und auch von uns benutzten Software OpenCV haben die Hauptmodelle 5 oder 14 Parameter. Die Kriterien für die Zuverlässigkeit einer Kalibrierung sind noch unklar: weder ist bekannt, welche Parameter welche Unsicherheiten haben müssen, um eine gewünschte „Qualität“ zu erreichen, noch wie viele Bilder dafür gebraucht werden. OpenCV errechnet zur Bewertung der Unsicherheit den re-projection error (RPE), dessen alleinige Verwendung aber nicht zu überzeugenden und zuverlässigen Ergebnissen führt.

Um zu besser nachvollziehbaren Unsicherheitsbewertungen zu kommen, führen wir zusätzlich den forward projection error (FPE) ein. Außerdem mussten die Bewertungsmethoden verbessert werden. Wir haben Trainings- und Testmethoden aus dem Machine Learning (ML) verwendet und stellen Ergebnisse aus Simulation und Experiment vor, um deren Nützlichkeit einzuschätzen.

2 Kamera-Modelle

Wir benutzen das Kamera-Modell aus OpenCV [1], das auf dem Lochkamera-Modell basiert. Mittels einer Kameramatrix und Verzerrungs- und Verzeichnisparametern wird dann weiterhin das Lochkameramodell verfeinert. Das Kameramodell mit der Kameramatrix und 5 Verzerrungsparametern bezeichnen wir als Modell A, das Modell mit bis zu 14 Verzeichnisparametern als Modell B. Die entsprechenden Gleichungen sind [1] zu entnehmen. Die drei Koordinatensysteme zeigt Abb. 1.




Abb. 1 Die drei Kamerakoordinatensysteme zur Kamera-Kalibrierung mit Sichtstrahl (view ray).

3 Gütemaße RPE und FPE

Mittels einer phasenschiebenden Streifenmethode werden auf einem Bildschirm (3D Weltobjekt) Muster erzeugt, aus denen die zugehörigen Abbildungspunkte in Welt- und Bildsensorkoordinaten erzeugt werden [2][3]. Der RPE beschreibt die Abweichung des bekannten Punkte $(u, v)^T$ zu dem mit Modell A oder B berechneten Punkt $(\tilde{u}, \tilde{v})^T$ auf dem Bildsensor. Der neu eingeführte FPE beschreibt die Abweichung im realen 3D Bild, also in Weltkoordinaten. Dazu muss der bekannte Punkt $(u, v)^T$ des Bildsensors mittels der berechneten Verzerrungsparameter in die 3D-Welt projiziert werden und ergibt den berechneten Punkt $(\tilde{x}_w, \tilde{y}_w, \tilde{z}_w)^T$, der mit dem bekannten 3D Weltpunkt $(x_w, y_w, z_w)^T$ verglichen wird. Abb. 2 zeigt beide Gütemaße.




Abb. 2 Der RPE und FPE als Gütemaß.

Aus den Abweichungsvektoren werden dann die absoluten Fehler für jeden Bildpunkt i bestimmt:

$$RPE_i := |\vec{\Delta}_{u,i}| = \sqrt{(\tilde{u}_i - u_i)^2 + (\tilde{v}_i - v_i)^2} \quad (1)$$

$$FPE_i = \sqrt{(\tilde{x}_{W,i} - x_{W,i})^2 + (\tilde{y}_{W,i} - y_{W,i})^2 + (\tilde{z}_{W,i} - z_{W,i})^2} \quad (2)$$

Abb. 2 zeigt die Verteilung des FPE für eine Pose.




Abb. 3 FPE Vektoren (links) und FPE Histogramm für eine Pose mit insgesamt 4991 Einzelpunkten.

Im Intervall $0 \leq \overline{FPE} + 2\sigma$ befinden sich 95,0 % der FPE Abweichungen (\overline{FPE} : Mittelwert, σ = FPE Standardabweichung). Gleiches gilt auch für den RPE.

4 ML Ansatz

Mit dem FPE als objektives Gütemaß in den 3D Weltkoordinaten wurde mittels "Train, Validation and Test Sets" [4] ein ML Ansatz erprobt. Dies ermöglicht eine objektive Abschätzung der Kamerakalibrierqualität. In der Validierung werden die Hyperparameter verändert (hier Modell A, Modell B) und wegen dieser Einfachheit wird dieser Schritt nicht benötigt. Somit wird das Modell trainiert und anschließend getestet. Das Vorgehen ist wie folgt (bestimmt werden die Gütemaße RPE und FPE):

1. Benutze ~70% der Posen zur Bestimmung der Kameramatrix und Verzeichnisparameter;
2. Teste mit den Parametern die restlichen 30% der Posen;
3. Durchlaufe Punkte 1. und 2. zehn Mal und würfle bei jedem Durchlauf die verwendeten Posen für 1.

5 Messungen und Ergebnisse

0. Durchlauf	average distance per view RPE	Pose	av. uv dist err [pxl]	std dev. [pxl]
Train-Posen		00	2,024	1,056
		01	2,147	1,075
		02	0,368	0,252
		03	4,875	2,681
		04	0,695	0,475
		05	2,544	1,344
		06	1,562	0,843
		07	2,443	1,710
		08	0,451	0,275
		09	1,670	0,919
		10	0,783	0,494
		11	1,662	0,942
		12	0,734	0,411
		13	4,425	2,358
		14	0,414	0,245
		15	0,445	0,283
		16	1,708	0,916
		17	2,129	1,156
		18	1,886	1,012
		19	0,411	0,258
		20	0,385	0,246
	Average distance RPE	Mean:	1,608	0,903

Abb. 4 RPE von Durchlauf 1 des Trainings.

Unser 3D Weltobjekt war ein flacher 55" Monitor mit 1920 x 1080 Pixel (Pixelgröße ~0,63 mm), die 5,1 MP Kamera hat 3,45 µm Pixelgröße mit einem F#=4,0 Objektiv (2% Verzeichnung laut Hersteller) und 8,0 mm Brennweite. In einem ersten Versuch

wurden 28 Posen (mit jeweils 4 Einzelbildern) bei den Abständen ~10cm, ~25cm, ~100cm, ~250cm aufgenommen. Abb. 4 zeigt die Trainingsergebnisse des RPE. Rot markiert sind Posen, bei denen der RPE deutlich über dem Mittelwert aller Posen liegt und daher unwahrscheinlich ist. Es stellte sich heraus, dass dies die ganz nahen Posen mit ca. 10cm Abstand sind, wo z.B. Moiré-Muster als Störungen auftraten. Diese Posen liefern keine „guten“ Beiträge zur Kamerakalibrierung und wurden daher aus dem Kalibrierprozess entfernt. Mit den „guten“ Posen wurden nun die Modelle A und B (5 / 14 Verzerrungsparameter) mit Hilfe des ML-inspirierten Ansatzes verglichen, siehe Abb. 5. Bei der hier verwendeten Messung hat keines der beiden Modelle einen Vorteil – dies muss für präzisere Messungen nicht immer so sein (Modell B hat jedoch eine ca. 10 fach längere Rechenzeit).

Training	Run	RPE [pxl]	std RPE [pxl]	FPE [mm]	std FPE [mm]
	0	1,054	0,588	0,306	0,183
	1	1,075	0,599	0,303	0,182
	2	1,038	0,584	0,298	0,178
	3	0,913	0,525	0,309	0,189
	4	1,212	0,669	0,288	0,169
	5	0,955	0,544	0,327	0,200
	6	1,158	0,649	0,299	0,180
	7	1,109	0,622	0,317	0,188
	8	1,113	0,617	0,298	0,177
	9	1,111	0,626	0,298	0,180
	mean	1,074	0,602	0,304	0,183

Training	Run	RPE [pxl]	std RPE [pxl]	FPE [mm]	std FPE [mm]
	0	1,138	0,635	0,293	0,173
	1	1,033	0,583	0,301	0,179
	2	0,970	0,547	0,323	0,194
	3	1,138	0,634	0,297	0,175
	4	0,977	0,550	0,306	0,185
	5	1,068	0,607	0,313	0,187
	6	1,148	0,642	0,292	0,175
	7	0,971	0,543	0,317	0,187
	8	1,092	0,609	0,312	0,184
	9	1,214	0,667	0,295	0,173
	mean	1,075	0,602	0,305	0,181

Abb. 5 Ergebnisvergleich (RPE und FPE, jeweils Mittelwerte und Standardabweichungen) für Modelle A (oben) und B (unten) bei der hier verwendeten Messung.

6 Zusammenfassung

Der neu eingeführte FPE erlaubt den Gütevergleich in realen 3D Weltkoordinaten und bietet daher einen objektiven Ansatz für Messaufgaben. Mit Hilfe des ML inspirierten Ansatzes können Unsicherheiten der Messungen posenweise angegeben und damit die Kamerakalibrierung objektiviert und verbessert werden. Auch die verschiedenen Kamera-Modelle können bewertet und verglichen werden.

Literatur

- [1] OpenCV: „Camera Calibration and 3D Reconstruction“, (Zugriff:19.10.2021) - siehe: docs.opencv.org/4.5.3/d9/d0c/group_calib3d.html
- [2] C. Zuo, S. Feng et al, „Phase shifting algorithms for fringe projection profilometry: A review“ in: Optics & Lasers in Engineering 109, 23-59 (2018)
- [3] A. Pak, „The concept of smooth generic camera calibration for optical metrology“ in: tm – Technisches Messen, 25-35 (2016)
- [4] T. Hastie, R. Tibshirani, J. Friedman, *The Elements of Statistical Learning - Data Mining, Inference, and Prediction*, (2nd Ed., Springer 2017)