



## Flächennutzungsmonitoring IX Nachhaltigkeit der Siedlungs- und Verkehrsentwicklung?

IÖR Schriften Band 73 · 2017

ISBN: 978-3-944101-73-6

### **Einsatz von Crowdsourcing zur Gewinnung von Gebäudeinformationen**

*Robert Hecht, Matthias Kalla, Tobias Krüger*

Hecht, R.; Kalla, M.; Krüger, T. (2017): Einsatz von Crowdsourcing zur Gewinnung von Gebäudeinformationen. In: Meinel, G.; Schumacher, U.; Schwarz, S.; Richter, B. (Hrsg.): Flächennutzungsmonitoring IX. Nachhaltigkeit der Siedlungs- und Verkehrsentwicklung? Berlin: Rhombos, IÖR Schriften 73, S. 123-134.

# Einsatz von Crowdsourcing zur Gewinnung von Gebäudeinformationen

*Robert Hecht, Matthias Kalla, Tobias Krüger*

## Zusammenfassung

Zur Erforschung von Siedlungen spielen Informationen zu Gebäudebeständen eine bedeutende Rolle. Da Informationen zum Gebäudebestand oft nicht in ihrer räumlichen und inhaltlichen Detailliertheit gegeben sind, kommen zunehmend maschinelle Lernverfahren zum Einsatz, um auf Basis von geometrisch-topologischen Eigenschaften der Gebäude einen bestimmten Gebäudetyp oder andere Eigenschaften für ganze Städte und Regionen abzuleiten. Diese prädiktiven, datengetriebenen Ansätze benötigen jedoch stets eine ausreichende Menge an Trainings- und Validierungsdaten. Erfahrungen aus anderen Disziplinen haben gezeigt, dass Crowdsourcing das Potenzial bietet, den Prozess der Gewinnung von Trainings- und Validierungsdaten zu unterstützen. Es wird ein integriertes System zur automatischen Klassifizierung von Gebäudegrundrissen vorgestellt, das durch eine Crowdsourcing-Komponente zur Erfassung von Referenzdaten ergänzt wird und erste Ergebnisse einer experimentellen Studie zeigt.

## 1 Einführung

Die Gestalt von Siedlungen und Städten ist hauptsächlich durch die Bebauung, speziell den Gebäuden, geprägt. Trotz wirtschaftlicher und gesellschaftlicher Bedeutung fehlen jedoch oft ausreichend detaillierte Informationen zum Gebäudebestand, deren Struktur und räumlichen Verteilung. Amtliche Geodaten enthalten zwar die Gebäude in ihrem Grundriss, die wichtigen Informationen zum Gebäudetyp, der Nutzung, dem Alter oder auch der Anzahl der Etagen sind jedoch oft nicht gegeben. Daher kommen zunehmend Methoden der Mustererkennung und des maschinellen Lernens zum Einsatz, die eine Bestimmung von Gebäudetypen und anderen Gebäudeeigenschaften und damit eine effiziente Beschreibung des Gebäudebestandes von Städten und Regionen ermöglichen. Die Erhebung der dazu benötigten Menge an Trainings- und Validierungsdaten ist in der Regel kostenintensiv und zeitaufwändig.

## 2 Crowdsourcing zur Geodatengewinnung

Die Einbindung von Bürgern bei der Erhebung von Geoinformation spielt im heutigen digitalen Zeitalter eine immer bedeutendere Rolle. Es existieren verschiedene Begriffe, die den Prozess der nutzergenerierten Erfassung von Geodaten, z. B. Crowdsourcing, Citizen Science (Bürgerwissenschaft), Collaborative Mapping, oder die erfassten

Geodaten als solche, z. B. Volunteered Geographic Information (VGI) or User-Generated Content (UGC), beschreiben. Die Art und Weise der Datenerfassung kann unterschiedlich erfolgen, wobei grundsätzlich zwischen einer aktiven Erfassung über eine Plattform (z. B. Open Street Map, Wikimapia) oder passiven Beiträgen durch die Auswertung von in anderen Zusammenhängen erfassten Daten (z. B. Mobilfunkdaten, georeferenzierte Inhalte sozialer Medien, wie Twitter, Flickr, Instagram) zu unterscheiden ist (See et al. 2016). Des Weiteren variieren sowohl die Daten hinsichtlich ihres Typus (räumlich oder nichträumlich, semantisch oder geometrisch), den Datenerfassern und deren Motivation (Bezahlung, Anerkennung, Gamification, etc.) als auch der Art und Weise, wie die Information erfasst wird (Desktop, mobile App, etc.).

In unserem Ansatz gehen wir bei der Nutzung des Begriffs „Crowdsourcing“ von einer partizipativen Onlineaktivität aus, die von den Teilnehmern freiwillig in Form der Lösung von spezifischen Aufgaben (Tasks) durchgeführt wird (Estellés-Arolas and Ladrón-de-Guevara 2012). Crowdsourcing wurde durch den Journalisten Jeff Howe (2006) populär, der ihn als Geschäftspraxis zum Auslagern von Produktionsprozessen beschrieb. Heute zählt das Crowdsourcing zu einem etablierten Ansatz, um spezielle Aufgaben über das Internet an eine große Gruppe von Freiwilligen auszulagern. Es hat sich beispielsweise im Anwendungsfall der Spracherkennung gezeigt, dass eine große Anzahl an Annotationen fachlicher Laien nahezu dieselbe Qualität besitzen wie Experteneinschätzungen (Snow et al. 2008). Gleiches konnte auch im Bereich der medizinischen Bildverarbeitung und dem autonomen Fahren beobachtet werden (Maier-Hein et al. 2014; Donath, Kondermann 2013).

Auf dem Markt existiert heute eine Vielzahl kommerzieller (z. B. Amazon Mechanical Turk, CrowdFlower) als auch nichtkommerzieller Crowdsourcing-Plattformen (z. B. Crowdcrafting, Zooniverse). Alternativ können eigene Umgebungen entwickelt, wie z. B. Cropland Capture (Salk et al. 2016) oder Spielumgebungen genutzt werden. Ein wohl für jeden Internetnutzer bekanntes Beispiel von Crowdsourcing ist der ReCAPTCHA-Dienst. Dabei handelt es sich um einen Mechanismus zur Identifikation von Spambots, bei dem Nutzer aufgefordert werden, unkenntliche Wörter gescannter Buchbestände zu erkennen und einzugeben, um Zugang zu den angeforderten Webinhalten zu bekommen (von Ahn et al. 2008). Mittlerweile wird ReCAPTCHA auch eingesetzt, um Hausnummern und Straßennamen aus Google Street View Bildern zu extrahieren oder andere Bilddaten zu annotieren.

Im Kontext von Landnutzungskartierungen und Fernerkundung wird Crowdsourcing vorrangig zur Erhebung von Trainings- und Validierungsdaten genutzt (Fritz et al. 2012; See et al. 2013; Laso Bayas et al. 2016). Im EU-Projekt CAP4Access wurde Crowdsourcing zur Erfassung von Daten über Fußgängerwege verwendet, um Beiträge für behindertengerechte Fußgängernavigationssysteme zu liefern (Hahmann et al. 2016). Neben der Klassifizierung (Annotation, Labeling) von Objekten können auch komplexere

Tasks zur Digitalisierung von Polygonen oder das Zusammenführen von Datensätzen (Conflation) definiert werden (Albuquerque et al. 2016). Hillen und Höfle (2015) nutzen beispielsweise den ReCAPTCHA-Ansatz und entwickelten einen Prototypen (Geo-reCAPTCHA) zur Digitalisierung von Gebäudegrundrissen. Der Ansatz wurde später um die Möglichkeiten zur Erfassung von 3D-Informationen aus Punktwolken weiterentwickelt (Hillen et al. 2016).

### **3 System zur Crowdsourcing-gestützten Gebäudetypenklassifizierung**

Nachfolgend stellen wir ein integriertes System zur automatischen Klassifizierung von Gebäudegrundrissen vor. Bei diesem System wird ein maschinelles Lernverfahren zur Gebäudetyperkennung (Hecht 2014, Hecht et al. 2015) um eine Crowdsourcing-Komponente erweitert. Mittels Crowdsourcing werden Eigenschaften zu Gebäuden erfasst, die dem Training und der Validierung des Lernverfahrens dienen. Als Grundlage für die Interpretation werden geokodierte Straßenansichten (Street Views) aus dem Internet verwendet.

Der Arbeitsablauf für die Crowdsourcing-basierte Erhebung von Referenzdaten zur automatischen Klassifizierung ist in Abbildung 1 dargestellt und umfasst im Wesentlichen sechs Schritte.

Zunächst müssen in einer Problemdefinition (1) die zu erkennenden Gebäudetypen und deren typischen Charakteristika bei Betrachtung in Straßenbildern definiert werden.

Anschließend erfolgt die Dekomposition des Klassifikationsproblems in einzelne Bildannotationsaufgaben (2). Dies wird durch das Erstellen einfacher Fragen realisiert. Die Fragen beziehen sich dabei auf alle identifizierten visuellen Charakteristika, die für eine eindeutige Trennung der Typen nötig sind. Eine einfache Aufgabe wäre beispielsweise eine binäre Abfrage, ob eine bestimmte Eigenschaft zutrifft oder nicht. Komplexe Aufgaben eröffnen dem Teilnehmer mehr als zwei Antwortmöglichkeiten mit einer oder mehreren möglichen Auswahloptionen (Single-/Multiple-Choice-Fragen). Einer der wichtigsten Aspekte beim Design von Tasks ist die leichte Verständlichkeit und Bedienerfreundlichkeit. Ein Task sollte mit einem geringstmöglichen Zeitaufwand lösbar sein. Des Weiteren sind Einschränkungen im Zusammenhang mit Displaygröße und Lesbarkeit zu beachten (Darstellung auf PC-Bildschirm oder Smartphone).

Im Schritt (3) werden die Bilddaten gesammelt, welche später zu annotieren sind. Im Allgemeinen werden geokodierte Straßenansichten (Street view) oder Vogelperspektiven (Bird's eye view) bevorzugt, da diese das Erkennen von wichtigen Gebäudeeigenschaften ermöglichen. Potenzielle Bildquellen sind Google Street View, Microsoft Bing Maps Bird's Eye Views sowie auch offene Bild- und VGI-Plattformen, wie Wikimapia,

OpenStreetCam oder Mapillary. Grundsätzlich sind jedoch auch Bilddaten aus sozialen Medien (Flickr, Facebook, Instagram etc.) denkbar, sofern ein automatisierter API-gesteuerter Zugriff mittels räumlicher Abfrage möglich ist. Die Bildauswahl kann auf Grundlage einer Zufallsstichprobe einer Adressliste erfolgen, die im Vorfeld aus einer räumlichen Datenbank abgeleitet wurde.

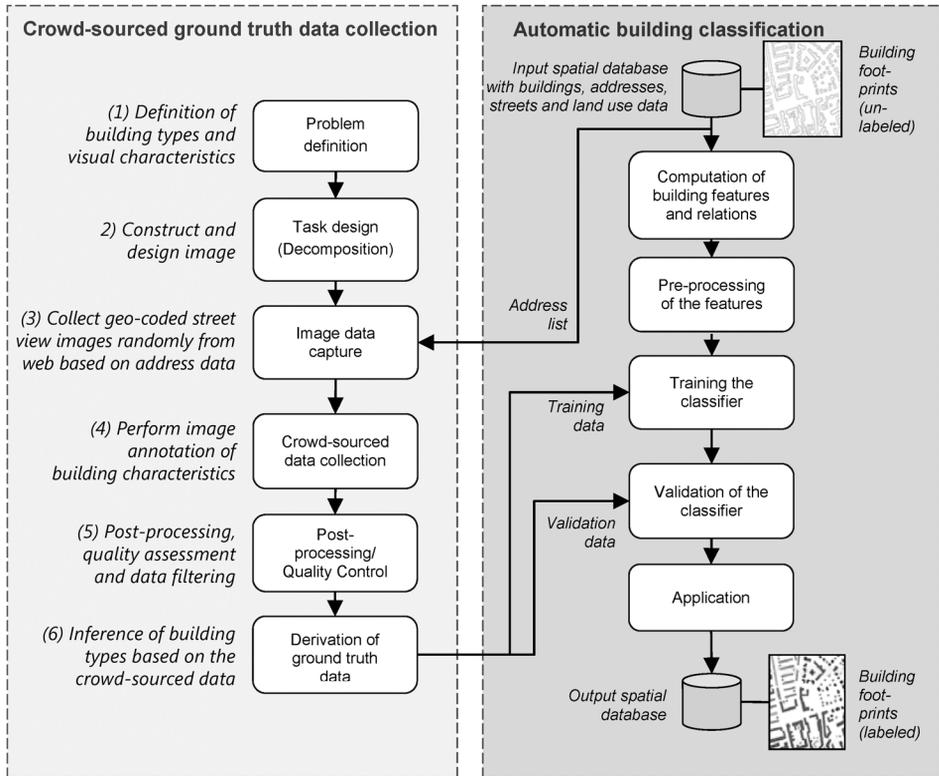


Abb. 1: Arbeitsablauf für die Crowdsourcing-basierte Erhebung von Referenzdaten zur automatischen Gebäudeklassifikation (Quelle: Hecht et al. 2017)

Nach Sammlung der Bilddaten wird deren Annotation durch die Crowd durchgeführt (4). Die Antworten auf die Tasks werden gemeinsam mit einer Reihe verfügbarer Meta-informationen (Zeit, Nutzernamen/IP-Adresse, Land, etc.) gespeichert. Zur Sicherung der Qualität wird jeder Task mehreren Nutzern zur Annotation vorgelegt.

In einer anschließenden Nachprozessierung (5) werden die Resultate auf Grundlage des Mehrheitsprinzips (majority voting) aggregiert. Mittels intrinsischer Maße zur Qualität der Annotation können minderwertige Aufzeichnungen eliminiert und unzuverlässige Nutzer identifiziert und ggf. aus der weiteren Prozesskette ausgeschlossen werden.

Im letzten Schritt (6) werden die Gebäudetypen, basierend auf den abgeleiteten Charakteristiken, abgeleitet (Komposition). Die somit erzeugten Referenzdaten können nach-

folgend zum Training bzw. zur Validierung im Kontext einer automatischen Gebäudeklassifizierung Anwendung finden.

## 4 Experimentelle Studie

Im Rahmen einer ersten experimentellen Studie soll der Crowdsourcingansatz zur Erhebung von ausgewählten Gebäudeeigenschaften unter Verwendung von online verfügbaren Straßenbildern erprobt werden. Im Folgenden wird das Setup des Experiments vorgestellt.

### 4.1 Definition der Gebäudetypen

In der Studie fokussieren wir auf die Klassifikation des Wohngebäudebestandes in Deutschland. Entsprechend Hecht et al. (2015) wird eine hierarchisch strukturierte Typologie verwendet, die neun Wohngebäudetypen unterscheidet: Freistehendes Einfamilienhaus (EFH), halbfreistehendes EFH, EFH als Reihenhauseinheit, Mehrfamilienhaus (MFH) in offener Bauweise, MFH in geschlossener Bauweise (Blockrandbebauung), MFH in traditioneller Zeilenbauweise, MFH in industrieller Zeilenbauweise (Plattenbau), MFH als Hochhaus sowie ländliches Haus.

### 4.2 Task-Design

Um die Anforderung nach möglichst einfacher Lösbarkeit der Tasks zu erfüllen, wurden sehr einfache Fragen formuliert, deren Beantwortung unproblematisch für jedermann sein sollte, unabhängig vom kulturellen Kontext des Bearbeiters. Dafür wurden zunächst die relevantesten Gebäudeeigenschaften zur Unterscheidung der Gebäudetypen definiert. Dies sind der morphologische Typ (z. B. freistehend vs. gereiht), die Anzahl der Stockwerke, die Wohnform (Einfamilienhaus vs. Mehrfamilienhaus), die Dachform und das Gebäudealter.

Mithilfe dieser Kriterien wurden sechs Aufgaben (Tasks) mit einfacher Antwortmöglichkeit formuliert, die jeweils eine Gebäudeeigenschaft adressieren (Tab. 1). Das Gebäudealter wurde separat für MFH (Task 5) und EFH (Task 6) über einen Fassadentyp approximiert. Dabei hatten die Teilnehmer Beispielbilder von typischen Fassadenansichten einzelner Bauperioden zur Auswahl, um das zu klassifizierende Gebäude entsprechend einzuordnen.

Tab. 1: Definierte Tasks und abgefragte Eigenschaften (Quelle: Hecht et al. 2017)

Task	Question	No. of options	Options
T1: Morphological type	Which type of building do you see?	3	Detached house, semi-detached house, row house
T2: Number of floors	How many storeys do you see (including ground storey)?	9	1, 2, 3, 4, 5, 6, 7, 8-15, 15 and more
T3: Housing type	Do you see a single-family house or a multi-family house?	2	single-family house (SFH), multi-family house (MFH)
T4: Roof type	Do you see a flat roof or a steep roof?	2	flat roof, steep roof
T5: Façade type (only MFH)	What type of façade is most similar to the building you see?	5	Wilhelminian Style (1870-1918), Traditional row houses (1918-1945), Traditional row houses (1945-1990), Industrial row houses (Precast concrete) (1970-1990), Modern construction (after 1990)
T6: Façade type (only SFH)	What type of façade is most similar to the building you see?	3	before 1870 (pre-industrial), 1870-1918, (Wilhelminian style), after 1919 (after first world war)

### 4.3 Bilddatensammlung

Für die Städte Dresden und Hamburg waren Gebäudereferenzdaten aus früheren Studien und Expertenbegehungen vorhanden. Diese beinhalten neben den Gebäudegrundrissen auch die postalischen Adressen sowie Informationen zum Gebäudetyp (entsprechend den 9 Typen), Gebäudehöhe (in Metern) und das Baualter (Periode). Darauf basierend wurde eine zufällige Stichprobe von 2 000 Gebäuden gezogen und als Adressliste verwendet, um mittels der API von Google Street View automatisiert standardisierte HTTP-Abfragen zu generieren. Die resultierenden Street-View-Ansichten wurden visuell auf Tauglichkeit und Erkennbarkeit bewertet und nötigenfalls durch Anpassung der Parameter bei der URL-Abfrage (z. B. Zoomstufe, Blickwinkel, Bildneigung) adaptiert. Etwa 46 % der Bilder konnten wegen der bei Google Street View auf Verlangen der Hausbewohner bzw. -eigentümer durchzuführenden Unkenntlichmachung von Gebäuden nicht verwendet werden. Der endgültige Datensatz umfasste 924 Gebäudeabbildungen (ca. 100 pro Gebäudetyp) und wurde in einer Datenbank inklusive der postalischen Adresse, der URL-Abfrage, den Gebäudekoordinaten und den vorliegenden Referenzdaten (Typ, Höhe, Dachform, Baualter etc.) abgelegt.

## 4.4 Implementation

Die Implementation der Tasks erfolgte mit Unterstützung der Firma Pallas Ludens GmbH ([www.pallas-ludens.com](http://www.pallas-ludens.com)), die sich spezialisiert hat, Crowdsourcing-Tasks in Computerspiele einzubetten. Onlinespieler haben die Möglichkeit, gegen eine Belohnung (virtuelle Währung) eine Aufgabe zu lösen. Ein weltweit verbreitetes Onlinespiel für Desktop-PC, in dem die Tasks durch Ersetzen von Werbefilmen eingebettet wurden, ist das Farmspiel „Farmerama“ der Firma Bigpoint ([www.bigpoint.net](http://www.bigpoint.net)). Die Anzahl der aktiven Spieler, welche als „Crowd“ potenziell zur Verfügung stehen, wird auf etwa 250 000 Personen pro Monat geschätzt (Pallas Ludens 2014). Die Nutzerschnittstelle der spielunterbrechenden Tasks besteht aus zwei Komponenten: einem Feld zur Visualisierung des Street-View-Bildes des zu klassifizierenden Gebäudes und einem Dialogfeld zur Auswahl der vorgegebenen Antwortmöglichkeiten. Interaktive Schaltflächen (Radio buttons) mit symbolhaften Illustrationen und ergänzenden Texteinblendungen beim Überfahren mit der Maus unterstützen den Annotationsprozess. Die Nutzer werden gebeten, eine der gebotenen Kategorien anzuklicken (Abb. 2).



Abb. 2: Beispiel einer Interaktionsabfrage zur Lösung von Task 1. Linksseitig befindet sich das Street-View-Bild des gewählten Gebäudes (Doppelhaus/Zweifamilienhaus). Rechts erscheint das Auswahlfeld mit den möglichen anklickbaren Antwortmöglichkeiten (Quelle: eigene Darstellung; Google Street View © Google 2016)

Der durch die Pallas Ludens GmbH durchgeführte Annotationsprozess resultierte in strukturierten JSON-Dateien (JavaScript Object Notation), welche anschließend in CSV-Daten (Comma-separated values) konvertiert wurden und die folgenden Werte für jede einzelne Annotation umfassten:

- annotation\_ID: eindeutiger Identifikator für die Annotation (Integer)
- task\_ID: Identifikator des Tasks (Integer)
- image\_ID: Identifikator des Bildes (Integer)
- creator: Nutzernamen als Identifikator des Annotators (Text)
- result: Kategorie der Nutzer (Text)

Diese Daten bilden die Grundlage für die statistischen Analysen und die Validierung. Zum Abgleich mit den externen Referenzdaten wurde für jedes Bild die am häufigsten vergebene Klasse (majority vote) ermittelt.

## 5 Ergebnisse

Einen ersten Überblick über die Daten gibt die Übersichtsstatistik in Tabelle 2. Die Statistik zeigt, dass viele verschiedene Nutzer (Annotatoren) jeweils einen sehr kleinen Anteil zur Lösung der Tasks beigetragen haben. Im Schnitt hat jeder Annotator mit nur insgesamt 5 bis 14 Annotationen beigetragen. Dies ist dadurch begründet, dass die Nutzer im Online-Spiel nur sehr selten mit einer zu lösenden Task konfrontiert werden.

Tab. 2: Übersicht der Daten und deskriptive Statistik (Quelle: eigene Darstellung)

Task	Bilder	Anzahl an Kategorien	Anzahl an Annotationen	Anzahl an Annotatoren	Mittlere Anzahl an Annotationen pro Bild	Mittlere Anzahl an Annotationen pro Annotator	Mindestanzahl an Annotationen für 95 % aller Bilder
T1:Morphological type	924	3	17 644	2 888	19,1	6,1	14
T2:Number of floors	924	9	13 710	2 097	14,8	6,5	15
T3:Housing type	924	2	13 857	1 001	15,0	13,8	14
T4:Roof type	639	2	13 497	1 047	21,1	12,9	20
T5:Façade type (only MFH)	519	5	18 159	3 525	35,0	5,2	20
T6:Façade type (only SHF)	405	3	14 175	2 896	35,0	4,9	35

Die mittlere Anzahl an Annotationen pro Bild ist mit 15 bis 35 sehr hoch. Aufgrund dieser hohen Redundanz konnte sichergestellt werden, dass 95 % aller Bilder mindestens 14 Annotationen pro Task aufweisen (siehe auch Histogramm in Abb. 3).

Zur Bewertung der Qualität der mittels Crowdsourcing erhobenen Informationen gibt es verschiedene Möglichkeiten. Ein üblicher Ansatz ist der Vergleich mit extern erhobenen Referenzinformationen und die Berechnung von Genauigkeitsmaßen. Es wird hier die Gesamtgenauigkeit verwendet, welche als das Verhältnis der korrekten zur Gesamtzahl aller vergebenen Annotationen definiert ist. Weitere Genauigkeitsmaße, wie die Produzentengenauigkeit (Producer accuracy PA) und die Nutzergenauigkeit (User accuracy UA), zur

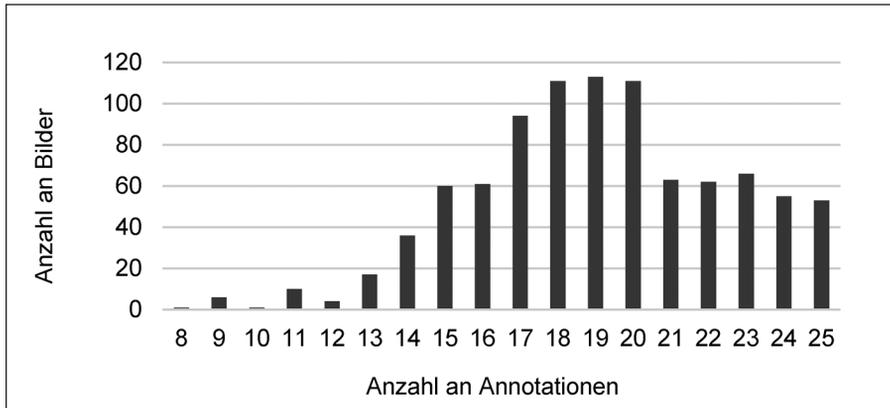


Abb. 3: Anzahl an Annotationen pro Bild für Task 1: Morphologischer Typ  
(Quelle: eigene Darstellung)

Bewertung der einzelnen Genauigkeiten für einzelne Kategorien können auf Basis einer Konfusionsmatrix berechnet werden (Congalton, Green 1998).

In Tabelle 3 ist die Qualität für jeden Task dargestellt. Die Gesamtgenauigkeit wurde durch den Vergleich der Ergebnisse aus dem Mehrheitsentscheid der Nutzerangaben mit externen Referenzdaten verglichen und die Anzahl korrekter und falscher Informationen ermittelt. Die Tabelle zeigt die höchste Genauigkeit für Task 2 (Geschossanzahl), Task 3 (Gehäusentyp) und Task 4 (Dachtyp) mit Werten über 0,84. Die Genauigkeit der Erkennung von Fassadentypen, die zur Rekonstruktion des Bauzeitalters (Task 5 und 6) verwendet werden sollen, ist jedoch nicht befriedigend. Offenbar ist die Zuordnung der Gebäude zu einem bestimmten Fassadentyp zu schwierig für Laien. Überraschenderweise ist die Erkennungsgenauigkeit der Wohnform mit 86 % relativ hoch. Die Genauigkeit von Task 1 (morphologischer Typ) war jedoch unerwartet niedrig. Vertiefte Untersuchungen deuten darauf hin, dass es häufig zu Verwechslungen zwischen Reihenhäusern und Doppelhaushälften kommt, wenn ein ungünstiger Bildausschnitt oder eine Verdeckung vorliegt, die eine Erkennung der Nachbargebäude nicht ermöglichen. Des Weiteren spielt offenbar auch ein fehlendes Verständnis für eine richtige Gebäudeabgrenzung eine Rolle, die am Ende zu einer falschen Interpretation führt. Weitere Untersuchungen sind hierfür erforderlich, um die Ursachen für diese Fehlklassifikation zu ermitteln. Es sei allerdings erwähnt, dass der morphologische Typ eindeutig und automatisch aus Gebäudegrundrissdaten abgeleitet werden kann, sofern es die Datenqualität erlaubt (Hartmann et al. 2016). Ein Crowdsourcing-basierter Ansatz wäre bei gegebenen Gebäudedaten zur Erhebung dieser Eigenschaft nicht nötig.

Tab. 3: Genauigkeiten der einzelnen Tasks (Quelle: eigene Darstellung)

Task	Korrekt	Falsch	Gesamtgenauigkeit
T1: Morphologischer Typ	529	395	0,57
T2: Anzahl an Geschosse*	803	121	0,87
T3: Wohnform	792	132	0,86
T4: Dachtyp	538	101	0,84
T5: Fassadentyp (MFH)	247	272	0,48
T6: Fassadentyp (EFH)	262	142	0,65

\* unter Zulassung einer Toleranz von  $\pm 1$  Geschosse

## 6 Diskussion und Ausblick

Der Beitrag zeigt das Potenzial von Crowdsourcing für die Gewinnung von Gebäudeinformationen aus Straßenansichten. Die hier vorgestellten Ergebnisse geben einen ersten Einblick in die zu erreichende Qualität. Für einen tieferen Einblick sind jedoch weitere differenziertere Qualitätsbetrachtungen (z. B. nach Gebäudetypen) nötig. Zudem wurden bisher nur die einzelnen Charakteristiken validiert. Ziel sollte es jedoch sein, die Qualität der aus den Charakteristiken abgeleiteten Gebäudetypen (nach der Komposition) zu ermitteln.

Eine externe Validierung erfordert stets Referenzdaten, die jedoch nicht immer verfügbar sind. Daher sollten geeignete intrinsische Maße als Näherungswerte für die Qualität eines Datensatzes entwickelt werden. Auch sollten Maße entwickelt werden, mit denen die Vertrauenswürdigkeit einer Annotation quantifiziert werden kann. Dies könnte dann Grundlage für eine Filterung sein, um nur die Informationen weiter zu verarbeiten, die von vertrauenswürdigen Nutzern kommen.

Für diese experimentelle Studie haben wir eine Online-Spielumgebung zum Crowdsourcing. Neben dieser Möglichkeit existieren eine Vielzahl anderer kommerzieller (z. B. Amazon MTurk) oder kostenfreier Plattformen (Crowdcrafting oder Zooniverse), die in diesem Zusammenhang getestet werden könnten. Auch im Hinblick auf die verwendeten Bilddaten gibt es kostenfreie alternative Datenquellen. Die VGI Plattform Wikimapia enthält beispielsweise einen großen Bestand an geokodierten Bildern zu Gebäuden, während Mapillary Straßenbilder anbietet, in denen auch der straßenzugewandte Teil von Gebäuden zu erkennen ist. Eine weitere interessante, wenn auch nicht flächendeckend verfügbare und nicht kostenfreie Bilddatenquelle, sind die Bird's Eye View Daten von Microsoft Bing Maps. Die API ermöglicht damit auch die Bereitstellung multiperspektivische Ansichten, die den Nutzern zur Verfügung gestellt werden können.

Auch wenn weitere Forschungsarbeiten notwendig sind, so glauben wir, dass der hier vorgestellte Ansatz das Potenzial hat, den Aufwand bei der Erfassung von Gebäudeinformationen massiv zu reduzieren. Eine effizientere Erfassung ist auch international bedeutsam, da damit auch Kartierungen im Katastrophen- und Krisenmanagement unterstützt werden können.

## 7 Literatur

- Albuquerque, J. P.; Herfort, B.; Eckle, M. (2016): The Tasks of the Crowd: A Typology of Tasks in Geographic Information Crowdsourcing and a Case Study in Humanitarian Mapping. In: *Remote Sensing* 8/2016: 859.
- Congalton, R. G.; Green, K. (1998): *Assessing the Accuracy of Remotely Sensed Data: Principles and Practices*, 1st ed. CRC Press.
- Donath, A.; Kondermann, D. (2013): Is Crowdsourcing for Optical Flow Ground Truth Generation Feasible?. In: Chen M.; Leibe B.; Neumann B. (eds): *Computer Vision Systems. ICVS 2013. Lecture Notes in Computer Science Vol. 7963*. Berlin, Heidelberg: Springer.
- Estellés-Arolas, E.; González-Ladrón-de-Guevara, F. (2012): Towards an integrated crowdsourcing definition. In: *Journal of Information Science* 38/2012: 189-200.
- Fritz, S.; McCallum, I.; Schill, C.; Perger, C.; See, L.; Schepaschenko, D.; van der Velde, M.; Kraxner, F.; Obersteiner, M. (2012): Geo-Wiki: An online platform for improving global land cover. In: *Environmental Modelling & Software* 31/2012: 110-123.
- Hahmann, S.; Zipf, A.; Rousell, A.; Mobasher, A.; Rylow, M.; Steiger, E.; Loos, L.; Lauer, J. (2016): GIS-Werkzeuge zur Verbesserung der barrierefreien Routenplanung aus dem Projekt CAP4Access. In: *AGIT – Journal für Angewandte Geoinformatik* 2: 328-333.
- Hartmann, A.; Meinel, G.; Hecht, R.; Behnisch, M. (2016): A Workflow for Automatic Quantification of Structure and Dynamic of the German Building Stock Using Official Spatial Data. In: *ISPRS International Journal of Geo-Information* 5/2016: 142.
- Hecht, R. (2014): *Automatische Klassifizierung von Gebäudegrundrissen – Ein Beitrag zur kleinräumigen Beschreibung der Siedlungsstruktur*. Berlin: Rhombos-Verlag, IÖR Schriften Band 63: S. 440.
- Hecht, R.; Kalla, M.; Krüger, T. (2017): Crowd-sourced data collection to support automatic classification of building footprint data. In: *Proceedings of the 28th International Cartographic Conference (ICC2017), July 1-8th 2017, Washington DC, USA*, 1-10.
- Hecht, R.; Meinel, G.; Buchroithner, M. F. (2015): Automatic identification of building types based on topographic databases – A comparison of different data sources. In: *International Journal of Cartography* 1/2015: 18-31.

- Hillen, F.; Gerdas, M.; Herfort, B.; Höfle, B. (2016): 3D-MicroMapping – Crowdsourcing zur Klassifikation von 3D-Geodaten. In: AGIT – Journal für Angewandte Geoinformatik 2: 156-161.
- Hillen, F.; Höfle, B. (2015): Geo-reCAPTCHA: Crowdsourcing large amounts of geographic information from earth observation data. In: International Journal of Applied Earth Observation and Geoinformation 40/2015: 29-38.
- Howe, J. (2006): The rise of crowdsourcing. In: Wired Magazine 14(6): 1-4.
- Laso Bayas, J. C.; See, L.; Fritz, S.; Sturn, T.; Perger, C.; Dürauer, M., Karner, M.; Moorthy, I.; Schepaschenko, D.; Domian, D.; McCallum, I. (2016): Crowdsourcing In-Situ Data on Land Cover and Land Use Using Gamification and Mobile Technology. In: Remote Sensing 8(11): 905.
- Maier-Hein, L.; Mersmann, S.; Kondermann, D.; Stock, C.; Kenngott, H. G.; Sanchez, A.; Wagner, M.; Preukschas, A.; Wekerle, A. L.; Helfert, S.; Bodenstedt, S.; Speidel, S. (2014): Crowdsourcing for reference correspondence generation in endoscopic images. In: Medical Image Computing and Computer-Assisted Intervention – MICCAI, Springer: 349-356.
- Pallas Ludens (2014). We inject human intelligence precisely where automation fails. In: Andrulis, J.; Kondermann, D. Presentation.  
[http://www.spectronet.de/portals/visqua/story\\_docs/vortraege\\_2014/141104\\_vision/141104\\_06\\_02\\_kondermann\\_pallas\\_ludens.pdf](http://www.spectronet.de/portals/visqua/story_docs/vortraege_2014/141104_vision/141104_06_02_kondermann_pallas_ludens.pdf) (Zugriff: 01.09.2017).
- Römer, C.; Plümer, L. (2010): Identifying architectural style in 3D city models with support vector machines. In: Photogrammetrie – Fernerkundung – Geoinformation 5: 371-384.
- Salk, C. F.; Sturn, T.; See, L.; Fritz, S.; Perger, C. (2016): Assessing quality of volunteer crowdsourcing contributions: lessons from the cropland capture game. In: International Journal of Digital Earth 9(4).
- See, L.; Comber, A.; Salk, C.; Fritz, S.; van der Velde, M.; Perger, C.; Schill, C.; McCallum, I.; Kraxner, F.; Obersteiner, M. (2013): Comparing the Quality of Crowdsourced Data Contributed by Expert and Non-Experts. In: PLoS ONE 8(7), e69958.
- See, L.; Mooney, P.; Foody, G.; Bastin, L.; Comber, A.; Estima, J.; Fritz, S.; Kerle, N.; Jiang, B.; Laakso, M.; Liu, H-Y.; Milčinski, G.; Nikšič, M.; Painho, M.; Pödör, A.; Olteanu-Raimond, A.-M.; Rutzinger, M. (2016): Crowdsourcing, Citizen Science or Volunteered Geographic Information? The Current State of Crowdsourced Geographic Information. In: ISPRS International Journal of Geo-Information 5(5): 55.
- Snow, R.; O'Connor, B.; Jurafsky, D.; Ng, A. J. (2008): Cheap and fast – but is it good? Evaluating non-expert annotations for natural language tasks. Proceedings of the Conference on Empirical Methods in Natural Language Processing (EMNLP), ACM Press, 254-263.
- von Ahn, L.; Maurer, B.; McMillen, C.; Abraham, D.; Blum, M. (2008): reCAPTCHA: Human-Based Character Recognition via Web Security Measures. In: Science 321(5895): 1465-1468.