

Punkt- und ebenenbasierte Detektion von Ecken und Kanten in Innenraum-Punktwolken

JAKOB SCHMIDT¹, ANDREAS EICHHORN¹ & DOROTA IWASZCZUK²

Zusammenfassung: In dieser Arbeit werden ein konturpunkt-basierter und ein ebenenbasierter Ansatz zur Extraktion von Kanten und Ecken aus Innenraumpunktwolken untersucht. Dabei liegt der Fokus auf der Detektion verdeckter Kanten und Ecken. Der ebenbasierte Ansatz erweist sich robuster gegenüber stark verrauschten und unvollständigen Punktwolken. Der punkt-basierte Ansatz erscheint durch die Verwendung lokaler Nachbarschaft zuverlässiger in komplexen Räumen. Beide Ansätze ermöglichen die Erfassung verdeckter Kanten. Der ebenbasierte Ansatz liefert dabei ein vollständigeres Ergebnis. Beide Ansätze erzeugen eine Übererfassung von Ecken und Kanten, daher ist eine Erweiterung der Ansätze zur Filterung und Verknüpfung der Ecken und Kanten sowie zur Darstellung als 3D-Modell notwendig.

1 Einleitung

Zur Erfassung von Gebäudebeständen werden häufig Laserscanning und Photogrammetrie eingesetzt. Dabei werden große Datenmengen mit vielen Punkten erzeugt. Diese sind in der Regel unstrukturiert und werden als Basis für die Modellierung z. B. eines Building Information Models (BIM) verwendet (LÓPEZ IGLESIAS et al. 2020). Im Gegensatz dazu werden bei einer klassischen tachymetrischen Objektvermessung Ecken direkt gemessen. Die Oberflächen werden dabei auf die minimal notwendigen Punkte beschränkt. Die Ecken werden bei der Messung durch den Anwender manuell in Beziehung zueinander und zu den beschriebenen Objekten gesetzt. Um vergleichbare Informationen aus photogrammetrischen und Laserscanning-Punktwolken zu gewinnen, ist es notwendig Informationen über Objekte und deren Beziehungen zueinander zu extrahieren. Im Folgenden werden zwei Ansätze zur Extraktion von Ecken und Kanten aus Punktwolken von Innenräumen betrachtet und verglichen. Dabei basiert eines auf der Detektion von Ebenen (SCHNABEL et al. 2007) und das andere auf der Detektion von Konturpunkten (AHMED et al. 2018).

2 Problemstellung

Die Erfassung von Innenräumen über photogrammetrische Verfahren und Laserscanning ermöglicht eine schnelle und vollständige Erfassung von Gebäuden in Form von Punktwolken. Aus diesen Daten Innenraummodellen auf manuelle Weise zu erzeugen ist sehr arbeits- und zeitaufwändig. Deshalb ist die automatische Extraktion von Ecken und Kanten zur Verarbeitung von Punktwolken essenziell für die Erfassung von Innenräumen als 3D-Modelle (LÓPEZ IGLESIAS et al. 2020).

¹ Technische Universität Darmstadt, Fachgebiet Geodätische Messsysteme und Sensorik, Franziska-Braun-Straße 7, D-64287 Darmstadt, E-Mail: Jakob.Schmidt1@tu-darmstadt.de, eichhorn@geod.tu-darmstadt.de

² Technische Universität Darmstadt, Fachgebiet Fernerkundung und Bildanalyse, Franziska-Braun-Straße 7, D-64287 Darmstadt, E-Mail: Dorota.Iwaszczuk@tu-darmstadt.de

Dieser Arbeit liegt die Idee zugrunde, Ecken und Kanten in Innenraum-Punktwolken zu erfassen und die Beziehungen dazwischen zu bestimmen. Dabei soll eine polygonisierte Darstellung von Innenräumen mit einem Ansatz, der es ermöglicht, verdeckte Kanten und Ecken zu erfassen, umgesetzt werden. In aktuellen Publikationen wird dafür unter anderem Deep Learning verwendet. Abhängig vom Verfahren wird dabei davon ausgegangen, dass Ecken im Raum in einer Punktwolke repräsentiert sind, wodurch Verdeckungen nicht berücksichtigt werden können (LIU et al. 2021). Passende Trainingsdatensätze mit verdeckten Kanten, um ein entsprechendes Netz zu trainieren, sind den Autoren bisher nicht bekannt. Die Beschaffung solcher Trainingsdaten wäre zeitaufwändig. Um diesem Problem auf andere Weise zu begegnen, werden in dieser Arbeit zwei geometrische Ansätze zur Extraktion von Ecken und Kanten aus Innenraum-Punktwolken betrachtet und verglichen. Diese sind grundsätzlich geeignet, um verdeckte Kanten zu bestimmen und benötigen keine Trainingsdaten. Der erste Ansatz basiert auf der Detektion von Konturpunkten, der zweite auf der Detektion von Ebenen. Der erste wird im Folgenden als punktbasiert und der zweite als ebenbasierter Ansatz bezeichnet. Der Fokus der polygonisierten Darstellung der Innenraumgeometrie liegt dabei auf Wänden, Decken und Böden. Dabei wird untersucht, welcher Ansatz sich besser eignet und welche Vor- und Nachteile in Bezug auf Vollständigkeit und Korrektheit bestehen. Diese Untersuchung dient als Grundlage für die Entwicklung eines Konzepts zur Erfassung von Innenräumen, welches kein Deep Learning benötigt.

3 Verwandte Arbeiten

Für die Extraktion dreidimensionaler Kanten in Punktwolken existieren unterschiedliche Lösungsansätze. Dazu gehört die Verwendung von Ebenen und deren Schnittstellen, das direkte Klassifizieren von Kanten, semantische Segmentierung von Ebenen und letztlich Deep Learning zum Lernen und Detektieren von Ecken und Kanten.

Um die Konturen von Gebäuden in Punktwolken zu bestimmen, nutzen LU et al. (2019) eine zweidimensionale Kantendetektion. Dafür werden 3D-Punkte von Ebenen in eine 2D-Darstellung übertragen. Diese Darstellung wird zur Kantendetektion binarisiert. Die resultierenden Kanten werden in den dreidimensionalen Raum zurücktransformiert. Um die Konturen direkt aus Punktwolken zu bestimmen, können Punkte entlang von Ecken und Kanten klassifiziert werden. HACKEL et al. (2016) nutzen dafür geometrische Merkmale basierend auf Eigenwerten und Eigenvektoren. Für jeden Punkt wird auf Basis dieser Merkmale die Wahrscheinlichkeit für einen Konturpunkt abgeschätzt. Aus gleichmäßig verteilten Punkten, die einer Kantenbedingung entsprechen, wird ein Graph aufgebaut, der Kantenkandidaten beinhaltet. In diesem Graph wird aus Nachbarschaftsbeziehungen eine Untermenge an Punkten gewählt, die der Kontur auf Basis geometrischer Merkmale am besten entsprechen. Auf vergleichbare Weise nutzen AHMED et al. (2018) die Symmetrie der lokalen Nachbarschaft, um Punkte entlang von Kanten zu extrahieren und diese anschließend mit Hilfe von Krümmungsvektoren in Eck- und Konturpunkte zu trennen. Dieser Ansatz wird in dieser Arbeit als Grundlage verwendet. Andere Publikationen verwenden neuronale Netze zur Bestimmung von Konturpunkten. HIMEUR et al. (2020) beschreiben dafür Punkte und deren lokale Nachbarschaft in unterschiedlicher Skalierung. Es werden die Rauheit, die Normalen und die Krümmung betrachtet. Punkte, die direkt auf einer Kante liegen, werden als scharfe Kante

definiert und Punkte in der unmittelbaren Umgebung als weiche Kante. Damit wird ein neuronales Netz zur Kantendetektion trainiert. Da nur wenige Punkte nah an einer Kante zu liegen kommen, erhöht die Einbeziehung der umgebenden Punkte, gemäß der Autoren, die Robustheit der Detektion. Dieser Ansatz benötigt nur wenige manuell annotierte Trainingsdaten und ermöglicht eine Anpassung auf die spezifischen Eigenschaften einer Punktwolke, die z. B. durch unterschiedliche Erfassungsmethoden entstehen. Der klassische Ansatz zur Bestimmung der Geometrie von Innenräumen ist die Detektion von Wänden, Böden und Decken über Ebenen (VILLE et al. 2021). Zur Bestimmung dieser Ebenen können z. B. Local Hough Voting oder RANSAC verwendet werden (SOMMER et al. 2020). Sie bestimmen orthogonale Ebenen in einer Punktwolke und verschneiden diese, um Schnittgeraden aus zwei Ebenen entlang von Kanten und Schnittpunkte aus drei Ebenen als Eckpunkte zu berechnen. Eine semantische Segmentierung ermöglicht die Erweiterung dieses Ebenenansatzes (CASTAGNO & ATKINS 2020). verwenden diese zur Erfassung von Strukturen in Innenräumen und zur Repräsentation als Polygone. Dazu werden Meshs aus Punktwolken mit Hilfe der Normalenvektoren segmentiert und zu Flächen mit gleicher Ausrichtung zusammengefasst. Anschließend werden Polygone bestimmt, die diese Flächen umschließen, um die Strukturen in Innenräumen zu repräsentieren. IWASZCZUK et al. (2017) nutzen semantische Informationen über Konturen und Ebenen aus Bildern, um diese auf Tiefenkarten zu übertragen. Damit erzeugen sie eine semantisch angereicherte Punktwolke, aus der Ebenen, mittels k-Means-Clustering und RANSAC, bestimmt werden. Ein Verfahren, das ohne die Erfassung von Ebenen funktioniert, ist die direkte Erstellung von Drahtgittermodellen aus Punktwolken mittels Deep Learning (LIU et al. 2021). Die Autoren stellen ein Feed-Forward-Neuronal-Network vor, das für die Anwendung auf CAD-Modelle von einzelnen Objekten konzipiert wurde. Über mehrere Netze werden zuerst Eckpunkte bestimmt. Diese Eckpunkte werden anschließend mit Kanten verknüpft.

4 Methodik

Im folgenden Kapitel wird die Vorgehensweise der punktbasierten und ebenbasierten Extraktion von Kanten und Ecken aus Innenraum-Punktwolken beschrieben.

4.1 Punktbasierter Ansatz

Beim punktbasierten Ansatz werden in einem ersten Schritt Konturpunkte extrahiert. Dafür wird die Methode von AHMED et al. (2018) verwendet. Zu jedem Punkt wird die Symmetrie der lokalen Nachbarschaft betrachtet und ein Schwerpunkt bestimmt. Bei großer Abweichung des Punkts zum Schwerpunkt kann von einem Eck- oder Kantenpunkt ausgegangen werden. Anschließend werden Krümmungsvektoren in Form der Eigenvektoren aus den kleinsten Eigenwerten verwendet, um die Punkte in Eck- und Konturpunkte zu klassifizieren. Abhängig von der Form der Punktwolke und der Punktzahl ist diese Vorgehensweise sehr rechenintensiv, daher wird ein Subsampling auf einen Punkt pro Zentimeter der Originalpunktwolke durchgeführt, um die Rechenzeit und den Speicherbedarf zu reduzieren. Dieser Ansatz wird mittels Random Sample Consensus (RANSAC) erweitert, um Geraden in die Konturpunkte zu legen. Durch RANSAC wird eine zufällige Stichprobe gewählt und geprüft, wie gut die umgebenden Punkte zum vorgegebenen Modell einer Gerade passen. Da diese Geraden unterschiedlich lang sein können und unterschiedlich viele Punkte beinhalten, hängt das Ergebnis der Detektion stark von der Wahl der Parameter für

RANSAC ab. Deshalb wird die maximale Distanz für Inlier, die Anzahl an Iterationen und die Anzahl an Inliern für eine Gerade in dieser Arbeit empirisch festgelegt. Zuerst werden 500 Geraden geschätzt und davon die Gerade mit den meisten Inliern, mit einer maximalen Distanz von 5 cm, gewählt. Die zugehörigen Punkte werden aus der Punktwolke entfernt und von der weiteren Bestimmung ausgeschlossen. Dieser Prozess wird wiederholt, bis 100 Geraden gefunden wurden. Diese Vorgehensweise ist notwendig, um mögliche Geraden zu finden, hat jedoch den Nachteil, dass die Eckpunkte, als Schnittpunkte mehrerer Geraden, nach der ersten Zuordnung zu einer Gerade für die Bestimmung weiterer Geraden nicht mehr zur Verfügung stehen. Um diesem Problem und der unterschiedlichen Anzahl an Punkten pro Kante zu begegnen und alle Kanten zu finden, wird die anfangs geforderte Anzahl von 210 Inliern bei jeder Iteration um 2 reduziert. Diese Geraden werden als Kantenkandidaten interpretiert. Unter der Annahme von Manhattan-World (COUGHLAN & YUILLE 1999) werden aus diesen Kantenkandidaten nur solche gewählt, die nahezu parallel zu den Koordinatenachsen verlaufen. Jeweils aus zwei Geraden wird ein Schnittpunkt berechnet, der als Eckpunkt interpretiert wird. Aufgrund von Messungenauigkeiten ist davon auszugehen, dass die Geraden entlang der Kanten windschief verlaufen. Daher wird ein Pseudo-Schnittpunkt als Mittelpunkt der geringsten Distanz zweier Geraden als Eckpunktkandidat berechnet. Durch die Wahl eines maximal erlaubten minimalen Abstands zwischen Geraden wird ermittelt, welche Kanten potenziell einen gemeinsamen Schnittpunkt besitzen. Die resultierenden Schnittpunkte werden über eine Bounding Box um die Punktwolke gefiltert, um Ausreißer zu entfernen. Da sich in einem Eckpunkt grundsätzlich drei Geraden treffen, wird zu diesen Schnittpunkten die geringste Distanz zu allen anderen Kanten bestimmt. Liegt eine dicke Kante in einer maximalen Entfernung von 20 cm zu einem Eckpunkt, wird der zugehörige Eckpunkte bestätigt und als Mittelpunkt zu dieser Gerade neu bestimmt. Somit können theoretisch auch verdeckte Eckpunkte erfasst werden.

4.2 Ebenenbasierter Ansatz

Der ebenenbasierte Ansatz entspricht der Vorgehensweise von SOMMER et al. (2020). Mit Hilfe von M-Estimator Sample Consensus (MSAC) werden Ebenen in die Punktwolke gelegt, diese können als Kandidaten für Wandelemente betrachtet werden. MSAC ist eine Erweiterung von RANSAC, bei dem die Inlier abhängig zur Distanz zum gewählten Modell gewichtet werden. MSAC wird aufgrund der Robustheit und einfachen Implementierung genutzt. Dabei wird ein maximaler Punktabstand zur Ebene von 5 cm verwendet. Es werden Ebenen detektiert und die zugehörigen Punkte entfernt, bis keine Ebenen mit mehr als 1000 Punkten gefunden werden können. Die Verschneidung zweier Ebenen erlaubt die Berechnung von Schnittgeraden. Diese entsprechen den Kantenkandidaten. Die Schnittbedingung wird mit Hilfe des Kreuzprodukts der Normalenvektoren unter Berücksichtigung einer Toleranz auf nahezu rechtwinklige Schnitte eingeschränkt. Ein Schnittpunkt von drei Ebenen entspricht einem potenziellen Eckpunkt. Diese Vorgehensweise hat den Vorteil, dass ein Eckpunkt immer auf einem Geradenschnittpunkt von drei Geraden liegt. Die Schnittgeraden und Schnittpunkte, die durch Messfehler außerhalb des Raums liegen, werden außerhalb einer Bounding Box abgeschnitten, die die gesamte Punktwolke mit einer Toleranz von 20 cm umschließt. Zusätzlich wird eine Klassifikation implementiert, die Punkte und Geraden als weniger wahrscheinlich einstuft, die mit einem Toleranzmaß von 5 cm

außerhalb der Punktwolke liegen. Zu jedem Eckpunkt wird dazu die minimale Distanz zur Punktwolke bestimmt. Da verdeckte Ecken ebenfalls eine große Entfernung zur Punktwolke aufweisen eignet sich diese Klassifikation nicht zum eindeutigen Ausschluss von Eckpunkten und Kanten.

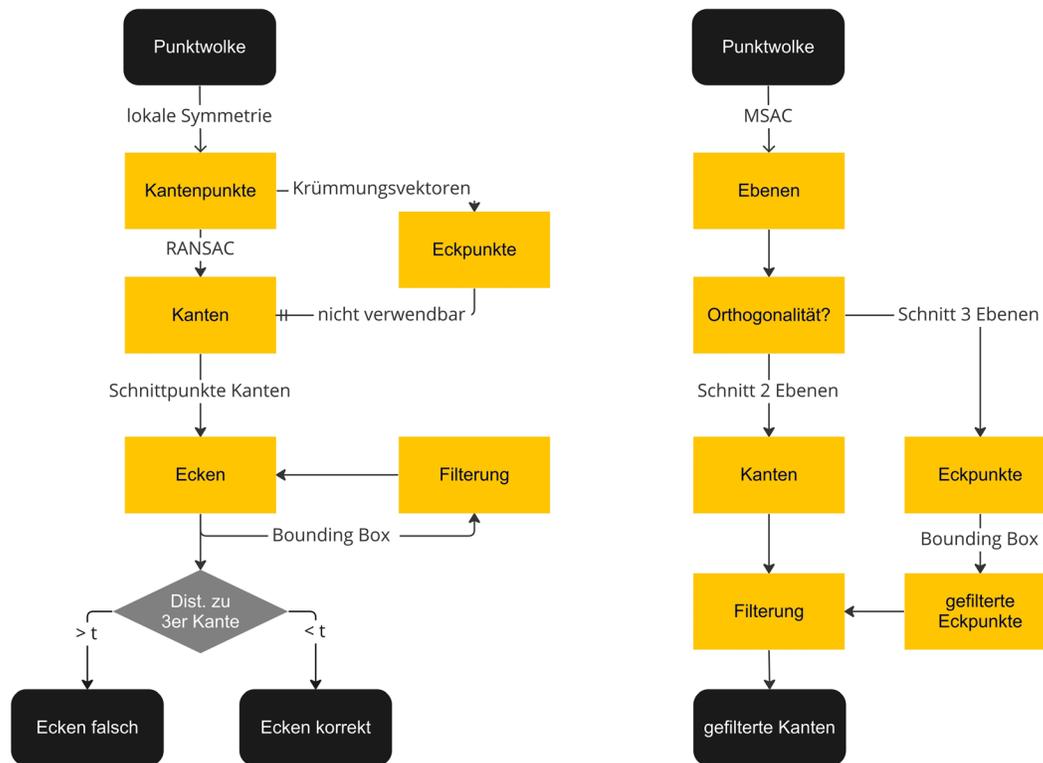


Abb. 1: Ablaufdiagramm punktbasierter (links) und ebenbasierter Ansatz (rechts)

5 Experimente

Die vorgestellte Methodik wird anhand von zwei Datensätzen getestet (siehe Tab. 1 und Abb. 2), dem „ISPRS Benchmark on Indoor Modelling“, im Folgenden BoIM genannt, (KHOSHELHAM et al. 2018) und dem „Stanford large-scale 3D Indoor Spaces Dataset“ (S3DIS) (ARMENI et al. 2016). Die Datensätze bestehen aus Punktwolken von Stockwerken mehrerer Gebäude. Der S3DIS-Datensatz wurde mit einer Matterport-Kamera erfasst, die auf Basis von Structured Light Tiefeninformationen liefert und daraus eine Punktwolke erzeugt. Der BoIM-Datensatz wurde mit einem Mobile Laserscanning System erfasst. Dieses Trolley-System besteht aus drei einzeiligen Laserscannern und einer 360°-RGB-Kamera für die Farbinformationen. Die verwendete Punktwolke beinhaltet jedoch keine Farbinformation. Abb. 2 macht deutlich, dass der S3DIS-Datensatz eine deutlich gleichmäßigere Punktverteilung aufweist als der BoIM-Datensatz. Der S3DIS-Datensatz beinhaltet in jedem Raum das Mobiliar, bei BoIM existieren Stockwerke und Räume mit und ohne Mobiliar. Als geometrische Referenz stehen bei BoIM von Hand modellierte BIM-Daten zur Verfügung. Bei S3DIS existiert nur eine semantisch gelabelte Punktwolke. Das BIM eignet sich nur eingeschränkt zur Kontrolle der Ergebnisse, denn ein BIM besteht aus volumetrischen

Wandelementen. Im Vergleich dazu korreliert eine Indoor-Punktwolke stärker mit der Repräsentation von Wänden als unendlich dünne Ebenen (VILLE et al. 2021). Dadurch entstehen Unterschiede sowohl an Ecken als auch an Kanten zwischen der BIM-Referenz und der Punktwolke. Bei einem BIM sind z. B. die Kanten, an denen sich die Wände im Innenraum berühren, nicht für alle Wände identisch modelliert. Deshalb lassen sich die Innenraum-Kanten und Eckpunkte in Position und Anzahl nicht direkt aus dem BIM extrahieren und vergleichen. Da die Anpassung der Referenz zur Kontrolle der Ergebnisse nicht ohne Weiteres möglich ist, wurden die detektierten Ecken und Kanten vorerst nur visuell auf Plausibilität geprüft. Dafür wurden die Kanten und Eckenzahl pro Raum in der Originalpunktwolke gezählt und mit der Anzahl an Ecken und Kanten aus den beiden Ansätzen verglichen (Tab. 2). Die vorliegende Betrachtung erfolgt für einzelne Räume und nicht für gesamte gesamten Stockwerke. Aus dem S3DIS-Datensatz wird ein Konferenzraum mit Mobiliar verwendet, aus dem BoIM-Datensatz ein Raum ohne Mobiliar. Aus dem S3DIS-Datensatz wurde der „conferenceRoom_1“ in „Area_1“ mit einer Grundfläche von 4×5 m, einer Höhe von 3 m und einer Punktzahl von 1,95 Mio. verwendet. Aus dem BoIM-Datensatz wurde ein Raum aus „CaseStudy1_TUB1“ mit einer Fläche von 5×7 m, einer Höhe von ca. 2,5 m und einer Punktzahl von 1,14 Mio. ausgewählt (Tab. 1). Auf die beiden Datensätze werden jeweils der punktbasierte und der ebenenbasierte Ansatz angewendet. Der Vergleich der Ergebnisse der beiden Datensätze lässt zum einen Rückschlüsse auf die Auswirkung der Erfassungsmethoden auf die Kanten- und Eckendetektion zu, zum anderen lässt sich durch die unterschiedliche Möblierung der Räume auch eine Einschätzung der Ansätze in Bezug auf die Erfassung verdeckten Ecken und Kanten ableiten.

Tab. 1: Parameter der untersuchten Datensätze

	BoIM	S3DIS
Raum	Raum aus CaseStudy1_TUB1	conferenceRoom_1 in Area_1
Größe	5x7x2,5 m	4x5x3 m
Sensor	Viametris iMS3D	Matterport Kamera
Punktzahl	1,14 Mio.	1,95 Mio.
Referenz	BIM-Modelle	semantisch gelabelte Punktwolke

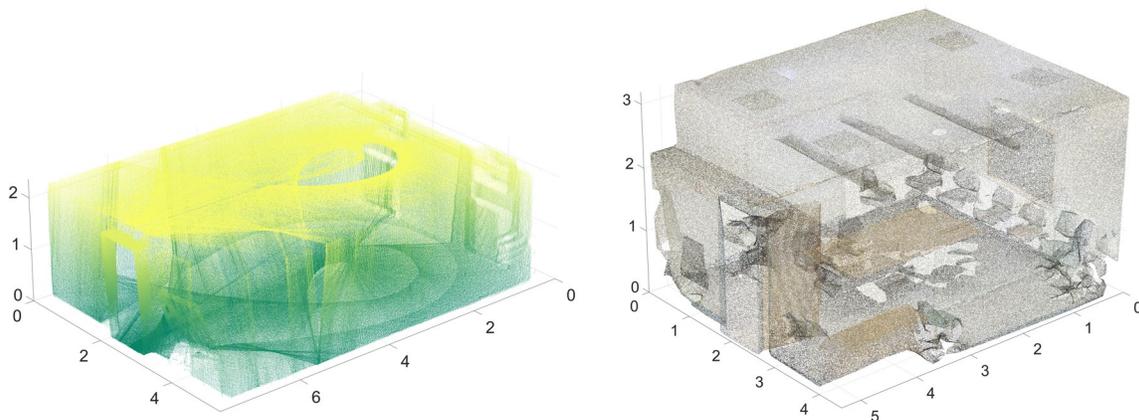


Abb. 2: Originalpunktwolke BoIM (links) und S3DIS (rechts) [m]

6 Ergebnisse

In Tab. 2 wird die tatsächliche und die durch die vorgestellten Ansätze erfasste Anzahl an Ecken und Kanten gegenübergestellt. Kanten und Ecken wurden manuell ohne Berücksichtigung von Mehrfachbestimmung gezählt. Die Anzahl an Ecken- und Kantenkandidaten stellt die tatsächlich vom Algorithmus bestimmte Anzahl der Ecken und Kanten dar.

Tab. 2: Tatsächliche und bestimmte Anzahl an Ecken und Kanten mit beiden Datensätzen und Ansätzen

	tatsächlich		punktbasiert		ebenenbasiert	
	BoIM	S3DIS	BoIM	S3DIS	BoIM	S3DIS
Kanten	12	18	10	12	12	17
Ecken	8	12	7	4	8	11
verdeckte Ecken	0	4	0	2	0	4
Kantenkandidaten	-	-	49	51	93	180
Eckkandidaten	-	-	141	92	188	441

6.1 Punktbasierter Ansatz

Der punktbaasierte Ansatz liefert mit S3DIS 12 von 18 Kanten und 7 von 12 Ecken (siehe Tab. 2). Von den 4 verdeckten Ecken wurden 2 gefunden, mit BoIM sind es 10 von 12 Kanten und 6 von 8 Ecken. Im S3DIS-Datensatz wurden 51 Kanten- und 92 Eckkandidaten gefunden, mit BoIM 49 Kanten- und 141 Eckkandidaten. Abb. 3 zeigt die Extrahierte der Konturpunktwolke Dabei werden mit S3DIS ca. 31500 Punkte und mit BoIM ca. 16700 Punkte als Konturpunkte bestimmt. Es ist zu sehen, dass sich die ungleichmäßige Punktwolke bei BoIM auch zu einer weniger vollständigen und stärker verrauschten Konturpunkt wolke führt als bei S3DIS. Die Konturen der Objekte im Raum können bei S3DIS ebenfalls mitbestimmt werden. Es lässt sich beobachten, dass mit BoIM ebenfalls Punkte als Konturpunkte eingestuft werden, die durch Scanmuster entstanden sind und nicht auf einer Kante liegen. Diese Punkte bilden kurvenförmige Strukturen. Für den punktbaasierten Ansatz ist neben der vollständigen Konturerfassung besonders die geradlinige Erfassung der Kanten für alle folgenden Schritte wichtig. Das Messverfahren mittels MLS führt bei BoIM zu unvollständigen und falsch bestimmten Konturen. Auch die Raummessung mit Structured Light bei S3DIS erzeugt Konturen, die stark von Geraden abweichen. Daneben ist auffällig, dass besonders an der Tür bei S3DIS sehr viele Kanten und Eckpunkte falsch bestimmt werden, in Abb.2 scheint diese ebenfalls ungleichmäßig erfasst zu sein.

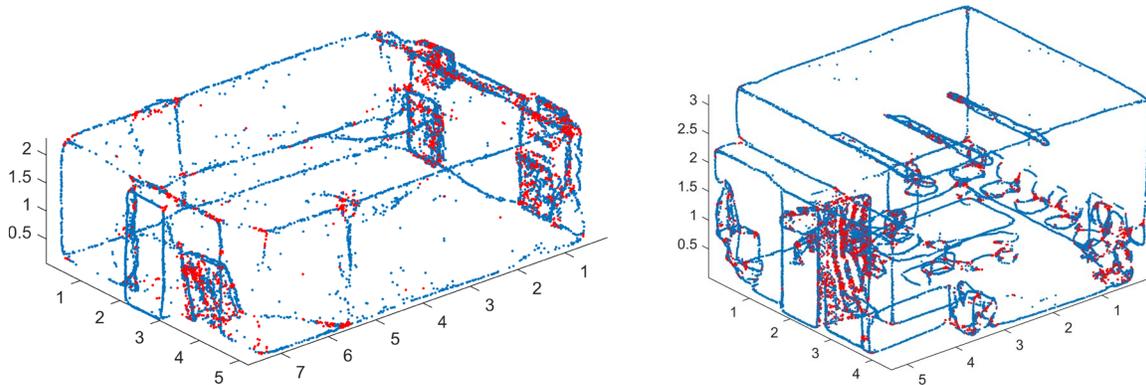


Abb. 3: Kantenpunktwolke (blau) mit Eckpunkten (rot) aus Krümmungsvektoren (links BoIM, rechts S3DIS) [m]

Die Weiterverarbeitung der Konturpunkte durch die Trennung von Eck- und Konturpunkten mithilfe von Krümmungsvektoren erweist sich als sehr unzuverlässig (Abb. 3). Es werden sehr viele Punkte falsch als Eckpunkte bestimmt. Diese werden daher nicht weiterverwendet. Stattdessen ermöglicht die Bestimmung der Pseudo-Schnittpunkte von drei windschiefen Geraden entlang der Kanten die Erfassung verdeckter Eckpunkte (Abb. 3). Die Ungenauigkeiten in der Konturpunktwolke führen dazu, dass an den betreffenden Kanten mittels RANSAC falsche oder keine Geraden gefunden werden. Die Filterung der Kanten unter der Manhattan-World-Annahme reduziert diese falschen Beobachtungen teilweise, aber nicht vollständig. Die Bestimmung von Pseudo-Schnittpunkten aus diesen Geraden erzeugt eine unvollständige und fehlerhafte Erfassung der Eckpunkte. Das Mobiliar im Raum im S3DIS-Datensatz führt ebenfalls zu falsch erkannten Kanten und Ecken. Der Schnitt von zwei Geraden beim punktbasieren Ansatz ermöglicht ebenfalls die Erfassung von regelmäßigen Öffnungen in den Wänden, wie z. B. des Türrahmens bei BoIM (Abb. 4).

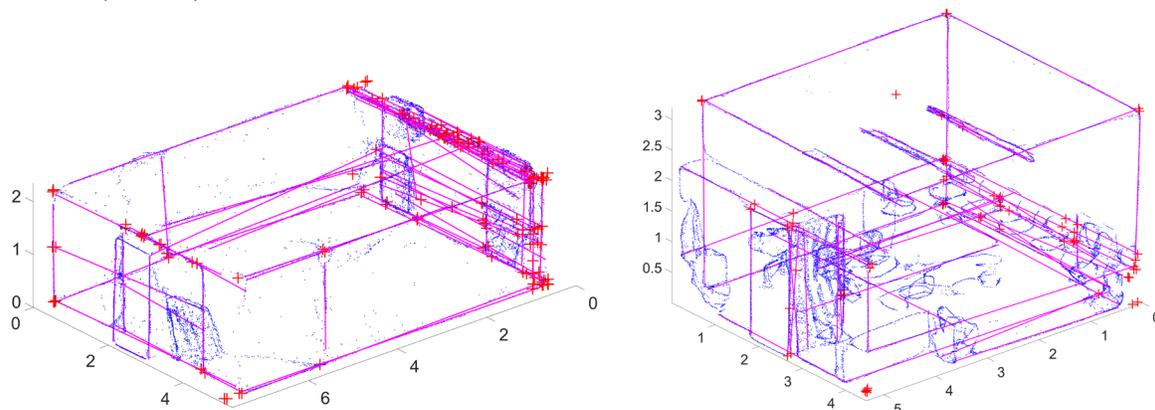


Abb. 4: Kantenpunktwolke (blau), Kanten- (magenta) und Eckkandidaten (rot) (links BoIM, rechts S3DIS) [m]

Da sich am Türrahmen in der Regel jedoch keine drei Kanten schneiden, erfüllen diese die Eckbedingung nur teilweise. Der Vergleich zwischen S3DIS und BoIM deutet darauf hin, dass eine gleichmäßige Punktverteilung auf den Wänden sowie entlang der Kanten- und Eckpunkte entscheidend für eine korrekte Extraktion von Ecken und Kanten ist. Dies gilt sowohl für die

Konturextraktion, als auch für die Bestimmung der Kanten mittels RANSAC. Die Grundform des Raums wird mit der punktbasierten Methode insgesamt unvollständig erfasst. Aufgrund von nicht detektierte Kanten werden die Ecken nur teilweise erfasst.

6.2 Ebenenbasierter Ansatz

Mit dem ebenbasierten Ansatz können mit dem S3DIS-Datensatz 17 von 18 Ecken- und 11 von 12 Kanten erfasst werden. Die 4 verdeckten Kanten wurden vollständig erfasst (Tab. 2). Mit BoIM wurden alle 8 Ecken und 12 Kanten vollständig erfasst. Insgesamt wurden bei S3DIS 180 Kanten- und 441 Eckkandidaten gefunden. Für BoIM sind es 93 Kanten- und 188 Eckkandidaten. Die Ebenen der Wände können mittels MSAC vollständig bestimmt werden (Abb. 5). Die Verschneidung dieser Ebenen führt zur Detektion vieler Geraden, die sich großteils im Bereich der tatsächlichen Kanten befinden. Diese Kantenkandidaten sind bündelartig angeordnet. An den Wänden, der Decke und dem Boden entspricht dabei an den meisten Kanten mindestens eine Gerade näherungsweise der tatsächlichen Kante. An den schrägen Schnittgeraden an der Decke (Abb. 5 BoIM) ist zu erkennen, dass die Ebenen bei kurzen Wandabschnitten, z. B im Türbereich nicht parallel zur eigentlichen Wand verlaufen. Die Objekte im Raum besonders beim S3DIS-Datensatz genügen teilweise ebenfalls der Ebenenbedingung, daher werden viele falsche Ebenen detektiert. Dies führt wiederum zu falschen Kanten- und Eckkandidaten. Die orthogonale Schnittbedingung reduziert die Anzahl falsch bestimmten Ecken und Kante deutlich, bedingt bei S3DIS jedoch auch, dass nicht alle Kanten im Raum vollständig erfasst werden. Dies liegt vermutlich daran, dass die Wände im S3DIS-Datensatz weniger plan sind, als bei BoIM. Somit treten hier verstärkt unvollständig erfasste Ecken und Kanten auf. Die verdeckten Ecken wurden mit dem ebenbasierten Ansatz vollständig bestimmt (Tab. 2). Die Grundform des Raumes wurde nahezu vollständig erfasst, es tritt jedoch eine deutliche Übererfassung der Ecken und Kanten auf.

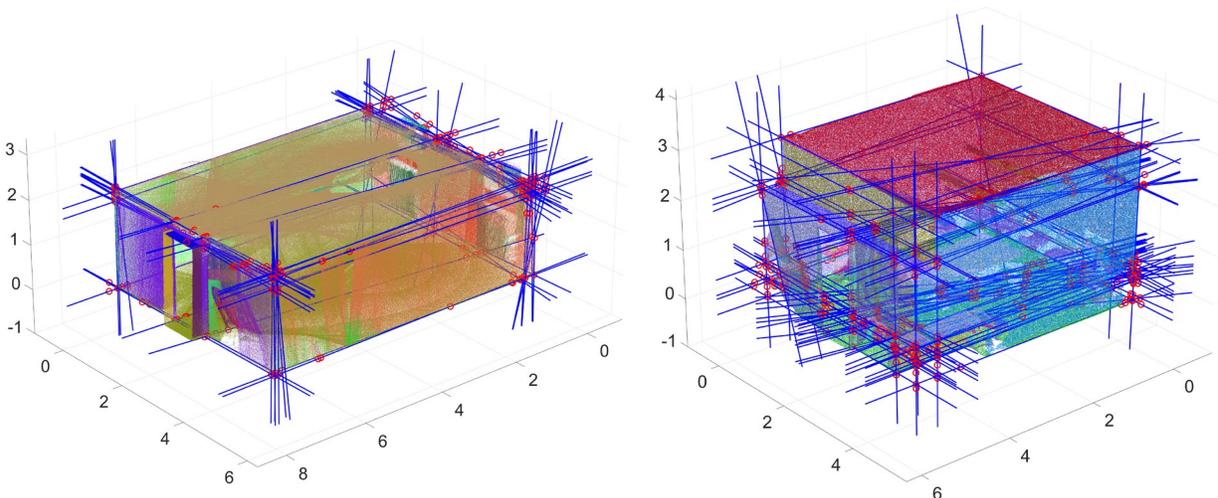


Abb. 5: Unterschiedlich gefärbte Ebenen mit Kanten- (blau) und Eckkandidaten (rote Kreise) (links BoIM, rechts S3DIS) [m]

7 Diskussion

Die Bestimmung von Ebenen erweist sich in den untersuchten Datensätzen als grundsätzlich robuster, als die Bestimmung von Konturen. Dies liegt vermutlich auch daran, dass für eine korrekte Erfassung einer Wand nur ein Teil sichtbar sein muss. Daneben ist die Wahrscheinlichkeit, dass eine Kante z. B. durch Möbel komplett verdeckt ist deutlich höher, als dass eine gesamte Wand nicht sichtbar ist. Die zuverlässigere Ebenendetektion führt ebenfalls zu einer vollständiger Kanten- und Eckenerfassung. Dies liegt vermutlich auch daran, dass eine Ebene Informationen über mehrere sowohl sichtbare als auch verdeckte Ecken und Kanten liefert. Eine Kante beinhaltet dagegen nur Informationen über zwei Eckpunkte. In Abb. 4 und 5 ist bei BoIM an der rechten Seite des Raums zu erkennen, dass ungenau erfasste Fenster in der Punktwolke mit beiden Ansätze zu einer großen Anzahl falsch bestimmter Kanten und Ecken führen. Dies zeigt, dass eine ungenaue Punktwolke die Auswahl korrekter Kanten und Ecken deutlich erschwert. Die Vollständige Erfassung der Ecken und Kanten bei BoIM zeigt ebenfalls, dass die Komplexität des Raums für die vollständige und korrekte Bestimmung aller Wände durch Ebenen entscheidend ist. Die stark variierenden Eigenschaften der einzelnen Wände führen demnach zu Unter- oder Überanpassung. Diese Übererfassung komplexer Räume, zeigt sich vermutlich bei S3DIS im Vergleich zu BoIM durch die deutlich größeren Anzahl an Kanten- und Eckkandidaten bei Verwendung des ebenbasierten im Vergleich zum punktbasierten Ansatz (Tab. 2). Bei BoIM unterscheiden sich die Ansätze in der Kanten- und Eckkandidatenzahl nur wenig. Die Komplexität des Raums hat durch die Verwendung der lokalen Nachbarschaft scheinbar nur einen geringen Einfluss. Die vorhandenen Unterschiede zeigen, dass die vollständige Erfassung aller Kanten mit dem punktbasierten Ansatz durch die Schätzung von Geraden aus der Kantenpunktwolke grundsätzlich ebenfalls von der variierenden Punktzahl und Dichte der Punkte entlang von Kanten unterschiedlicher Länge abhängig ist. Da alle Ecken und Kanten mit dem ebenbasierten Ansatz unter Verwendung des BoIM-Datensatz vollständig erfasst werden, kann davon ausgegangen werden, dass bei Verwendung von MSAC eine gleichmäßige Punktverteilung nicht notwendig ist, um Wandflächen zuverlässig zu erkennen. Die punktbasierte Methode erscheint deutlich abhängiger von gleichmäßig erfassten Kanten und Ebenen, wodurch z. B. nicht alle verdeckten Ecken gefunden werden konnten.

Neben der Zuverlässigkeit bei der Bestimmung von Ecken und Kanten unterscheiden sich die Ansätze ebenfalls im rekonstruierbaren Modell. So ermöglicht der ebenbasierte Ansatz die volumetrische Rekonstruktion von Innenräumen, durch die Erfassung der Wände als Flächen. Der punktbasierte Ansatz erzeugt nur ein Drahtgittermodell. Um vergleichbare Modelle aus beiden Ansätzen zu erhalten, müssen aus dem Drahtgittermodell zusätzlich Flächen aus umschließenden Kanten und Ecken bestimmt werden.

8 Fazit & Ausblick

Sowohl mit dem ebenbasierten als auch mit dem punktbasierten Ansatz ist die Erfassung der Geometrie eines Raumes mit Hilfe von Ecken und Kanten aus Punktwolken möglich. Beide Ansätze eignen sich zudem zur Detektion verdeckter Ecken und Kanten. Dabei stellt das Herausfiltern

falsch bestimmter Ecken und Kanten die größte Herausforderung dar. Die Bestimmung der Kanten und Eckpunkte mit Hilfe von Ebenen erweist sich als zuverlässiger und robuster als über Konturpunkte, insbesondere bei ungleichmäßig erfassten Punktwolken. Dabei muss eine sinnvolle Wahl der Parameter für die Ebenenbestimmung getroffen werden, um eine vollständige Erfassung erreichen zu können. Die vorliegenden Ergebnisse deuten darauf hin, dass sich der Ebenenansatz besser für verrauschte und ungleichmäßigen Punktwolken eignet. Der Punktansatz scheint besser für komplexe Räume geeignet. Die Einschränkung der Schnittbedingung für Ebenen und Kanten in beiden Methoden ermöglicht in den verwendeten Datensätzen eine effiziente Vorfilterung, begrenzt dabei jedoch die Allgemeingültigkeit des Modells. Zur zukünftigen Verwendung beider Ansätze sollte insbesondere die Filterung der Ecken und Kanten weiterentwickelt werden. Dazu können die Ansätze z. B. um eine Optimierung der Ecken und Kanten über Graphen erweitert werden. Zusätzlich ist eine Filterung der Kanten mit Hilfe von Punktdichte und -verteilung denkbar. Die Kombination beider Ansätze, kann vermutlich durch die doppelte Beobachtung von Ecken und Kanten die Robustheit und Zuverlässigkeit der Methodik verbessern. Des Weiteren können effizientere Algorithmen zur Bestimmung von Ebenen und Konturpunkten verwendet werden, z. B. das von SOMMER et al. (2020) vorgestellte Local Hough Voting. Dabei sollte der Fokus beim punktbasierten Ansatz besonders auf einer vollständigen Extraktion von Konturpunkten liegen. Da der aktuelle Ansatz nicht automatisch auf die Eingangspunktwolke angepasst wird, ist eine Erweiterung um die Wahl sinnvoller Parameter z. B. auf Basis von Clustering der Flächen und Rauheit der Punktwolke zur Abschätzung der Parameter für RANSAC und MSAC denkbar. Hierzu kann z. B. auch eine semantische Segmentierung zur Ebenendetektion, sowie zur Filterung und Klassifizierung der Objekte im Raum eingesetzt werden (IWASZCZUK et al. 2018). Zur Bestimmung der Beziehungen zwischen detektierten Ecken und Kanten kann ebenfalls Deep Learning verwendet werden. Dabei können die vorgestellten Ansätze dazu dienen, z. B. das von LIU et al. (2021) vorgestellte Verfahren, um die Extraktion verdeckter Ecken zu erweitern. Allerdings müsste dazu ein Trainingsdatensatz aufgebaut werden, der auch verdeckte Kanten enthält.

9 Literaturverzeichnis

- AHMED, S. M., TAN, Y. Z., CHEW, C. M., MAMUN, A. A. & WONG, F. S., 2018: Edge and Corner Detection for Unorganized 3D Point Clouds with Application to Robotic Welding. IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS), <https://arxiv.org/pdf/1809.10468>.
- ARMENI, I., SENER, O., ZAMIR, A. R., JIANG, H.; BRILAKIS, I., FISCHER, M. & SAVARESE, S., 2016: 3D Semantic Parsing of Large-Scale Indoor Spaces. IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 1534-1543.
- CASTAGNO, J. & ATKINS, E., 2020: PolyLidar3D -- Fast Polygon Extraction from 3D Data. <https://arxiv.org/pdf/2007.12065>.
- COUGHLAN, J. M. & YUILLE, A. L., 1999: Manhattan World: compass direction from a single image by Bayesian inference. Proceedings of the Seventh IEEE International Conference on Computer Vision, (2), 941-947.
- HACKEL, T., WEGNER, J. D. & SCHINDLER, K., 2016: Contour Detection in Unstructured 3D Point Clouds. IEEE Conference on Computer Vision and Pattern Recognition, 1610-1618.

- HIMEUR, C.-E., LEJEMBLE, T., PELLEGRINI, T., PAULIN, M., BARTHE, L. & MELLADO, N., 2022: PCEDNet: A Lightweight Neural Network for Fast and Interactive Edge Detection in 3D Point Clouds. *ACM Trans. Graph.*, **41**(1), 1-21, <https://doi.org/10.1145/3481804>.
- IWASZCZUK, D.; KOCH, T. & STILLA, U., 2017: Innenraumrekonstruktion aus semantisch angereicherten 3D Punkten und Linien. 37. Wissenschaftlich-Technische Jahrestagung der DGPF - Publikationen der DGPF, **26**, 129-137.
- IWASZCZUK, D., KOPPANYI, Z., GARD, N. A., ZHA, B., TOTH, C., & YILMAZ, A., 2018: Semantic Labelling of Structural Elements in Buildings by Fusing RGB and Depth Images in an Encoder-Decoder CNN Framework. *Int. Arch. Photogramm. Remote Sens. Spatial Inf. Sci.*, **42**(1), 225-232, <https://doi.org/10.5194/isprs-archives-XLII-1-225-2018>.
- KHOSHELHAM, K., TRAN, H., DÍAZ-VILARIÑO, L., PETER, M., KANG, Z. & ACHARYA, D., 2018: An Evaluation Framework for Benchmarking Indoor Modelling Methods. *Int. Arch. Photogramm. Remote Sens. Spatial Inf. Sci.*, **42**(4), 297-302, <https://doi.org/10.5194/isprs-archives-XLII-4-297-2018>.
- LÓPEZ IGLESIAS, J., DÍAZ SEVERIANO, J. A., LIZCANO AMOROCHO, P. E., MANCHADO DEL VAL, C.; GÓMEZ-JÁUREGUI, V., FERNÁNDEZ GARCÍA, O., PRECIADOS ROYANO, A. & OTERO GONZÁLEZ, C., 2020: Revision of Automation Methods for Scan to BIM. *International Conference on the Digital Transformation in the Graphic Engineering*, 482-490, https://link.springer.com/chapter/10.1007/978-3-030-41200-5_53.
- LEHTOLA, V. V., NIKOOHEMAT, S. & NÜCHTER, A., 2021: Indoor 3D: Overview on Scanning and Reconstruction Methods. *Handbook of Big Geospatial Data*, 55-97, https://link.springer.com/chapter/10.1007/978-3-030-55462-0_3.
- LIU, Y., D'ARONCO, S., SCHINDLER, K. & WEGNER, J. D., 2021: PC2WF: 3D Wireframe Reconstruction from Raw Point Clouds. <https://arxiv.org/pdf/2103.02766>.
- LU, X., LIU, Y. & LI, K., 2019: Fast 3D Line Segment Detection from Unorganized Point Cloud. <https://arxiv.org/pdf/1901.02532>.
- SCHNABEL, R., WAHL, R. & KLEIN, R., 2007: Efficient RANSAC for Point-Cloud Shape Detection. *Computer Graphics Forum*, **26**(2), 214-226. <https://doi.org/10.1111/j.1467-8659.2007.01016.x>.
- SOMMER, C., SUN, Y., GUIBAS, L., CREMERS, D. & BIRDAL, T., 2020: From Planes to Corners: Multi-Purpose Primitive Detection in Unorganized 3D Point Clouds. *IEEE Robot. Autom. Lett.*, **5**(2), 1764-1771, <https://doi.org/10.1109/LRA.2020.2969936>.