

Straßenzustandsermittlung durch Klassifikation mobiler Sensordaten von Smartphones

Johannes Lauer, Andreas Jochem, Alexander Zipf

Abteilung Geoinformatik
Geographisches Institut, Universität Heidelberg
Berliner Straße 48
69120 Heidelberg
johannes.lauer@geog.uni-heidelberg.de
andreas.jochem@geog.uni-heidelberg.de
zipf@uni-heidelberg.de

Abstract: Moderne handelsübliche "Smartphones" verfügen heutzutage über hohe Rechenkapazitäten und sind mit einer Vielzahl hochempfindlicher Sensoren wie zum Beispiel GPS, Gyroskop, Beschleunigungs- und Orientierungssensoren ausgestattet. Analyse, Auswertung und Fusion dieser Sensoren können für eine große Anzahl mobiler Anwendungen herangezogen werden. Die Anwendungsbereiche, welche auf diese Sensoren zurückgreifen reichen von einfachen Geschicklichkeitsspielen bis hin zu sehr komplexen Verfahren, mit welchen sich die Positionen der Nutzer innerhalb von Gebäuden bestimmen lassen. In Rahmen dieser Arbeit werden sowohl GPS, Orientierungs- als auch Beschleunigungssensoren während des Befahrens einer Straße aus einem Android Smartphone ausgelesen, analysiert und für die Klassifikation des Straßenzustandes verwendet. Die ausgelesenen Sensordaten dienen als Eingangsdaten zur Durchführung eines überwachten Klassifikationsverfahrens. Dadurch wird eine Einteilung der Straßen in die Klassen (i) einwandfreie (ii) mittelmäßige (iii) Schotterstraßen vorgenommen.

1 Problem

Die Ermittlung von Straßenzuständen und -eigenschaften ist ein sehr komplexes Feld. Neben den Kommunen, Landkreisen, Ländern und dem Bund (welche innerhalb Deutschlands in der Regel Eigner der Straßen sind) besteht auch Seitens der Karten- und Navigationsgerätehersteller und damit auch von Seiten der Anwender aus Logistik, Land- und Forstwirtschaft, Tourismus, sowie aller Nutzer öffentlicher Straßen und Wege, ein Interesse Eigenschaften wie Fahrbahnbeschaffenheit und -zustand zu kennen. Die Kosten, die durch das Befahren der Straßen mit speziell dafür entwickelten Messfahrzeugen entstehen sind erheblich (mehrere hundert €/km). Somit sind sowohl der technische, als auch der personelle Aufwand sehr kostenintensiv. In diesem Beitrag wird daher ein Ansatz entwickelt, der aufzeigt wie diese Kosten durch den Einsatz von Smartphones als Sensorplattform reduziert werden können. Es werden Potentiale und Grenzen aufgezeigt inwieweit die Möglichkeit besteht, auf Basis der gemessenen Sensordaten, Rückschlüsse auf die Beschaffenheit der Fahrbahn unter festgelegten Messbedingungen zu treffen. Diese Arbeit beruht auf der Annahme, dass die Straßenverhältnisse mit den Messwerten der Beschleunigungssensoren, welche beim Befahren einer Straße aufgezeichnet werden korrelieren, d.h. die Messwerte der Beschleunigungssensoren spiegeln die aktuellen Straßenzustände wider.

2 Stand der Forschung

Moderne handelsübliche Smartphones verfügen heutzutage über hohe Rechenkapazitäten und sind mit einer Vielzahl hochempfindlicher Sensoren ausgestattet. Dazu gehören unter anderem GPS, Gyroskop, Beschleunigungs- und Orientierungssensoren. Die aufgezeichneten Sensordaten werden mittlerweile für eine Vielzahl von Anwendungen herangezogen. Zur Klassifikation dieser Daten wird in den meisten Fällen auf Data Mining Methoden zurückgegriffen. In einigen Arbeiten werden zum Beispiel die Werte der Beschleunigungssensoren hinsichtlich ihrer Eignung für "Activity Recognition" herangezogen (bspw. Mladenov und Mock 2009). Kwapisz et al. (2010) entwickelten ein auf Data Mining basiertes Model, welches die Werte der Beschleunigungssensoren heranzieht um auf Basis dieser Daten unterschiedliche menschliche Bewegungsmuster (z.B. gehen, joggen, sitzen, stehen) erkennen zu können. Dabei werden zum Teil Vorhersagegenauigkeiten von mehr als 90% erzielt. Wiederum andere Arbeiten beschäftigen sich mit der Auswertung der Beschleunigungs- und Drehratensensoren zur Positionsbestimmung innerhalb von Gebäuden, wo GPS Signale generell nicht zur Verfügung stehen. Schmidt (2010) untersucht in seiner Arbeit unter anderem die Eignung der Beschleunigungs- bzw. Orientierungsdaten eines auf Android basierenden Smartphones (HTC Hero) für die Positionsbestimmung innerhalb von Gebäuden.

Zusätzliche Stützinformationen zur Positionsbestimmungen werden hierbei nicht herangezogen. Zufriedenstellende Ergebnisse hinsichtlich der exakten Positionsbestimmung können aufgrund der noch zu ungenauen Sensorwerte jedoch nicht erzielt werden. Oschatz (2011) kommt ebenfalls zu der Schlussfolgerung, dass die in Smartphones integrierte Sensorik noch weiterer Optimierung bedarf, um somit bessere Verfahren zur Schrittbestimmung entwickeln zu können und Ungenauigkeitsfehler hinsichtlich der Indoor Positionsbestimmung reduzieren zu können.

Im Bereich der Straßenzustandserfassungen haben sich die Beschleunigungssensoren ebenfalls als geeignete Datenquelle zur Detektion von Schlaglöchern erwiesen (Strazdins et al. 2010), wobei der Einfluss unterschiedlicher Hardware Spezifikationen noch genauer zu untersuchen ist. Eriksson et al. (2008) nutzen die Daten von Smartphone Sensoren zur Bestimmung von Schlaglöchern in einem Straßennetz. Dazu wurden innerhalb des Pothole Patrol Projektes sieben Taxen, die Fahrten innerhalb der Stadt Boston durchführen, mit Smartphones ausgestattet. Für die sehr große Testdatenmenge (>1000 km) wurde eine sehr hohe Klassifikationsgenauigkeit erreicht. Die Fehlklassifikation bei der gute Straßenabschnitte als schlecht erkannt wurden betrug lediglich 0.2%.

3 Hardware, Sensoren und Software-API

3.1 Android Smartphone als Sensorplattform

Durch die Vielzahl an Sensoren und die einfache Zugänglichkeit der Programmier API eignen sich Android Smartphones sehr gut zur Verwendung als Sensorplattform. Zudem sind Preis und Verfügbarkeit der Geräte in einem annehmbaren Rahmen, so dass sich sehr schnell erste Implementierungen und erste Tests realisieren lassen.

Als Beispielgeräte wurden zur Datenaufnahme zwei Modelle verwendet. Ein etwas älteres HTC Hero mit Android 2.1 und ein aktuelles Google Nexus S mit der (für Smartphones) aktuellsten Android Version 2.3.4. Dies ermöglicht einen Vergleich der beiden Hardwareplattformen und der Möglichkeiten, die die APIs zum Auslesen der Sensoren anbieten.

3.2 Beschreibung der Hardware

	HTC Hero	Samsung Nexus S
Prozessor	Qualcomm MSM7200A, 528 MHz	ARM Cortex-A8 (Hummingbird), 1 GHz mit PowerVR SGX 540 GPU
Beschleunigungssensor	Bosch Sensortec BMA150, 10-bit	STMicroelectronics KR3DM, 12-bit

Orientierungssensor	AK8973 Orientation Sensor ¹	AK8973 Orientation Sensor
GPS	Qualcomm GPSOne	Qualcomm GPSOne

Tabelle 1: Hardware Spezifikationen der verwendeten Smartphones

Durch die fast zweijährige Entwicklungszeit, die zwischen den beiden Modellen liegt, besitzt das Google Nexus S etwas höherwertige Sensoren.

3.3 Auslesen der Sensordaten mit Hilfe des Android SDK

Das Betriebssystem Android bietet Unterstützung für eine Vielzahl von Sensoren, wobei ein Gerät nicht immer alle unterstützten Sensoren enthalten muss. Mit Hilfe des Android Software Development Kit (SDK) kann man auf die einzelnen Sensoren zugreifen und die gewünschten Werte für die weitere Verarbeitung auslesen. Für die hier vorgestellte Anwendung werden sowohl die Werte von GPS als auch die der Bewegungs- und Orientierungssensoren erfasst und aufgezeichnet. Zum Auslesen dieser Werte benötigt man eine Instanz des sogenannten SensorManager, über welchen die unterschiedlichen Sensoren angesprochen werden. Die abstrakte Klasse SensorEventListener ermöglicht es die Änderungen der jeweiligen Sensoren zu registrieren. Dadurch besteht die Möglichkeit die Werte aufzuzeichnen sobald sich diese ändern. Im Rahmen dieser Arbeit wird der SensorEventListener für die Beschleunigungssensoren registriert. Eine Aufzeichnung der oben genannten Sensorwerte geht mit einer Änderung der Werte der Beschleunigungssensoren einher. Wahlweise können die Werte in eine Textdatei geschrieben oder über eine Verbindung im 3G Netz an einen eigens dafür aufgesetzten Server gesendet werden. Ein JAVA Servlet nimmt die per POST gesendeten Sensordaten entgegen und schreibt diese in eine relationale PostgreSQL Datenbank.

¹ <http://www.asahi-kasei.co.jp/akm/en/product/ak8973nbs/ak8973nbs.html>

4 Methodik

4.1 Datenerfassung

Die Messwerte der in Kapitel 3.2 beschriebenen Sensoren werden durch Befahren von "Trainingsstraßen" aufgezeichnet und anschließend für ein überwachtes Klassifikationsverfahren in Form eines Neuronales Netzes (Kapitel 4.3) herangezogen. Für das Befahren dieser Trainingsgebiete wird das Smartphone in einer eigens dafür hergestellten Halterung befestigt. Als Messfahrzeug wird ein VW Golf IV verwendet. Es werden sowohl einwandfreie, mittelmäßige als auch Schotterstraßen befahren, wobei die Einteilung der Trainingsgebiete in diese Straßentypen in der Subjektivität des Messteams liegt. Das programmierte Android App bietet die Möglichkeit die Messungen als Referenzmessung zu kennzeichnen. Dabei kann sowohl der Straßentyp als auch der Fahrzeugtyp (Auto, Fahrrad, Traktor) als Referenzmesswert angegeben werden. Im Rahmen dieses Beitrags wird allerdings nur auf den Fahrzeugtyp Auto als Messfahrzeug zurückgegriffen. Die aufgezeichneten Werte der Beschleunigungssensoren können zudem in Echtzeit in Form eines Diagramms visualisiert werden (Abbildung 1).



Abbildung 1: Das Grafische User Interface der entwickelten Android Anwendung

Die Datenaufzeichnung erfolgte innerhalb eines ausgewählten Gebietes in Heidelberg (Baden-Württemberg / Deutschland). Durch die regelmäßige Aufzeichnung der GPS Koordinaten können die Trainingsgebiete räumlich verortet und zur Darstellung in ein Geographisches Informationssystem (GIS) geladen werden (Abbildung 2).




Abbildung 2: Verortung eines Ausschnitts der aufgezeichneten Trainingsdaten innerhalb des Testgebietes in Heidelberg.

4.2 Preprocessing der Daten

4.2.1 Interpolation der GPS-Daten

Da sich die Abtastraten von GPS und Beschleunigungssensoren unterscheiden, werden die GPS Daten interpoliert, d.h. es werden, abhängig von der gefahrenen Geschwindigkeit zwischen den gemessenen GPS Positionen neue Punkte mit den gemessenen Beschleunigungswerten berechnet. Damit wird eine sehr viel höhere Datendichte erreicht (Abbildung 3).



Abbildung 3 Interpolierte GPS-Messungen (rot: gemessene GPS Position, grün: interpolierte Position)

4.2.1 Berechnung weiterer Kennwerte

Aus den gemessenen Rohdaten müssen prägnante Attribute ermittelt werden. Diese Attribute sind so zu wählen, dass sie eine Abgrenzung der verschiedenen Klassen erlauben. Zudem sind die Daten zu normieren.

Da die Lage des Smartphones nicht bekannt ist, bzw. sich bei zwischen den Messkampagnen verändern kann und sich somit die Beschleunigung orthogonal zur Fahrbahnoberfläche nicht ermitteln lässt, muss dieser Wert berechnet werden. Hierzu ist der resultierende Beschleunigungsvektor rechtwinklig zur Fahrbahnoberfläche zu bestimmen. Dies wird durch eine Systemdrehung unter Berücksichtigung der Orientierungsvektoren, die durch den Orientierungssensor des Smartphones gemessen werden, ermittelt. Das Resultat ist die tatsächlich auftretende Beschleunigung des Smartphones in orthogonaler Richtung zur Fahrbahnebene.

Abbildung 4 zeigt zwei Messausschnitte normierter Beschleunigungswerte in Z-Richtung, orthogonal zur Fahrbahnoberfläche. Die unterschiedlich großen Amplituden und die Anzahl der Peaks zeigen, wie erwartet, eine deutlich unruhigere Fahrt auf der Schotterstraße im Vergleich zur glatteren Straße. Dies legt die Vermutung nahe, dass sich aus diesen Messungen repräsentative Werte zur Trennung der beiden Klassen ableiten lassen.




Abbildung 4 Normierte Beschleunigungswerte für einwandfreie Straße und Schotterstraße

Zur Ermittlung der Rauigkeit einer Straße wird eine Mittelwertbildung über 20 gemessene Werte, sowie der mittlere Wert der fünf größten Peaks innerhalb eines 20 Messwerte Fensters berechnet.

Diese Daten fließen als Attribute in die Klassifikation ein. Nicht berücksichtigt werden die Positionsdaten, da diese bspw. bei parallelen Straßen zu unerwünschten Korrelationen führt.

4.3 Klassifikation

4.3.1 Trainingsdaten

Abbildung 5 zeigt Beispiele für die verwendeten Trainingsgebiete. Die glatte geteerte Straße links ist Repräsentant für eine einwandfreie Straße. Die mittlere Abbildung zeigt eine Straße mittelmäßigen Zustands mit teilweise eingesetzten Teerflicken und die rechte Abbildung zeigt einen als Trainingsdatensatz verwendeten Schotterweg.



Abbildung 5 Trainingsgebiete (einwandfrei, mittelmäßig, Schotter)

4.3.2 Klassifikationsverfahren

Zur Klassifikation der Daten wurde ein Neuronales Netz verwendet. Neuronale Netze lehnen sich an die Struktur eines Nervensystems an. Das Netz besteht aus mehreren Neuronen und Synapsen, den Verbindungen zwischen den einzelnen Neuronen. Ein Neuron besitzt mehrere Eingangs- und eine Ausgangsverbindung. Übersteigt die Summe der Eingangswerte einen festgelegten Schwellwert, so reagiert das Neuron und gibt ein Ausgangssignal.

Der Nachteil an Neuronalen Netzen besteht in der nicht Nachvollziehbarkeit der resultierenden Ergebnisse. Es lässt sich nachträglich keine Logik entwickeln, wie die Ergebnisse zu Stande kamen. Dies erschwert mitunter die Interpretierbarkeit. Das Neuronale Netz lernt durch Erfahrung, d.h. dass die Regeln nicht zu Beginn zur Verfügung stehen, sondern im Lernprozess entstehen. Dadurch gewinnen die Eingabedaten an Bedeutung. Entscheidend für eine gute Klassifikation ist also ein repräsentativer Trainingsdatensatz mit dem das Neuronale Netz die Erfahrung erlangen kann, die es zur späteren Klassifikation der Daten benötigt.

4.4 Klassifikationsergebnis

Es wurden etwa 14.000 Messwerte aufgenommen. Die aufgenommenen Daten wurden nach dem Zufallsprinzip in Verhältnis 80/20 (Trainings- und Validierungsdaten) aufgeteilt. Anschließend wurde die Klassifikation mit Hilfe der Ground Truth Daten bewertet. Das Klassifikationsergebnis zeigt, dass sich Straßen einwandfreien Zustands, d.h. bspw. Teerstraßen mit glattem Belag ohne Unebenheiten durch Schlaglöcher etc. anhand der Messwerte deutlich von anderen Straßen unterscheiden. Es zeigt sich jedoch auch, dass die eher subjektive Klassenbildung in einwandfrei, mittelmäßig und Schotter Probleme bei der Abgrenzung benachbarter Klassen aufwirft. Eine Gesamtklassifikationsgenauigkeit von 77.8% zeigt aber auch, dass es möglich ist, den Straßenzustand anhand der gemessenen und im Preprocessing errechneten Kennwerte zu ermitteln.



Abbildung 6 Klassifikationsergebnis links: einwandfreier Zustand, rechts: Schotterstraße

	true einwandfrei	true mittelmäßig	true Schotter	class precision
pred. einwandfrei	2058	485	15	80.45%
pred. mittelmäßig	92	147	36	53.45%
pred. Schotter	0	11	34	75.56%
class recall	95.72%	22.86%	40.00%	

Tabelle 2 Klassifikationsergebnis, Accuracy: 77.8%, Spearman ρ : 0.405

7 Diskussion

Der vorgestellte Ansatz zur Nutzung von Sensordaten zeigt, dass sich aus den aufgezeichneten Sensordaten unter festgelegten Bedingungen Straßenzustand und Fahrbahnbeschaffenheit ableiten lassen. Die mittlerweile am Markt verfügbaren Smartphones bieten eine Vielfalt an Sensoren. Gerade die Sensoren zur Detektion von Beschleunigung und Orientierung bieten eine hohe Abtastfrequenz, die eine ausreichend hohe Datendichte produziert. Die Android-API bietet zudem die Möglichkeit, diese Sensordaten einfach abzufragen und zu speichern. Bei der Auswertung der Daten sind jedoch einige Faktoren zu beachten.

So ist es nicht möglich Sensordaten just-in-time zu einem Server zu senden. Die Funkverbindung im 3G Netz bricht oft ab, so dass es zu Problemen beim Datentransfer kommt. Hierbei könnte die Implementierung eines Datenpuffers sinnvoll sein, so dass man die Daten so lange puffert, bis die Verbindungsqualität ausreicht, um die Daten zum Server zu senden.

Die Sensorik der auf dem Markt verfügbaren Endgeräte ist sehr unterschiedlich. Die Sensoren älterer Geräte (1-2 Jahre) besitzen eine geringere Abtastfrequenz und liefern damit nicht die erforderliche Datendichte. Zudem sind die Prozessoren und die Leseschreibraten auf diesen Geräten meist zu langsam, um einen nutzbaren Datensatz zu erzeugen.

Die Lage des Gerätes innerhalb des Messfahrzeugs ist enorm wichtig. Durch die Normierung der Beschleunigungsdaten durch Einbezug der Orientierung des Mobilgerätes kann die Lage vernachlässigt werden. Die Position des Gerätes innerhalb des Fahrzeugs spielt jedoch eine wichtige Rolle und beeinflusst die Daten enorm. Die durch die Beschleunigungssensoren ermittelten Kräfte beinhalten die von der Fahrbahn verursachte Vibration. Diese wird durch Reifen, Stoßdämpfer, ggf. Sitz oder Armaturenbrett (je nach Lage des Gerätes) verfälscht. Die wirkenden Kräfte sind auch, je nach Position im Fahrzeug unterschiedlich. So werden (nach den Hebelgesetzen) im Fußraum in der Fahrzeugmitte andere Werte gemessen, als auf Sitz, Hutablage oder Armaturenbrett. Zu den gemessenen Kräften, die durch Fahrbahnunebenheiten entstehen, fließen auch Motorvibrationen, Kurvenkräfte sowie positive und negative Beschleunigung des Fahrzeugs in die Messung ein. Weiterhin ist der Fahrzeugtyp (Sportcoupé, Limousine, Geländewagen, ...) aufgrund der unterschiedlichen Fahrwerkabstimmung und der unterschiedlichen Bereifung bei der Messung entscheidend. Diese Einflüsse auf die gemessenen Werte der Sensordaten bedürfen noch genauerer Untersuchungen und werden Gegenstand zukünftiger Forschungen sein.

Eine Klassifikation auf Basis der Rohdaten schließt sich schon aus den im Vorfeld genannten Faktoren aus. Hier ist es wichtig die zur Klassifikation günstigen Messwerte zu bestimmen und die Daten vor der Klassifikation derart zu bearbeiten, dass sie prägnante Merkmale zu den einzelnen Klassen repräsentieren. Mittelwertbildung, Anzahl der Peaks, Amplitude, Geschwindigkeitsquantile für festgelegte Messfenster sind nur einige Möglichkeiten diese Merkmale herauszuarbeiten.

Sehr wichtig ist die Klassenbildung, anhand derer die Trainingsgebiete festgelegt werden. Diese Klassen sollen einerseits zum Routing wichtige Eigenschaften repräsentieren (bspw. Schotter, Waldweg, Teerstraße (inkl. Zustand)) andererseits müssen sich diese Klassen auch anhand der gemessenen/prozessierten Attribute separierbar sein. Die Separabilität der einzelnen Klassen ist entscheidend zur Quantifizierung des Klassifikationsergebnisses. Weiterhin ist eine Orientierung an bestehenden Klassifikationen (OpenStreetMap, ATKIS, Straßenbau) sinnvoll, da ein Ziel darin besteht, die erhobenen Daten zur Ergänzung und Aktualisierung dieser Datenbestände zu nutzen.

Literaturverzeichnis

- [Ej08] Eriksson, J.; Girod, L.; Hull, B.; Newton, R.; Madden, S.; Balakrishnan, H.: The Pothole Patrol: Using a Mobile Sensor Network for Road Surface Monitoring. MobiSys'08, Colorado, USA, 2008
- [Kj10] Kwapisz, J.R.; Weiss, G.M.; Moore, S.A.: Activity Recognition using Cell Phone Accelerometers. SensorKDD '10, Washington, DC, 2010
- [Mm09] Mladenov, M., Mock, M.: A step counter service for Java-enabled devices using a built-in accelerometer, Proceedings of the 1st International Workshop on Context-Aware Middleware and Services: affiliated with the 4th International Conference on Communication System Software and Middleware (COMSWARE 2009), June 16-16, 2009, Dublin, Ireland
- [Oa10] Oschatz, A.: Indoor-Positionierung mittels Smartphone, Seminararbeit: Trends in mobilen und verteilten Systemen, Lehrstuhl für Mobile und Verteilte Systeme, LMU München, 2011
- [Sg11] Strazdins, G., Mednis, A., Kanonirs, G., Zviedris, R., Selavo, L.: Towards Vehicular Sensor Networks with Android Smartphones for Road Surface Monitoring, The Second International Workshop on Networks of Cooperating Objects, CONET 2011, April 11th, 2011 – Chicago, USA
- [Sr10] Schmidt, R.: Implementierung eines Inertialnavigationssystems für mobile Geräte, Institut für parallele verteilte Systeme, Universität Stuttgart (Studienarbeit Nr.2252), 2010